




การตรวจหามะเร็งผิวหนังชนิดเมลาโนมาบนภาพเดอริโมสโคปิกโดยใช้การเรียนรู้เชิงลึก  
MELANOMA DETECTION ON DERMOSCOPIC IMAGES USING DEEP LEARNING



รัชพล ปราบราย

บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ

2566

การตรวจหามะเร็งผิวหนังชนิดเมลาโนมาบนภาพเดอริโมสโคปิกโดยใช้การเรียนรู้เชิงลึก



สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
วิทยาศาสตร์มหาบัณฑิต สาขาวิชาวิทยาการข้อมูล  
คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ  
ปีการศึกษา 2566  
ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

MELANOMA DETECTION ON DERMOSCOPIC IMAGES USING DEEP LEARNING



RATCHAPHON PRABRAI

A Master's Project Submitted in Partial Fulfillment of the Requirements

for the Degree of MASTER OF SCIENCE

(Data Science)

Faculty of Science, Srinakharinwirot University

2023

Copyright of Srinakharinwirot University

สารนิพนธ์

เรื่อง

การตรวจหามะเร็งผิวหนังชนิดเมลาโนมาบนภาพเดอริโมสโคปิกโดยใช้การเรียนรู้เชิงลึก

ของ

รัชพล ปราบราย

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล

ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์ฉัตรชัย เอกปัญญาสกุล)

คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

ที่ปรึกษาหลัก

(อาจารย์ ดร.วีระ สอึ้ง)

ประธาน

(รองศาสตราจารย์ ดร.สุพัฒนา เอื้อทวีเกียรติ)

กรรมการ

(ผู้ช่วยศาสตราจารย์ ดร.ศิริสรรพ เหล่าหะเกียรติ)

ชื่อเรื่อง	การตรวจหามะเร็งผิวหนังชนิดเมลาโนมาบนภาพเดอริโมสโคปิกโดยใช้การเรียนรู้เชิงลึก
ผู้วิจัย	รัชพล ปราบราย
ปริญญา	วิทยาศาสตร์มหาบัณฑิต
ปีการศึกษา	2566
อาจารย์ที่ปรึกษา	อาจารย์ ดร. วีระ สอิ่ง

มะเร็งผิวหนังชนิดเมลาโนมาเป็นมะเร็งผิวหนังชนิดที่มีความรุนแรงมากที่สุดในจำนวนมะเร็งผิวหนังทั้งหมด การวินิจฉัยมะเร็งผิวหนังชนิดนี้ถือเป็นความท้าทายอย่างมากต่อบุคคลากรทางการแพทย์ เนื่องจากต้องอาศัยความรู้ ความชำนาญในการดูรอยโรคที่ผิวหนังด้วยตาเปล่า จุดประสงค์ของการศึกษารั้งนี้ต้องการจัดการความท้าทายในการวินิจฉัยมะเร็งผิวหนังชนิดเมลาโนมา โดยการนำเทคนิคการเรียนรู้เชิงลึกสำหรับการตรวจหารอยโรคมะเร็งที่ผิวหนังตั้งแต่ในระยะที่มะเร็งยังไม่แพร่กระจายไปยังส่วนอื่นของร่างกาย โดยในการศึกษารั้งนี้ได้ทำการรวบรวมข้อมูลจาก 4 ชุดข้อมูลสาธารณะ ทำให้ได้จำนวนภาพเดอริโมสโคปิกทั้งสิ้น 13,986 ภาพ หลังจากนั้นทำการแบ่งชุดข้อมูลออกเป็น Training Set, Validation Set และ Testing Set ตามอัตราส่วน 80,10,10 ตามลำดับ ในการศึกษารั้งนี้ใช้ตัวแบบที่มีสถาปัตยกรรมต่างกัน ได้แก่ VGG16, DenseNet201, ResNet152V2, EfficientNetB5, InceptionResNetV2, และ Xception เพื่อค้นหาตัวแบบที่มีประสิทธิภาพสูงสุด หลังจากนั้นทำการปรับไฮเปอร์พารามิเตอร์ ที่ปรับพารามิเตอร์ที่ให้ประสิทธิภาพสูงสุด ทำให้ในการศึกษารั้งนี้มีการสร้างตัวแบบทั้งหมด 384 แบบและทำการทดสอบกับ Testing Set พบว่าตัวแบบที่ให้ประสิทธิภาพสูงสุดคือ สถาปัตยกรรม EfficeientNetB5 ร่วมกับ Adam Optimizer และใช้ Batch Size 64 ร่วมกับ Learning Rate 0.01 ทำให้ได้ค่า Accuracy, Recall และ F1-Score เท่ากันที่ 0.94 มากไปกว่านั้นในการศึกษารั้งนี้ใช้ Grad-Cam ในการชี้ว่าจุดใดในภาพรอยโรคที่ตัวแบบให้ความสนใจ และใช้ในการทำนายบริเวณรอยโรค ดังนั้นแบบจำลองที่ได้จากการศึกษาในครั้งนี้น่าจะสามารถช่วยบุคคลากรทางการแพทย์ในการวินิจฉัยโรคมะเร็งผิวหนังชนิดเมลาโนมาได้อย่างมีประสิทธิภาพ

คำสำคัญ : เมลาโนมา, มะเร็งผิวหนัง, การเรียนรู้เชิงลึก

Title	MELANOMA DETECTION ON DERMOSCOPIC IMAGES USING DEEP LEARNING
Author	RATCHAPHON PRABRAI
Degree	MASTER OF SCIENCE
Academic Year	2023
Thesis Advisor	Dr. Vera Sa-ing

Melanoma, the most widespread form of skin cancer, poses a diagnostic challenge requiring considerable expertise in visual assessment. This study aims to address this challenge by investigating a deep learning technique for the early detection of cancerous lesions to mitigate their potential spread. Gathering four public skin lesion datasets, totaling 13,986 images, we divided them into 80% training, 10% validation, and 10% testing sets. This study used VGG16, DenseNet201, ResNet152V2, EfficientNetB5, InceptionResNetV2, and Xception to find the best model and then hyperparameter tuning to find the best parameter. 384 Models were implemented and tested with the test set in this study. The best model is EfficientNetB5 with Adam, batch size 64, and a learning Rate of 0.01 that gives Accuracy, Recall, and F1-Score equally at 0.94. Additionally, our study incorporates Grad-Cam visualization to pinpoint skin cancer areas, offering a nuanced understanding of the model's outcomes. This proposed model holds promise for healthcare professionals in diagnosing and focusing on skin cancers.

Keyword : Melanoma, skin cancer, deep learning, Image Classification

## กิตติกรรมประกาศ

งานวิจัยฉบับนี้จะไม่สามารถเกิดขึ้นได้หากขาดความช่วยเหลือ เอาใจใส่ และถ่ายทอดความรู้ ตลอดจนคอยแนะนำข้อผิดพลาดและข้อควรปรับปรุงของ อ.ดร.วีระ สอึ้ง อาจารย์ประจำภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ และเป็นอาจารย์ที่ปรึกษาหลักของงานวิจัยฉบับนี้ ข้าพเจ้าขอแสดงความขอบคุณเป็นอย่างสูงมา ณ ที่นี้

ขอขอบคุณคณาจารย์ภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒทุกท่านที่ได้ถ่ายทอดความรู้และประสบการณ์ที่ใช้ในการทำงานวิจัยชิ้นนี้

ขอขอบคุณบัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ ที่ได้มอบทุนการศึกษาในการเดินทางไปนำเสนอผลงานวิจัยในการประชุมวิชาการระดับนานาชาติให้กับข้าพเจ้า ข้าพเจ้าขอแสดงความขอบคุณเป็นอย่างสูงมา ณ ที่นี้

สุดท้ายนี้ข้าพเจ้าหวังเป็นอย่างยิ่งว่างานวิจัยฉบับนี้จะเป็นประโยชน์กับผู้เกี่ยวข้อง และหากมีข้อผิดพลาดประการใดข้าพเจ้าขอน้อมรับความผิดพลาดและกล่าวขออภัยมา ณ ที่นี้

รัชพล ปราบราย

## สารบัญ

	หน้า
บทคัดย่อภาษาไทย .....	ง
บทคัดย่อภาษาอังกฤษ .....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ .....	ช
สารบัญตาราง.....	ณ
สารบัญรูปภาพ .....	ญ
บทที่ 1 บทนำ.....	1
ที่มาและความสำคัญ .....	1
วัตถุประสงค์ของงานวิจัย .....	5
ขอบเขตงานวิจัย .....	6
ขั้นตอนการดำเนินงานวิจัย .....	6
ประโยชน์ที่คาดว่าจะได้รับจากงานวิจัย .....	7
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง .....	8
ทฤษฎีที่เกี่ยวข้อง .....	8
1. Overview of the Skin .....	8
2. Skin Cancer .....	9
3. Dermoscope .....	17
4. การเรียนรู้เชิงลึก (Deep Learning) .....	18
5. โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) .....	19
งานวิจัยที่เกี่ยวข้อง .....	22
บทที่ 3 แนวคิดและวิธีวิจัย .....	26



การเก็บรวบรวมข้อมูล (Data Acquisition) .....	26
การเตรียมข้อมูล (Pre-Processing) .....	28
การสร้างแบบจำลอง (Modeling) .....	29
1.VGG16 .....	29
2.DenseNet201 .....	29
3.ResNet152V2.....	30
4.EfficientNetB5 .....	31
5.InceptionResNetV2.....	32
6.Xception.....	33
การประเมินผลแบบจำลอง (Model Evaluation).....	34
1.Confusion Matrix.....	34
2.Accuracy (ความถูกต้อง).....	34
3.Sensitivity หรือ Recall (ความไว).....	35
บทที่ 4 การทดลองและผลการศึกษา .....	36
บทที่ 5 สรุปผลการศึกษา.....	62
5.1 สรุปและอภิปรายผลการศึกษา .....	62
5.2 ข้อเสนอแนะและการศึกษาในอนาคต.....	66
บรรณานุกรม .....	67
ประวัติผู้เขียน.....	74

## สารบัญตาราง

หน้า

ตาราง 1 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ VGG16 ร่วมกับ SGD Optimizer .....	37
ตาราง 2 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ VGG16 ร่วมกับ RMSprop Optimizer .....	38
ตาราง 3 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ VGG16 ร่วมกับ Adam Optimizer .....	38
ตาราง 4 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ VGG16 ร่วมกับ Nadam Optimizer .....	39
ตาราง 5 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ DenseNet201 ร่วมกับ SGD Optimizer .....	40
ตาราง 6 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ DenseNet201 ร่วมกับ RMSprop Optimizer .....	41
ตาราง 7 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ DenseNet201 ร่วมกับ Adam Optimizer .....	42
ตาราง 8 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ DenseNet201 ร่วมกับ Nadam Optimizer .....	43
ตาราง 9 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ ResNet152V2 ร่วมกับ SGD Optimizer .....	44
ตาราง 10 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ ResNet152V2 ร่วมกับ RMSprop Optimizer .....	45
ตาราง 11 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ ResNet152V2 ร่วมกับ Adam Optimizer .....	46
ตาราง 12 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ ResNet152V2 ร่วมกับ Nadam Optimizer .....	47
ตาราง 13 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ EfficeintNetB5 ร่วมกับ SGD Optimizer .....	48
ตาราง 14 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ EfficeintNetB5 ร่วมกับ RMSprop Optimizer .....	49
ตาราง 15 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ EfficeintNetB5 ร่วมกับ Adam Optimizer .....	50
ตาราง 16 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ EfficeintNetB5 ร่วมกับ Nadam Optimizer .....	51
ตาราง 17 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ InceptionResNetV2 ร่วมกับ SGD Optimizer .....	52
ตาราง 18 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ InceptionResNetV2 ร่วมกับ RMSprop Optimizer .....	53
ตาราง 19 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ InceptionResNetV2 ร่วมกับ Adam Optimizer .....	54
ตาราง 20 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ InceptionResNetV2 ร่วมกับ Nadam Optimizer .....	55

ตาราง 21 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ Xception ร่วมกับ SGD Optimizer ..... 56

ตาราง 22 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ Xception ร่วมกับ RMSprop Optimizer ..... 57

ตาราง 23 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ Xception ร่วมกับ Adam Optimizer ..... 58

ตาราง 24 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ Xception ร่วมกับ Nadam Optimizer ..... 59

ตาราง 25 แสดงตัวแบบที่มีประสิทธิภาพสูงสุด 5 อันดับแรก ..... 61

ตาราง 26 ตารางเปรียบเทียบประสิทธิภาพของตัวแบบกับงานวิจัยที่ผ่านมาในอดีต ..... 65



## สารบัญรูปภาพ

	หน้า
ภาพประกอบ 1 Melanoma ชนิด Superficial Spreading Melanoma[2].....	2
ภาพประกอบ 2 Melanoma ชนิด Nodular Melanoma[3].....	2
ภาพประกอบ 3 Melanoma ชนิด Lentigo Maligna[4].....	3
ภาพประกอบ 4 Melanoma ชนิด Acral Lentiginous Melanoma[5] .....	3
ภาพประกอบ 5 มะเร็งผิวหนังชนิดเมลาโนมาที่ถ่ายจากกล้องส่องผิวหนัง(Dermoscopic Image)[6].....	4
ภาพประกอบ 6 Stage of Melanoma[7].....	4
ภาพประกอบ 7 การรักษา Malignant Melanoma ด้วยการผ่าตัด[8] .....	5
ภาพประกอบ 8 Anatomy of the skin[9].....	9
ภาพประกอบ 9 มะเร็งผิวหนังชนิด Basal Cell Carcinoma [10].....	10
ภาพประกอบ 10 มะเร็งผิวหนังชนิด Squamous Cell Carcinoma[12].....	11
ภาพประกอบ 11 มะเร็งผิวหนังชนิด Merkel Cell Carcinoma[13].....	12
ภาพประกอบ 12 A: Asymmetry รอยโรคครึ่งหนึ่งไม่เหมือนหรือไม่สมมาตรกับอีกครึ่งหนึ่ง[15]... 13	
ภาพประกอบ 13 B: Irregular border ขอบเขตของรอยโรคไม่สม่ำเสมอหรือไม่สามารถแยกได้ อย่างชัดเจน[15] .....	14
ภาพประกอบ 14 C: Color variations มีความหลากหลายของสีภายในรอยโรค เช่น สีแดง น้ำตาล ดำ ขาว[15] .....	14
ภาพประกอบ 15 D: เส้นผ่านศูนย์กลางใหญ่กว่า 6 มิลลิเมตร หรือใหญ่กว่าปลายนิ้วยางลบ[15] .....	14
ภาพประกอบ 16 E: Evolving มีการเปลี่ยนแปลงของรอยโรค เช่น สีเปลี่ยนไป ขนาดใหญ่ขึ้น หรือ รูปร่างผิดปกติ[15] .....	15
ภาพประกอบ 17 มะเร็งผิวหนังชนิด Melanoma[16].....	15

ภาพประกอบ 18 ตัวอย่างกล้อง Dermoscopy[19].....	17
ภาพประกอบ 19 Invasive Melanoma (ซ้าย) Macroscopic image, (ขวา) Dermoscopic image[6] .....	18
ภาพประกอบ 20 เซลล์ประสาทของมนุษย์ [21] .....	19
ภาพประกอบ 21 Deep Learning Network[21].....	19
ภาพประกอบ 22 Kernel และ Output(Feature Map)[22] .....	20
ภาพประกอบ 23 ภาพแสดงก่อนและหลังการทำ Padding[23].....	20
ภาพประกอบ 24 ภาพแสดงการทำ Max Pooling[22] .....	21
ภาพประกอบ 25 Fully Connected Layer[24].....	21
ภาพประกอบ 26 ขั้นตอนการทำวิจัย .....	26
ภาพประกอบ 27 ตัวอย่างชุดข้อมูลที่นำมาใช้ฝึกสอนโมเดลที่ใช้ในงานวิจัยนี้ .....	27
ภาพประกอบ 28 ตัวอย่างข้อมูลที่ผ่านมาการทำให้ Data Augmentation .....	28
ภาพประกอบ 29 VGG16 Architecture[27].....	29
ภาพประกอบ 30 DenseNet Architecture[47] .....	30
ภาพประกอบ 31 จำนวน Layer ของ DenseNet Architecture[47].....	30
ภาพประกอบ 32 จำนวน Layer ของ ResNet Architecture[49].....	31
ภาพประกอบ 33 (b)-(d) Conventional Scaling Method, (e) compound Scaling in EfficientNet Architecture[29] .....	31
ภาพประกอบ 34 Performance ของ EffientNet Architecture [29].....	32
ภาพประกอบ 35 InceptionResNetV2 Architecture[51] .....	32
ภาพประกอบ 36 Xception Architecture[52] .....	33
ภาพประกอบ 37 สมการที่ใช้ในการคำนวณค่า Accuracy (ความถูกต้อง) .....	35
ภาพประกอบ 38 สมการที่ใช้ในการคำนวณค่า Recall (ความไว) .....	35
ภาพประกอบ 39 ภาพแสดงแผนภูมิแท่งแสดงประสิทธิภาพของตัวแบบสูงสุด 5 ลำดับแรก.....	61

ภาพประกอบ 40 ภาพแสดง Confusion Matrix ของตัวแบบที่ให้ประสิทธิภาพสูงที่สุด ..... 63

ภาพประกอบ 41 ภาพแสดง Classification Report ของตัวแบบที่ให้ประสิทธิภาพสูงที่สุด ..... 63

ภาพประกอบ 42 รูปภาพเปรียบเทียบ ภาพต้นฉบับรอยโรคที่เป็นมะเร็ง(ซ้าย) และภาพที่ใช้ Grad-Cam Visualization(ขวา)..... 64

ภาพประกอบ 43 ภาพแสดงสัญญาณรบกวนในภาพถ่ายเดอริโมสโคปิก..... 66



## บทที่ 1

### บทนำ

#### ที่มาและความสำคัญ

มะเร็งผิวหนังชนิดเมลาโนมา(Melanoma) เป็นมะเร็งผิวหนังชนิดที่พบได้น้อย แต่มีอัตราการเสียชีวิตสูงที่สุดในปัจจุบันพบว่ามีผู้ป่วยมะเร็งผิวหนังชนิดเมลาโนมารายใหม่ทั่วโลกประมาณ 325,000 ราย และมีผู้เสียชีวิตประมาณ 57,000 ราย มักพบในเพศชายมากกว่าเพศหญิง นอกจากนี้ยังมีการคาดการณ์กันว่าตัวเลขผู้ป่วยรายใหม่จะเพิ่มขึ้นมากถึง 500,000 รายต่อปีและมีผู้เสียชีวิตประมาณ 100,000 รายต่อปีภายในปี 2040[1]

มะเร็งผิวหนังชนิดเมลาโนมามีต้นกำเนิดจากเซลล์ที่ทำหน้าที่ในการสร้างเม็ดสี(Melanocyte) พบมากในบริเวณที่ต้องสัมผัสกับแสงแดดเป็นเวลานานๆ เช่น ใบหน้า ลำคอ ลำตัว พบได้ในเพศหญิงมากกว่าเพศชาย และพบในชาวยุโรปและออกเตรเลียที่มีผิวขาวมากกว่าชาวเอเชีย อัตราอุบัติการณ์ของมะเร็งผิวหนังชนิดเมลาโนมา(Melanoma) ในประเทศไทยพบได้น้อย โดยพบว่าอัตราอุบัติการณ์ของ Melanoma ในประเทศไทยอยู่ที่ 0.4 ในเพศชาย และ 0.1 ต่อ 100,000 ประชากรในเพศหญิง ปัจจัยเสี่ยงที่สำคัญที่สุดสำหรับมะเร็งผิวหนังชนิดเมลาโนมา(Melanoma) คือรังสี UV(Ultraviolet Radiation) ทั้งจากดวงอาทิตย์ และหลอดไฟที่ใช้สำหรับอบผิวแทน คาดการณ์กันว่า รังสี UV จะเข้าไปทำลาย DNA ภายในเซลล์ ส่งผลกระตุ้นให้เกิดกระบวนการ DNA Repair จนเกิดการกลายพันธุ์ภายในเซลล์กลายเป็นเซลล์มะเร็งผิวหนังในที่สุด

ปัจจัยเสี่ยงอื่นๆของการเกิดมะเร็งผิวหนังชนิดเมลาโนมา(Melanoma) ได้แก่

- โรคทางพันธุกรรมบางชนิด
- คนผิวขาวหรือผิวเผือก
- แสงแดด
- สารเคมีบางชนิด เช่น สารหนู (Arsenic)
- Human papilloma virus
- แผลเรื้อรังที่ผิวหนัง
- การรับ Radiotherapy
- การรับยากดภูมิคุ้มกันในผู้ป่วยที่ทำการปลูกถ่ายอวัยวะ
- การสูบบุหรี่


รอยโรคของมะเร็งผิวหนังชนิดเมลาโนมามักจะมีลักษณะเป็นตุ่มหรือเป็นก้อนสีดำเข้มดำแดง ชมพู น้ำตาล หรือสีเทาได้ โดยสีของมะเร็งผิวหนังจะกระจายตัวอย่างไม่สม่ำเสมอ ใน



ผู้ป่วยชาวไทยสามารถพบมะเร็งผิวหนังชนิดนี้ได้ทั้งฝ่ามือหรือฝ่าเท้ามากถึง 50 % และมักเกิดในบริเวณที่เป็นฝ้าอยู่เดิม แล้วเกิดการเปลี่ยนแปลงของผิวหนังบริเวณฝ้าดังกล่าว หรืออาจเกิดไฟขึ้นมาใหม่ที่มีลักษณะผิดปกติ เช่น มีสีผิดปกติ ไม่สม่ำเสมอ หรือเป็นขนาดใหญ่กว่า 6 มิลลิเมตร มะเร็งผิวหนังชนิดเมลานาโมสามารถแบ่งได้เป็น 4 ประเภท ได้แก่

### 1. Superficial Spreading Melanoma (SSM)

Melanoma ชนิดนี้เป็นชนิดที่พบได้บ่อยที่สุด พบประมาณ 70 % ของ Cutaneous Melanoma ทั้งหมด พบได้บ่อยที่หลัง และรอยางค์ส่วนล่าง



ภาพประกอบ 1 Melanoma ชนิด Superficial Spreading Melanoma[2]

### 2. Nodular Melanoma (NM)

Melanoma ชนิดนี้พบได้ 15-30% ของ Melanoma ทั้งหมด พบมากที่สุดที่บริเวณลำตัว โดยรอยโรคจะโตขึ้นอย่างรวดเร็วภายในไม่กี่สัปดาห์



ภาพประกอบ 2 Melanoma ชนิด Nodular Melanoma[3]



### 3.Lentigo Maligna (LM) and Lentigo melanoma (LMM)

Melanoma ชนิดนี้ พบได้ประมาณ 10-15% ของ Melanoma ทั้งหมด อายุเฉลี่ยของผู้ป่วย อยู่ที่ 70-80 ปี พบบ่อยที่ใบหน้า แก้ม จมูก หรือใบหู



ภาพประกอบ 3 Melanoma ชนิด Lentigo Maligna[4]


### 4.Acral Lentiginous Melanoma

Melanoma ชนิดนี้พบได้แต่ต่างกันตามเชื้อชาติ คือ พบได้ 2-8% ในชาว Caucasians, 60-72% ในชาวแอฟริกัน และ 29-46% ในชาวเอเชีย



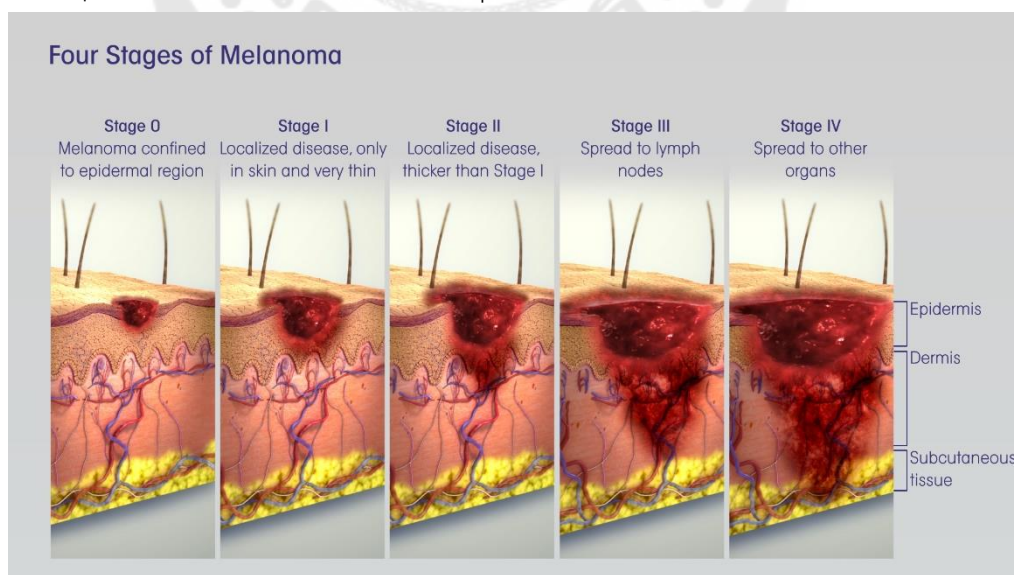
ภาพประกอบ 4 Melanoma ชนิด Acral Lentiginous Melanoma[5]

ในปัจจุบันการคัดกรองมะเร็งผิวหนังชนิดเมลาโนมา(Melanoma) ใช้การซักประวัติและตรวจดูรอยโรคที่ผิวหนังที่มีความเสี่ยง ร่วมกับการตรวจรอยโรคด้วยกล้องส่องรอยโรคซึ่งต้องอาศัยความชำนาญอย่างสูงเนื่องจากรอยโรคของมะเร็งผิวหนังชนิดเมลาโนมา มีความคล้ายคลึงกับไฝหรือ Pigment Lesion อื่นๆ ที่ไม่ใช่มะเร็ง



ภาพประกอบ 5 มะเร็งผิวหนังชนิดเมลาโนมาที่ถ่ายจากกล้องส่องผิวหนัง(Dermoscopic Image)[6]

มะเร็งผิวหนังชนิดมะเร็งชนิดเมลาโนมา(Melanoma) สามารถแบ่งได้เป็น 5 ระยะตามระยะการลุกลามของเซลล์มะเร็งไปยังชั้นต่างๆของผิวหนัง



ภาพประกอบ 6 Stage of Melanoma[7]

การรักษามะเร็งผิวหนังชนิดเมลาโนมา ขึ้นอยู่กับระยะของมะเร็งผิวหนัง โดยในระยะเริ่มแรกที่มะเร็งผิวหนังยังไม่แพร่กระจายไปยังอวัยวะอื่น สามารถรักษาได้โดยการผ่าตัดเอารอยโรคที่มีเซลล์มะเร็งผิวหนังออกทั้งหมด แต่หากมะเร็งผิวหนังเข้าสู่ระยะแพร่กระจายไปแล้ว การรักษาทำได้ค่อนข้างยากลำบาก ดังนั้นความสำคัญของการรักษามะเร็งผิวหนังชนิดนี้คือการวินิจฉัยโรคให้ได้ตั้งแต่ในระยะที่มะเร็งยังอยู่ในระยะเริ่มแรก และยังไม่แพร่กระจายไปยังอวัยวะอื่นๆ



ภาพประกอบ 7 การรักษา Malignant Melanoma ด้วยการผ่าตัด[8]

จากปัญหาข้างต้น ผู้วิจัยจึงมีแนวคิดที่จะนำโครงข่ายประสาทเทียมแบบคอนโวลูชันมาใช้สร้างเครื่องมือในคัดกรองมะเร็งผิวหนังชนิดเมลาโนมา(Melanoma) เพื่อช่วยบุคลากรทางการแพทย์ในการคัดกรอง ลดภาระงานของบุคลากรทางการแพทย์ ช่วยเพิ่มโอกาสให้ผู้ป่วยได้รับการวินิจฉัยและเข้าถึงการรักษาได้อย่างรวดเร็ว ช่วยเพิ่มโอกาสรอดชีวิตของผู้ป่วยได้มากยิ่งขึ้น

### วัตถุประสงค์ของงานวิจัย

1. เพื่อศึกษาการทำงานของโครงข่ายประสาทเทียมแบบคอนโวลูชันหรือ Convolutional Neural Network (CNN)
2. เพื่อสร้างหลักการทางคอมพิวเตอร์ในการคัดกรองมะเร็งผิวหนังชนิดเมลาโนมา

3. เพื่อค้นหาหลักการทางคอมพิวเตอร์ที่มีประสิทธิภาพในการคัดกรองมะเร็งผิวหนังชนิดเมลาโนมาจากภาพถ่ายรอยโรคจากกล้องส่องผิวหนัง (Dermoscopic Image)

### ขอบเขตงานวิจัย

1. ข้อมูลที่ใช้ในงานวิจัยฉบับนี้ได้จาก Public Dataset จาก 4 ชุดข้อมูลได้แก่ PH2 Database, 7-POINT CRITERIA EVALUATION DATABASE, ISIC Challenge 2020, และ ISIC Archive โดยเลือกใช้ข้อมูลเพียงบางส่วนจากชุดข้อมูลเพื่อแก้ปัญหาที่พบในงานวิจัยก่อนหน้านี้ เช่น Severe Imbalanced Data, ข้อมูลใน Training Set ไม่เพียงพอสำหรับการฝึกสอนโมเดล

2. โมเดลที่ใช้ในงานวิจัยฉบับนี้จะใช้ Pre-Trained Learning Model ชนิด VGG16, Xception, InceptionResNetV2, EfficientNetB5, ResNet152V2, DenseNet201 โดย ใช้ ImageNet Weight และ Simple CNN architecture โดยใช้ภาษา python รวมถึง Tensorflow และ Keras ในการจัดการโมเดล

3. เปรียบเทียบประสิทธิภาพของโมเดลแต่ละแบบ และเลือกใช้โมเดลที่มีประสิทธิภาพสูงที่สุดในการสร้างเครื่องมือคัดกรองมะเร็งผิวหนังชนิดเมลาโนมา(Melanoma)

4. ปรับจูนโมเดลเพื่อให้ได้ค่า Hyperparameter ที่ทำให้โมเดลมีประสิทธิภาพสูงที่สุด

5. ทดลองปรับ Threshold เพื่อให้ได้ค่า Recall ต่อมะเร็งผิวหนังชนิดเมลาโนมา (Melanoma) ให้ได้ครบทั้ง 100% และเปรียบเทียบประสิทธิภาพโดยรวมของโมเดลอีกครั้ง

### ขั้นตอนการดำเนินงานวิจัย

1. ศึกษากายวิภาคของผิวหนัง (Anatomy of the skin)

2. ศึกษามะเร็งผิวหนังชนิดต่างๆ (The skin cancer)

3. ศึกษางานวิจัยที่เกี่ยวข้องกับการใช้ Machine Learning หรือ Deep Learning ในการทำนายมะเร็งผิวหนังชนิด Melanoma พร้อมศึกษาแหล่งข้อมูลที่งานวิจัยนั้นๆเลือกใช้ และคัดเลือกเฉพาะแหล่งข้อมูลที่เป็นภาพถ่ายรอยโรคที่ผิวหนังจากกล้องส่องผิวหนัง (Dermoscopic Image)

4. ศึกษางานวิจัยที่เกี่ยวข้องโครงข่ายประสาทเทียม (Convolutional Neural Network) ที่มีโครงสร้างแบบต่างๆ เช่น ResNet, DenseNet, EfficientNet, InceptionResNet, VGG, Xception พร้อมศึกษาโครงสร้างและแนวคิดที่ถูกใช้ในการพัฒนา



5. นำเข้าข้อมูลจากชุดข้อมูลที่เลือกไว้โดยเลือกให้ทั้ง 2 Class เท่ากันตั้งแต่ต้น และมีชุดข้อมูลมากเพียงพอ เพื่อแก้ปัญหา Imbalanced Data และ Insufficient Data

6. สร้างแบบจำลองในการทำนายมะเร็งผิวหนังชนิดเมลาโนมา (Melanoma) จากแบบจำลองโครงข่ายประสาทเทียม CNN แบบต่างๆที่ได้ศึกษาไว้ ประกอบด้วย ResNet152V2, DenseNet201, EfficientNetB5, IncptionResNetV2, VGG16 และ Xception

7. เปรียบเทียบแบบจำลองชนิดต่างๆ ว่ามีประสิทธิภาพเป็นอย่างไร มีข้อดีข้อเสียอย่างไร พร้อมสรุปผลการทดลองเพื่อหาแบบจำลองที่ดีที่สุด

8. ปรับค่าพารามิเตอร์ต่างๆของแบบจำลองที่ให้ผลลัพธ์ที่ดีที่สุด เพื่อหาค่าพารามิเตอร์ที่ทำให้แบบจำลองมีความถูกต้องและความไวสูงที่สุด

9. วิเคราะห์และอภิปรายผลการทดลอง ถึงข้อดี ข้อเสีย ข้อจำกัด และแบบจำลองที่ได้เหมาะสมสำหรับการใช้ในสถานการณ์ใดบ้าง และสถานการณ์ใดที่ไม่ควรใช้

#### **ประโยชน์ที่คาดว่าจะได้รับจากงานวิจัย**

1. สร้างหลักการทางคอมพิวเตอร์ในการคัดกรองมะเร็งผิวหนังชนิดเมลาโนมาเบื้องต้นที่มีประสิทธิภาพ ช่วยแพทย์ในการรักษาผู้ป่วยได้อย่างรวดเร็ว
2. ช่วยลดเวลาการทำงานและภาระงานของแพทย์ในการทำงาน
3. ช่วยให้ผู้ป่วยสามารถเข้าถึงการรักษาได้รวดเร็วมากยิ่งขึ้น ลดเวลาการรอคอย

## บทที่ 2

### ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

#### ทฤษฎีที่เกี่ยวข้อง

##### 1. Overview of the Skin

ผิวหนังเป็นองค์ประกอบที่มีพื้นที่ผิวมากที่สุดในร่างกาย ปกคลุมด้านนอกทั้งหมดของร่างกาย มีหน้าที่หลักในการเป็นพื้นผิวชั้นแรกที่ทำหน้าที่ปกป้องอวัยวะภายใน ควบคุมอุณหภูมิ ปกป้องร่างกายจากรังสี การบาดเจ็บ เชื้อโรค สารพิษต่างๆ รวมถึงการรับรู้ความรู้สึกเจ็บปวด รับรู้อุณหภูมิ ควบคุมการสูญเสียน้ำออกจากร่างกาย นอกจากนี้ยังมีหน้าที่พิเศษอื่นๆ ขึ้นอยู่กับบริเวณที่ผิวหนังปกคลุมอยู่ ผิวหนังของมนุษย์สามารถแบ่งออกได้เป็น 3 ชั้น ได้แก่

##### 1.1 Epidermis


Epidermis หรือชั้นหนังกำพร้าเป็นชั้นที่อยู่นอกสุดของผิวหนัง มีหน้าที่ในการปกป้องผิวหนังชั้นในจากสิ่งแวดล้อมภายนอกประกอบด้วยเซลล์ต่างๆ 4 ชนิด ได้แก่ Keratinocyte เป็นเซลล์ที่พบได้มากที่สุด在这一ชั้นนี้ ทำหน้าที่ในการสร้าง Keratin(เคราติน), Melanocyte ทำหน้าที่ในการสร้าง Melanin(เมลานิน) ทำหน้าที่เป็นเม็ดสีของผิวหนัง ทำให้ผิวหนังมีสีแตกต่างกันไปในแต่ละคน นอกจากนี้ยังมีหน้าที่ในการป้องกันรังสียูวี(Ultraviolet radiation), Langerhans' cell ทำหน้าที่เกี่ยวกับระบบภูมิคุ้มกันของร่างกาย, Merkel Cell ทำหน้าที่ในการรับรู้สัมผัส(Light Touch)

##### 1.2 Dermis

Dermis หรือชั้นหนังแท้ เป็นชั้นที่อยู่ถัดลงมาจากรชั้น Epidermis ในชั้นนี้จะประกอบไปด้วยเนื้อเยื่อเกี่ยวพัน (Dense Connective tissue) และเส้นใยคอลลาเจน(Collagen Fibers) ผิวหนังในชั้นนี้เป็นที่อยู่ของ ต่อมเหงื่อ เส้นเลือด เส้นประสาท รูขุมขน กล้ามเนื้อ และเซลล์ประสาทซึ่งมีหน้าที่ในการรับสัมผัสอุณหภูมิ และความเจ็บปวด

##### 1.3 Subcutaneous Layers

Subcutaneous Layers หรือ Hypodermis เป็นชั้นล่างสุดของผิวหนังประกอบไปด้วยเนื้อเยื่อเกี่ยวพันและเซลล์ไขมัน ทำหน้าที่ในการช่วยควบคุมอุณหภูมิของร่างกาย



ภาพประกอบ 8 Anatomy of the skin[9]

## 2.Skin Cancer

Skin cancer หรือมะเร็งผิวหนังเป็นมะเร็งชนิดที่พบได้บ่อยที่สุดในสหรัฐอเมริกา สามารถแบ่งออกได้เป็น 2 ชนิด ได้แก่ Melanoma Skin cancer และ Nonmelanoma Skin Cancer อัตราอุบัติการณ์ของมะเร็งผิวหนังทั้ง 2 ชนิดเพิ่มขึ้นอย่างต่อเนื่องตลอดระยะเวลาหลายปีที่ผ่านมา บริเวณที่เป็นต้นกำเนิดของมะเร็งผิวหนังมักจะเกิดขึ้นในบริเวณที่ต้องสัมผัสกับแสงอาทิตย์เป็นประจำ เช่น ศีรษะ ลำคอ

ปัจจัยเสี่ยงที่สำคัญของการเกิดมะเร็งผิวหนังคือรังสียูวี(Ultraviolet Radiation) โดยสัมพันธ์กับการเกิดมะเร็งผิวหนังทั้ง Melanoma และ Nonmelanoma ซึ่ง UV-A และ UV-B เป็นสารก่อมะเร็งทั้งคู่โดย UV-A มักจะมีผลมากกว่า UV-B กระบวนการเกิดเซลล์มะเร็งมักจะเกิดจากรังสี UV เข้าไปทำลายเซลล์ผิวหนัง รวมถึงทำลาย DNA ภายในเซลล์ กระตุ้นให้เกิดกระบวนการซ่อมแซม DNA(DNA repair mechanism) และเกิดการกลายพันธุ์ภายใน DNA(DNA Mutations) จนกลายเป็นเซลล์มะเร็งในที่สุด

### 2.1 Nonmelanoma Skin Cancer (NMSC)

มะเร็งผิวหนังชนิด Nonmelanoma ประกอบด้วยมะเร็งผิวหนังชนิดย่อยๆ ได้แก่ Basal Cell Carcinoma(BCC), Squamous Cell Carcinoma(SCC), Merkel Cell Carcinoma(MCC) โดยเซลล์ต้นกำเนิดของมะเร็งผิวหนังชนิด Melanoma เป็นเซลล์ผิวหนังที่อยู่

ในชั้น Dermis(ชั้นหนังแท้) ซึ่งปัจจัยเสี่ยงที่สำคัญที่ทำให้เซลล์เหล่านี้กลายเป็นเซลล์มะเร็งคือ รังสียูวี(Ultraviolet Radiation) ปัจจัยเสี่ยงที่สำคัญอื่นๆเช่น ปัจจัยเสี่ยงของการเกิด BCC และ SCC ได้แก่ โรคสะเก็ดเงิน(Psoriasis), การติดเชื้อ HPV อย่างเรื้อรัง(Chronic Human Papilloma virus), การใช้ยากดภูมิคุ้มกันในผู้ป่วยที่ทำการปลูกถ่ายอวัยวะ

### 2.1.1 Basal Cell Carcinoma (BCC)

มะเร็งผิวหนังชนิด Basal Cell Carcinoma (BCC) คือมะเร็งผิวหนังชนิดที่พบได้บ่อยที่สุด พบได้ประมาณ 80 % ของผู้ป่วยมะเร็งผิวหนังทั้งหมด มักจะเกิดที่บริเวณใบศีรษะหรือลำคอ มะเร็งผิวหนังชนิดนี้มักจะไม่ค่อยแพร่กระจายไปยังอวัยวะอื่นแต่พบว่ามักจะมีการรุกรานหรือทำลายเนื้อเยื่อข้างเคียงจึงส่งผลให้มีอัตราทุพพลภาพสูง ปัจจัยเสี่ยงที่สำคัญของมะเร็งชนิดนี้ได้แก่ ผู้ชายอายุมากผิวขาว การสัมผัสรังสียูวีเป็นเวลานาน การใช้ยากดภูมิคุ้มกันในผู้ป่วยที่มีการปลูกถ่ายอวัยวะ สารหนู การติดเชื้อเอชไอวี

อัตราอุบัติการณ์ของมะเร็งผิวหนังชนิด BCC ทั่วโลกพบว่าอยู่ที่ประมาณ 88-164 ต่อ 100,000 ประชากรต่อปี อัตราการเสียชีวิตจากโรคมะเร็งผิวหนังชนิดนี้ค่อนข้างต่ำ การเสียชีวิตส่วนใหญ่มักเกิดจากผลข้างเคียงอื่น โรคประจำตัว หรืออายุ ลักษณะรอยโรคของมะเร็งชนิดนี้มีได้หลายรูปแบบ รอยโรคอาจเป็นตุ่ม อาจจะอยู่ตื้นหรืออยู่ลึกก็ได้ ในบางครั้งอาจพบ melanin อยู่ในรอยโรคได้เช่นเดียวกัน ลักษณะที่พบได้มากที่สุดมักจะมีลักษณะเป็น ตุ่มเล็กๆ (Nodular) พบได้ประมาณ 50-79% ของมะเร็งผิวหนังชนิด BCC ทั้งหมด

การรักษาหลักของมะเร็งผิวหนังชนิด BCC คือการผ่าตัดนำรอยโรคออกทั้งหมด โดยจะต้องตัดให้ให้ได้ชั้นเนื้อปกตึรอบๆรอยโรค(Margin of safety)



ภาพประกอบ 9 มะเร็งผิวหนังชนิด Basal Cell Carcinoma [10]



### 2.1.2 Squamous Cell Carcinoma (SCC)

มะเร็งผิวหนังชนิด Squamous Cell Carcinoma (SCC) เป็นมะเร็งผิวหนังที่พบได้มากที่สุดอันดับสอง พบมากในประชากรที่สัมผัสกับสิ่งแวดล้อมบางประเภทเช่น รังสียูวี การสูบบุหรี่ การติดเชื้อเรื้อรัง การใช้ยาเคมีภูมิคุ้มกัน อัตราอุบัติการณ์ของมะเร็งชนิดนี้ไม่แน่ชัด แต่คาดการณ์กันว่าในทศวรรษหน้าจำนวนผู้ป่วยมะเร็งผิวหนังชนิด SCC จะเพิ่มขึ้นเป็นสองเท่า

ลักษณะของมะเร็งผิวหนังชนิดนี้สามารถพบได้หลายรูปแบบ ตั้งแต่เป็นก้อนเดี่ยวที่โตช้า ไปจนถึงก้อนมะเร็งที่โตอย่างรวดเร็วและรุกร้าไปยังบริเวณข้างเคียง ลักษณะรอยโรคมีหลายรูปแบบขึ้นอยู่กับ ตำแหน่ง ขนาด รูปร่าง ความหนา และสีของรอยโรค รอยโรคส่วนใหญ่ มักจะมีลักษณะเป็นปื้น หรือเป็นก้อนนูนขึ้นมาและมักจะมีสีต่างๆกันไป[11]

การวินิจฉัยมะเร็งผิวหนังชนิด SCC ใช้การตรวจชิ้นเนื้อทางพยาธิวิทยาเพื่อยืนยันว่า ชิ้นเนื้อจากรอยโรคดังกล่าวคือมะเร็งผิวหนังชนิด SCC

การรักษามะเร็งผิวหนังชนิด SCC ขึ้นอยู่กับหลายปัจจัย เช่น ชนิดของมะเร็งผิวหนัง ขนาดของก้อนเนื้อ ตำแหน่งของรอยโรค ความลึกของรอยโรค อายุและสุขภาพโดยรวมของผู้ป่วย ความสวยงามหรือคุณภาพชีวิตหลังการรักษาของผู้ป่วย ซึ่งการรักษาหลักของมะเร็งชนิดนี้คือ การผ่าตัดโดยตัดรอยโรคออกทั้งหมดและตัดให้ติดเนื้อดีโดยรอบไปด้วยเพื่อเป็นการป้องกันการกลับเป็นซ้ำ หลังจากนั้นต้องทำการส่งชิ้นเนื้อตรวจเพื่อยืนยันว่าไม่มีเซลล์มะเร็งอยู่ในบริเวณเนื้อดีที่ตัดมาด้วย ในกรณีที่รอยโรคมีการแพร่กระจายการรักษาด้วยการผ่าตัดเพียงอย่างเดียวอาจจะไม่เพียงพอ อาจต้องใช้วิธีการอื่นๆ เช่น การฉายรังสี การให้เคมีบำบัดร่วมด้วย



ภาพประกอบ 10 มะเร็งผิวหนังชนิด Squamous Cell Carcinoma[12]

### 2.1.3 Merkel Cell Carcinoma (MCC)

มะเร็งผิวหนังชนิด Merkel Cell Carcinoma หรือ Primary Cutaneous Neuroendocrine Carcinoma คือมะเร็งผิวหนังชนิดที่พบได้ค่อนข้างยาก อัตราอุบัติการณ์ของมะเร็งชนิดนี้พบได้ประมาณ 0.7 ต่อประชากรแสนรายต่อปี อย่างไรก็ตามในช่วง 2-3 ทศวรรษที่ผ่านมาจำนวนผู้ป่วยของมะเร็งชนิดนี้เพิ่มขึ้นมากถึง 5-10% ต่อปี โดยพบมากในผู้ป่วยที่อายุมากกว่า 50 ปี ปัจจัยเสี่ยงที่สำคัญคือการสัมผัสกับรังสียูวี หรือเป็นผู้ป่วยมะเร็งเม็ดเลือดขาวชนิดบีเซลล์

มะเร็งผิวหนังชนิด MCC มักจะมีรอยโรคที่มีลักษณะเป็นก้อนแข็งนูนโตเร็ว ไม่เจ็บ สีแดงหรือสีออกม่วง ในบริเวณที่ต้องสัมผัสกับแสงแดดบ่อยๆโดยเฉพาะศีรษะและลำคอ พบได้ในกลุ่มประชากรสูงอายุมากกว่ากลุ่มประชากรอายุน้อย มะเร็งผิวหนังชนิด MCC มีอัตราการเสียชีวิตที่ค่อนข้างสูง คาดการณ์ว่าประมาณมีผู้เสียชีวิตจากมะเร็งชนิดนี้ประมาณ 1 ใน 3 ของจำนวนผู้ป่วยทั้งหมด




ภาพประกอบ 11 มะเร็งผิวหนังชนิด Merkel Cell Carcinoma[13]

## 2.2 Malignant Melanoma(MM)


Melanoma คือมะเร็งผิวหนังชนิดที่มีความรุนแรงมากที่สุด เกิดจากเซลล์ซึ่งมีหน้าที่ในการสร้างเม็ดสี (Melanocyte) ซึ่งทำให้ผิวหนังมีสีต่างๆ สาเหตุที่ทำให้เกิดเมลาโนมานั้นไม่แน่ชัด โดยปัจจัยเสี่ยงที่สำคัญคือ การสัมผัสรังสียูวี(Ultraviolet radiation) มะเร็งผิวหนังชนิดเมลาโนมามักจะเกิดในบริเวณที่สัมผัสกับแสงแดดบ่อยๆ เช่น แขน หลัง แขน ขา หรือใบหน้า อย่างไรก็ตามยังสามารถเกิดในบริเวณที่ไม่ค่อยสัมผัสกับแสงแดดได้ เช่น ฝ่าเท้า หรือฐานรองเล็บ พบว่าในกลุ่มผู้ป่วยที่เป็นมะเร็งผิวหนังเมลาโนมาในระยะที่ยังไม่มีการแพร่กระจาย(Stage 0) มี 5-year relative survival rate ประมาณ 97% ในขณะที่ กลุ่มที่มีเข้าสู่ระยะแพร่กระจาย(Stage IV) มี 5-year relative survival rate เพียง 10% เท่านั้น[14]

อัตราการอุบัติการณ์ของการเกิดมะเร็งผิวหนังชนิดเมลาโนมาทั่วโลกเพิ่มขึ้นอย่างรวดเร็ว โดยพบมะเร็งผิวหนังชนิดนี้ได้ในประชากรผิวขาว มากกว่าประชากรผิวสีหรือชาวเอเชีย องค์การอนามัยโลกคาดการณ์ว่าในปี 2020 มีผู้ป่วยมะเร็งผิวหนังชนิดเมลาโนมารายใหม่ทั่วโลกประมาณ 325,000 ราย และมีผู้เสียชีวิตประมาณ 57,000 ราย และมักพบในเพศชายมากกว่าเพศหญิงนอกจากนี้ยังมีการคาดการณ์กันว่าตัวเลขผู้ป่วยรายใหม่จะเพิ่มขึ้นมากถึง 500,000 รายต่อปี และมีผู้เสียชีวิตประมาณ 100,000 รายต่อปีภายในปี 2040[1]ส่งผลให้มะเร็งผิวหนังชนิดเมลาโนมากลายเป็นปัญหาทางสาธารณสุขที่สำคัญที่ทั่วโลกจะต้องเผชิญในอนาคตอันใกล้


การวินิจฉัยมะเร็งผิวหนังชนิดเมลาโนมา ผู้ป่วยมักจะมีประวัติการเปลี่ยนแปลงของลักษณะรอยโรคที่ผิวหนังอย่างชัดเจน เช่น การเปลี่ยนแปลงที่ไม่ปกติของไฝที่มีอยู่เดิม หรือการเกิดไฝใหม่ที่ไม่ปกติ โดยหลักการที่นิยมใช้ในการตรวจดูลักษณะรอยโรคคือ ABCDE Rule [15]ได้แก่



ภาพประกอบ 12 A: Asymmetry รอยโรคครึ่งหนึ่งไม่เหมือนหรือไม่สมมาตรกับอีกครึ่งหนึ่ง[15]




ภาพประกอบ 13 B: Irregular border ขอบเขตของรอยโรคไม่สม่ำเสมอหรือไม่สามารถแยกได้  
อย่างชัดเจน[15]




ภาพประกอบ 14 C: Color variations มีความหลากหลายของสีภายในรอยโรค เช่น สีแดง น้ำตาล  
ดำ ขาว[15]



ภาพประกอบ 15 D: เส้นผ่านศูนย์กลางใหญ่กว่า 6 มิลลิเมตร หรือใหญ่กว่าปลายหัวยางลบ[15]



ภาพประกอบ 16 E: Evolving มีการเปลี่ยนแปลงของรอยโรค เช่น สีเปลี่ยนไป ขนาดใหญ่ขึ้น หรือรูปร่างผิดปกติ[15]



ภาพประกอบ 17 มะเร็งผิวหนังชนิด Melanoma[16]

เมื่อพบรอยโรคที่น่าสงสัยแพทย์ผู้ทำการรักษาจะทำการยืนยันการตรวจวินิจฉัย โดยการตรวจชิ้นเนื้อทางพยาธิวิทยาจากรอยโรค และเมื่อทำการยืนยันเรียบร้อยแล้วก่อนทำการรักษาจะต้องทำการตรวจหาว่ามะเร็งผิวหนังอยู่ในระยะใด (Staging) เพื่อให้สามารถกำหนดแนวทางการรักษาได้ โดยสามารถแบ่งระยะของมะเร็งผิวหนังชนิดเมลาโนมาได้เป็น 5 ระยะ[17] ตาม TNM system ได้แก่



## Early Melanoma

**Stage 0:** มะเร็งผิวหนังยังอยู่เฉพาะชั้นนอกสุดของผิวหนัง อาจเรียกมะเร็งในระยนี้ว่า

Melanoma in situ

**Stage I:** มะเร็งผิวหนังมีความลึกน้อยกว่า 1 มิลลิเมตร อาจมีหรือไม่มีแผลก็ได้ อาจจะมีการรูก้ำเข้าไปในผิวหนังชั้นที่ลึกขึ้น หากมีการรูก้ำเกิดขึ้นจะเรียกว่า Stage IA

## Intermediate or High-Risk Melanoma

**Stage II:** มะเร็งผิวหนังมีรอยโรคที่ลึกมากกว่า 1 มิลลิเมตร อาจมีหรือไม่มีรอยแผลก็ได้ ระยะเวลาที่แพทย์ผู้รักษาอาจจะต้องพิจารณาทำ sentinel lymph node biopsy (SLNB) เพื่อดูว่า เซลล์มะเร็งมีการแพร่กระจายไปยังต่อมน้ำเหลืองข้างเคียงหรือไม่

## Advance Melanoma

**Stage III:** มะเร็งผิวหนังจะมีการแพร่กระจายไปยังต่อมน้ำเหลืองข้างเคียง หรือมีการแพร่กระจายไปไกลมากกว่า 2 เซนติเมตร จากรอยโรคปฐมภูมิ

**Stage IV:** มะเร็งมีการแพร่กระจายไปยังบริเวณอื่นๆของร่างกาย โดยส่วนมากมักจะกระจายไปยัง ปอด ตับ สมอง กระดูก และระบบทางเดินอาหาร

การรักษา มะเร็งผิวหนังชนิดเมลาโนมา ใช้การผ่าตัดเป็นหลัก โดยเฉพาะหากเจอรอยโรคที่เป็นมะเร็งในระยะที่ยังไม่แพร่กระจายไปยังส่วนอื่นๆ ของร่างกาย แต่หากมะเร็งเข้าสู่ระยะแพร่กระจายแล้วการรักษาจะเน้นที่การรักษาตามอาการและประคับประคองให้ชีวิตยืนยาว และสุขสบายสุดเท่าที่จะทำได้ ดังนั้น ข้อสำคัญที่สุดในการรักษามะเร็งผิวหนังชนิดเมลาโนมาคือการวินิจฉัยให้ได้ก่อนที่มะเร็งจะเข้าสู่ระยะแพร่กระจาย

จะเห็นได้ว่าการคัดกรองมะเร็งผิวหนังชนิดเมลาโนมานั้นไม่ใช่เพียงตาเปล่าในการคัดกรองเท่านั้นทำให้เกิดปัญหาที่สำคัญคือจำเป็นต้องใช้ประสบการณ์และความชำนาญอย่างสูงในการแยกแยะรอยโรคที่เป็นมะเร็งออกจากรอยโรคที่ไม่ใช่มะเร็ง โดยเฉพาะแพทย์เวชปฏิบัติทั่วไป (General Practitioner) ซึ่งมีบทบาทสำคัญในระบบสาธารณสุขคือ เป็นบุคลากรทางการแพทย์คนแรกที่จะต้องคัดกรองผู้ป่วย ในปี 2001 Lieve B. และคณะทำการวิจัยเปรียบเทียบความสามารถในการแยกแยะรอยโรคที่มีการเปลี่ยนสีที่ผิวหนังระหว่างแพทย์เวชปฏิบัติทั่วไป (General Practitioner) และแพทย์เฉพาะทางด้านโรคผิวหนัง (Dermatologist) ในประเทศเบลเยียมพบว่า ความสามารถในการวินิจฉัยแยกกรอยโรคที่เป็นมะเร็งออกจากรอยโรคที่ไม่ใช่มะเร็งของแพทย์เฉพาะทางด้านโรคผิวหนังนั้นเหนือกว่าแพทย์เวชปฏิบัติทั้งนี้สาเหตุที่สำคัญคือแพทย์เฉพาะทางด้านโรคผิวหนังนั้นมีประสบการณ์ในการเจอผู้ป่วยที่มีรอยโรคมากกว่า [18] นอกจากนี้เมื่อมอง

ในบริบทของประเทศไทยจะพบปัญหาที่สำคัญอีกประการคือภาวะขาดแคลนบุคลากรทางการแพทย์ ส่งผลให้แพทย์มีเวลาตรวจผู้ป่วยต่อคนเพียงไม่กี่นาทีเท่านั้น ทำให้ไม่สามารถให้ความสำคัญกับทุกๆ รอยโรคที่เกิดขึ้นกับผู้ป่วยได้ ส่งผลให้อาจเกิดความล่าช้าในการวินิจฉัยผู้ป่วย ทำให้รอยโรคเข้าสู่ระยะแพร่กระจายจนยากที่จะทำการรักษา

จะเห็นได้ว่ามะเร็งผิวหนังชนิดเมลาโนมา นั้นเป็นปัญหาทางสาธารณสุขที่สำคัญ คือ เป็นมะเร็งผิวหนังที่มีอัตราการเสียชีวิตสูง และวินิจฉัยได้ยากทั้งจากตัวโรคเองและการขาดความชำนาญของแพทย์ นอกจากนี้หากสามารถวินิจฉัยได้รวดเร็วตั้งแต่ในช่วงที่ยังไม่เข้าสู่ระยะแพร่กระจายสามารถรักษาให้หายขาดได้ด้วยการผ่าตัดรอยโรคออกทั้งหมด ทำให้ในช่วงไม่กี่ปีที่ผ่านมามีความพยายามในการสร้างเครื่องมือในการช่วยวินิจฉัยมะเร็งผิวหนังชนิดนี้โดยใช้การเรียนรู้ของเครื่อง และโครงข่ายประสาทเทียมเข้ามาช่วย

### 3.Dermoscope

Dermoscope หรือ Dermatoscope เป็นเครื่องมือสำหรับส่องรอยโรคที่ผิวหนัง โดยที่ไม่ทำร้ายชั้นผิวหนัง (Non-Invasive technique) สามารถเห็นภาพขยายของรอยโรคบนผิวหนังได้ลึกถึงชั้น Dermis ทำให้เห็นลักษณะของเม็ดสี เส้นเลือด แนวเส้นเลือดต่างๆที่โดยปกติแล้วไม่สามารถมองเห็นได้ด้วยตาเปล่า ส่งผลให้สามารถช่วยให้การวินิจฉัยมีความแม่นยำมากขึ้น และสามารถวินิจฉัยโรคได้อย่างรวดเร็วตั้งแต่ในช่วงที่รอยโรคยังไม่เข้าสู่ระยะแพร่กระจาย



ภาพประกอบ 18 ตัวอย่างกล้อง Dermoscopy[19]

ในปี 2018 Dinner J. และคณะได้จัดทำ Systematic review ตีพิมพ์ใน Cochrane Library เรื่อง Dermoscopy, With and Without visual inspection, for diagnosing melanoma in adults โดยทำการรื้องานวิจัยทั้งสิ้น 104 งานวิจัย ซึ่งมีภาพรอยโรคทั้งหมด 42,788 ภาพ โดยเป็นภาพที่เป็นรอยโรคของมะเร็งผิวหนังชนิด Melanoma จำนวน 5,700 ภาพ จาก 354 datasets

โดยพบว่าการใช้ Dermoscopy ให้ Accuracy ที่ดีกว่าการใช้ Visual Inspection เพียงอย่างเดียว โดยให้ค่า Accuracy 95% และ 75 % ตามลำดับ ที่ 95% Confident Interval[20]



ภาพประกอบ 19 Invasive Melanoma (ซ้าย) Macroscopic image, (ขวา) Dermoscopic image[6]

#### 4. การเรียนรู้เชิงลึก (Deep Learning)

การเรียนรู้เชิงลึก (Deep Learning) เป็นแนวคิดที่ให้คอมพิวเตอร์เรียนรู้ข้อมูลโดยเลียนแบบเซลล์สมองของมนุษย์ (Neuron) เชื่อมต่อกันในลักษณะของโครงข่ายประสาทเป็นชั้นๆ (Layers) โดยจะประกอบด้วยโครงสร้างหลัก 3 ชั้น ได้แก่

##### 4.1 Input Layer

เป็นโครงข่ายประสาทชั้นแรกสุดทำหน้าที่ในการรับข้อมูลเข้ามาในโครงข่ายประสาท และส่งต่อข้อมูลไปยัง Hidden Layers


##### 4.2 Hidden Layer

เป็นโครงข่ายประสาทที่อยู่ตรงกลาง ทำหน้าที่ในการคำนวณทางคณิตศาสตร์ และหาค่าน้ำหนักที่เหมาะสม (Weight) หรืออาจจะเรียกได้ว่าโครงข่ายประสาทชั้นนี้ทำหน้าที่ในการสกัดคุณลักษณะ (Feature Extraction) ก็ได้ อาจประกอบด้วยชั้นย่อยเพียงชั้นเดียว หรือชั้นย่อยหลายชั้นที่ทำหน้าที่ร่วมกัน

##### 4.3 Output Layer


เป็นโครงข่ายประสาทชั้นสุดท้าย ทำหน้าที่ในการแสดงผลลัพธ์ที่ได้จากการคำนวณทั้งหมดออกมา





ภาพประกอบ 20 เซลล์ประสาทของมนุษย์ [21]

ในปัจจุบันมีการประยุกต์ใช้การเรียนรู้เชิงลึก (Deep Learning) โดยนำไปพัฒนาต่อยอดในหลากหลายสาขาวิชา เช่น Convolutional Neural Network(CNN) ซึ่งได้รับความนิยมเป็นอย่างมากในงานประเภท Computer Vision หรือ Image Classification



ภาพประกอบ 21 Deep Learning Network[21]

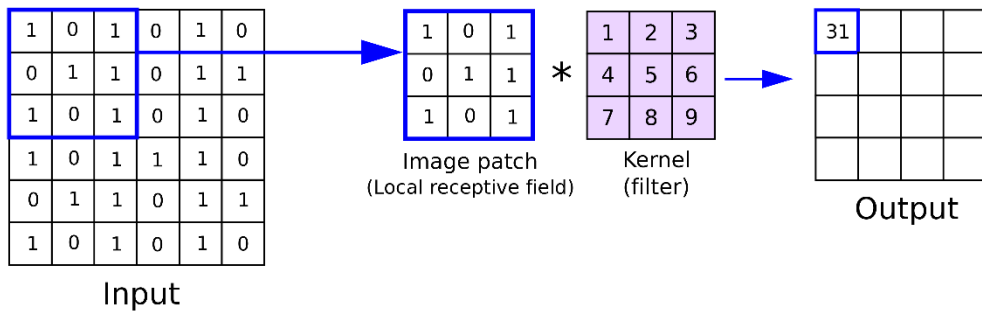
### 5. โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network)

Convolutional Neural Network หรือ CNN เป็นโครงข่ายประสาทเทียมที่พยายามเลียนแบบการมองเห็นของมนุษย์ซึ่งได้รับความนิยมเป็นอย่างมากในปัจจุบัน มีการนำ CNN มาใช้อย่างกว้างขวางเช่น การจำแนกรูปภาพ การจดจำใบหน้า การจดจำวัตถุ โดยการทำงานของ CNN จะมองเป็นพื้นที่ย่อยๆ และพยายามหาลักษณะเด่นๆของพื้นที่นั้นๆ แล้วจึงนำมารวมกันในภายหลัง เพื่อให้ได้เป็นภาพที่สามารถแปลความหมายได้ โครงสร้างของ CNN จะประกอบด้วยโครงสร้าง


หลักจำนวน 3 ชั้น ได้แก่ Convolutional Layer, Pooling Layer และ Fully Connected Layer ทำงานร่วมกันในลักษณะของโครงข่ายประสาท

### 5.1 Convolutional Layer

Convolutional Layer เป็นหัวใจของโครงข่ายประสาท CNN ทำหน้าที่ในการสกัดคุณลักษณะ (Feature Extraction) โดยจะใช้ Kernel หรือ Filter เป็นตัวตรวจจับคุณลักษณะ โดย Kernel จะเคลื่อนที่ไปยังทุก Pixel ของรูปภาพที่ Input เข้าไป โดยจะกำหนดค่า Stride หรือจำนวนก้าวที่ต้องการให้ Kernel เคลื่อนที่ไป จากนั้นจะทำการคูณแบบ Element-wise แล้วจึงเก็บค่าลงใน Matrix หรือ Feature Map เพื่อส่งไปยัง Layer ต่อไป นอกจากนี้ในบางครั้งมีแนวโน้มที่ข้อมูลบริเวณขอบของขอบภาพจะไม่ถูกนำไปคำนวณอย่างเหมาะสม จึงมีการทำ Padding โดยขยายขอบข้อมูลออกไปในทุกทิศทางเท่ากัน เพื่อให้ Kernel สามารถตรวจจับหรือสกัดคุณลักษณะออกมาได้จากทุกข้อมูลในรูปภาพ




ภาพประกอบ 22 Kernel และ Output(Feature Map)[22]



ภาพประกอบ 23 ภาพแสดงก่อนและหลังการทำ Padding[23]

## 5.2 Pooling Layer


Pooling Layer เป็นชั้นที่มีหน้าที่ในการลดมิติของข้อมูลลงเพื่อให้เหลือข้อมูลเฉพาะที่เป็นคุณลักษณะสำคัญเท่านั้น โดยทั่วไปนิยมใช้กัน 2 แบบได้แก่ Max Pooling คือการใช้ตัวกรองเลือกกรอบข้อมูลที่น่าสนใจ (Pool Size) หลังจากนั้นเลือกค่าที่มากที่สุดในกรอบข้อมูลนั้นมาเป็นผลลัพธ์ใหม่ หลังจากนั้นเลื่อนตัวกรองไปตามขนาด Stride ที่กำหนดไว้, Average Pooling มีลักษณะการดำเนินการที่คล้ายกับ Max Pooling แต่แทนที่จะใช้ค่าที่มากที่สุดที่อยู่ในกรอบความสนใจ กลับเลือกใช้ค่าเฉลี่ยของข้อมูลทั้งหมดที่อยู่ในกรอบที่สนใจแทน อย่างไรก็ตามในปัจจุบันการดำเนินการ Max Pooling ได้รับความนิยมมากกว่าการดำเนินการแบบ Average Pooling เป็นอย่างมาก



ภาพประกอบ 24 ภาพแสดงการทำ Max Pooling[22]

## 5.3 Fully Connected Layer

Fully Connected Layer เป็นชั้นสุดท้ายของโครงข่ายประสาทแบบ CNN ในขั้นนี้จะทำหน้าที่รับข้อมูลที่ได้จาก Pooling Layers เพื่อทำการคำนวณและทำนายประเภทของข้อมูล โดยในชั้นสุดท้ายของ Fully Connected Layer มักจะใช้ Activation Function เป็น Sigmoid และมีเพียง Node เดียว ในกรณีที่เป็นงานแบบ Binary Classification หรือ SoftMax Activation Function ในกรณีที่เป็นงานแบบ Multi-Classes Classification รวมถึงจะมีจำนวน Node เท่ากับจำนวน Class ที่ต้องทำนายอีกด้วย



ภาพประกอบ 25 Fully Connected Layer[24]

## งานวิจัยที่เกี่ยวข้อง

ในช่วงไม่กี่ปีที่ผ่านมาความก้าวหน้าทางเทคโนโลยีทั้งด้าน Software และ Hardware ส่งผลให้พลังการคำนวณของคอมพิวเตอร์(Computational Power) เพิ่มขึ้นอย่างก้าวกระโดด ทำให้มีงานวิจัยใหม่ๆเกี่ยวกับการใช้การเรียนรู้ของเครื่อง และโครงข่ายประสาทเทียมมาช่วยแพทย์และบุคคลากรทางสาธารณสุขในการคัดกรองและวินิจฉัยรอยโรคที่ผิวหนัง เพื่อวินิจฉัยมะเร็งผิวหนังที่เป็นอันตรายให้ได้ตั้งแต่ในระยะเริ่มแรก เพื่อเพิ่มโอกาสรอดชีวิตและคุณภาพชีวิตที่ดีที่สุดให้กับผู้ป่วย

ในปี 1990 Le Cun และคณะได้เผยแพร่ผลงานวิจัยที่ริเริ่มการใช้ Convolutional Neural Network(CNN) เป็นครั้งแรก โดยใช้ในงาน Handwritten Digit Recognition และแทนที่ Input data แบบเดิมที่ใช้ Features Vector มาใช้การ Input ภาพทั้งภาพเข้าไปแทน โดยในงานวิจัยฉบับนี้ใช้ภาพขนาด 16\*16 pixel โดยเป็นภาพของตัวเลขที่เขียนด้วยลายมือ[25] ซึ่งต่อมา Convolutional Neural Network หรือ CNN เป็นที่นิยมมากขึ้นเรื่อยๆ ในงานที่เกี่ยวข้องกับการวิเคราะห์ภาพ โดยองค์ประกอบหลักๆของ CNN จะประกอบด้วย 1.) Convolutional Layer ทำหน้าที่ Extract Specific Features จากข้อมูลที่ป้อนเข้าไป 2.) Pooling Layer ทำหน้าที่ในการลดมิติของข้อมูลในกรณีที่มีข้อมูลมีลักษณะเป็น High Dimensional Data 3.) Fully Connected Layers ทำหน้าที่แปลงค่าที่ออกจาก Pooling layer ให้กลายเป็น 1-D array อย่างไรก็ตามเมื่อข้อมูลมีความละเอียดที่เพิ่มมากขึ้น จำเป็นต้องมีข้อมูลปริมาณมหาศาลในการ Train Model ให้ได้ผลดีจึงได้มีการคิดโครงสร้าง CNN แบบต่างๆเพิ่มขึ้นมา

ในปี 2012 Alex Krizhevsky และคณะนำเสนอ CNN Architecture ชื่อ AlexNet ซึ่งถูกออกแบบมาสำหรับการ Classify รูปภาพ 1.2 ล้านรูป โดยมีจำนวน Class ที่ต้องทำนาย 1,000 Class ในการแข่งขัน ImageNet LSVRC-2010 contest AlexNet ประกอบด้วย 8 ชั้น โดยที่ 5 ชั้นแรกเป็น Convolutional Layers และ Fully Connected Layers 3 ชั้น และยังสามารถใช้ ReLU activation Function แทนที่ SoftMax หรือ hyperbolic tangent แบบเดิม นอกจากนี้ยังมีการนำเสนอหลักการของ Dropout ซึ่งทำให้โมเดลมีความยืดหยุ่นมากขึ้น[26] ต่อมาในปี Simonyan and Zisserman พยายามที่จะพัฒนาความแม่นยำของ AlexNet ให้มากขึ้นโดยใช้สมมติฐานที่ว่า “The Deeper The Better” กล่าวคือถ้าเพิ่มความลึกหรือความซับซ้อนให้กับโมเดลมากขึ้น ควรจะได้รับความแม่นยำที่มากขึ้น ซึ่งผลลัพธ์ที่ได้พบว่าให้ผลลัพธ์ที่ดีกว่า AlexNet ตามที่คาดไว้ อย่างไรก็ตามเมื่อเพิ่มจำนวนความลึกหรือความซับซ้อนของโมเดลไปจนถึงจุดหนึ่งกลับพบว่าความแม่นยำไม่ได้เพิ่มขึ้นอีก แต่โมเดลกลับให้ผลการทำนายที่แย่ลงกว่าเดิม[27]ซึ่ง Kaiming He และคณะพยายามแก้ปัญหาดังกล่าวโดยคาดการณ์ว่าสาเหตุของปัญหาเกิดจาก Gradient Vanishing หรือ

การที่ Gradient มีผลต่อ Layers ทั่วๆไปน้อยกว่าที่ควรจึงได้มีการออกแบบ CNN Architecture รูปแบบใหม่และให้ชื่อว่า ResNet โดยมีการเพิ่ม Residual Network เข้ามาในโมเดลหลักเพื่อช่วยในการลดปัญหา Gradient Vanishing ซึ่งในปัจจุบัน ResNet Architecture ยังคงเป็นโมเดลที่ให้ผลลัพธ์ที่ดีที่สุดสำหรับชุดข้อมูล ImageNet โดยมี Error rate เท่ากับ 3.57%[28]

ในปี 2019 Mingxing Tan นำเสนอแนวคิดของการ Scaling Up ของโมเดลโดยใช้ Compound Coefficient และให้ชื่อว่า EfficientNets โดยผลลัพธ์ที่ได้พบว่า EfficientNet-B7 ให้ Accuracy 84.3% ต่อชุดข้อมูล ImageNet ในขณะที่โมเดลมีขนาดเล็กลงประมาณ 8.4 เท่า และทำงานได้เร็วขึ้นประมาณ 6.1 เท่า [29]

Khalid M และคณะทำการวิจัยโดยใช้ชุดข้อมูล PH2 Dataset[30] ซึ่งประกอบด้วยรูปภาพรอยโรคที่ผิวหนังจำนวน 200 ภาพ แบ่งเป็น 3 Classes ได้แก่ Melanoma 40 ภาพ, Common Nevus 80 ภาพ และ Atypical Nevus 80 ภาพ แก้ปัญหา Imbalanced Data โดยใช้ Augmentation Techniques หลังจากนั้นใช้ Pretrained-model ชนิด AlexNet โดยแทนที่ Classification layer ด้วย Classification layer ใหม่ที่ใช้ SoftMax Activation Function ในการทำนายผลลัพธ์ทั้งหมด 3 classes และใช้วิธี fine tune weight ในตัว Pretrained model และเปลี่ยน Input size เป็น  $227 \times 227 \times 3$  ผลการทดลองพบว่า เมื่อใช้เฉพาะรูปต้นฉบับในการ Train model โดยไม่ใช้ Augmentation Techniques จะได้ Accuracy ที่ 80%, Sensitivity 72.92 และ Precision 75.81% แต่เมื่อเพิ่ม Augmentation techniques จะทำให้ได้ค่า Accuracy, Sensitivity และ Precision เพิ่มขึ้นเป็น 98.61%, 98.33% และ 97.73% ตามลำดับ[31]

Muhammad Q. และคณะทำการศึกษาโดยใช้ชุดข้อมูล DermIS ซึ่งประกอบด้วยรูปภาพรอยโรคทั้งหมด 397 ภาพ แบ่งเป็น Skin Cancer 146 ภาพ และ Nevus skin lesion 251 ภาพ โดยใช้เทคนิค K-mean Clustering ในการทำ Segmentation เพื่อหา Region of Interest(ROI) แล้วจึงทำ Features Extraction เฉพาะบริเวณที่เป็น ROI เท่านั้น โดยวิธีทำ Features Extraction ทั้งหมด 3 วิธี ได้แก่ i) Grey Level Co-Occurrence Matrix(GLCM), ii) Local Binary Pattern, iii) Color Features โดยพบว่าหากใช้ทั้งสามวิธีร่วมกันและใช้ Support Vector Machine(SVM) ในการทำ Classification จะได้ผลลัพธ์ที่ดีที่สุดคือ Accuracy 96%, Sensitivity 97%, Precision 97%[32]

Justice O. และคณะทำการศึกษาโดยใช้ชุดข้อมูล ISIC Archive โดยการศึกษาเลือกใช้เฉพาะรอยโรคของ Melanoma 1,179 ภาพ และ Benign 1,179 ภาพ เพื่อแก้ปัญหา Imbalanced Data ในชุดข้อมูลทั้งหมด จากนั้นแบ่งเป็น Train Set 70% และ Test Set 30% และใช้

Augmentation Techniques เพื่อเพิ่มจำนวนข้อมูลในการ Train model โดยเปรียบเทียบ Model ทั้งหมด 3 Model ได้แก่ (i) 3-layer Convolutional neural network, (ii) Transfer Learning VGG16, (iii) Transfer Learning Inception V3 ผลการศึกษาพบว่า Inception V3 ให้ผลลัพธ์ที่ดีที่สุด คือ Accuracy 81%, Sensitivity 84.33%, และ Precision 79.06%[33]

Maad M. ทำการศึกษาโดยใช้ชุดข้อมูลจาก ISIC-Archive โดยมีรูปภาพรอยโรคทั้งสิ้น 24,225 ภาพ และใช้ Resampling Techniques ในการแก้ปัญหา Imbalanced Data หลังจากนั้น ใช้ Pre-trained Learning Model ,VGG19, InceptionV3, ResNet ในการ Train Model โดยพบว่า เมื่อใช้ InceptionV3 ร่วมกับ ImageNet Weight, Adam Optimizer, Learning Rate 0.0001, Epoch 10 จะให้ผลลัพธ์ที่ดีที่สุดคือ Accuracy 86.90%, Recall 86.14%, Precision 87.47% และ Specificity 87.66%[34]

Javed R. และคณะทำการศึกษาโดยใช้ชุดข้อมูล SIIM-ISIC2020[35] ประกอบด้วย รูปภาพรอยโรค 33,126 ภาพ แบ่งเป็น Malignant Class จำนวน 584 ภาพ และ Benign Class จำนวน 32,542 ภาพ โดยในการศึกษานี้ใช้ภาพ Malignant 584 ภาพ และ Benign Class จำนวน 11,670 ภาพ และใช้ Augmentation Technique เพื่อแก้ปัญหา Imbalanced Data หลังจากนั้น เปลี่ยนขนาดของภาพเป็น 256\*256 และใช้ Pre-trained Model MobileNetV2 ในการเทรน Model ผลการทดลองพบว่าค่า Accuracy, Recall, Precision และ F1-Score เท่ากับ 98.2%, 98.3%, 98% และ 98.1% ตามลำดับ[36]

Karar A. และคณะทำการศึกษาโดยใช้ชุดข้อมูล HAM10000[37] ซึ่งประกอบด้วย รูปภาพประมาณ 10,015 ภาพ ประกอบด้วย 7 classes ได้แก่ aklec 127 ภาพ, bcc 514 ภาพ, bkl 1099 ภาพ, df 115 ภาพ, mel 1113 ภาพ, nv 6705 ภาพ, vasc 142 ภาพ โดยนำมาแบ่งเป็น Train Set 72%, Validation Set 8%, Test Set 20% หลังจากนั้นนำมา Train model ด้วย Pre-trained Model EfficientNet B0-B7 ทั้งหมด 7 model ซึ่งพบว่า Model EfficientNet B4 และ EfficientNet B5 ให้ผลลัพธ์ที่ดีที่สุด โดยมี Accuracy, Recall, Precision เท่ากับ 88%, 88% และ 88% ตามลำดับ[38]

Muhammad Zia U. R. และคณะทำการศึกษาโดยใช้ชุดข้อมูลส่วนหนึ่งของ ISIC Archive ซึ่งเลือกมาเพียงบางส่วน ได้แก่ Malignant Class 1,497 ภาพ และ Benign Class 1,800 ภาพ และใช้ Augmentation Techniques เพื่อเพิ่มจำนวนข้อมูลที่ใช้ในการ Train Model โดยใช้ Transfer Learning MobileNetV2, DenseNet201, Modified MobileNetV2 และ Modified



DenseNet201 ในการเทรน โดย Modified DenseNet201 ให้ผลลัพธ์ที่ดีที่สุด คือ Accuracy 91.86%, Sensitivity 91.09%, Precision 92.82% และ F1-Score 91.95%[39]

Maryam T. และคณะทำการศึกษาโดยใช้ชุดข้อมูล i) ISIC-2020[35] โดยเลือกเฉพาะ Melanoma 579 ภาพ, ii) HAM10000[37] โดยเลือกเฉพาะ Basal Cell Carcinoma 510 ภาพ, Melanoma 1107 ภาพ และ Melanocytic Nevi 2007 ภาพ iii) DermIS โดยเลือก Melanoma จำนวน 30 ภาพ, Squamous Cell Carcinoma จำนวน 97 ภาพ ทำให้ได้ข้อมูลรวมคือ Basal Cell Carcinoma 510 ภาพ, Melanoma 1686 ภาพ, Melanocytic Nevi 2007 ภาพ และ Squamous Cell Carcinoma 97 ภาพ หลังจากนั้นแก้ปัญหา Imbalanced Data ด้วย SMOTE Tomek Upsampling Techniques และ Train Model ด้วย DSCC\_Net structure ผลการศึกษาพบว่า Accuracy 94.17%, Recall 94.28%, Precision 93.76% และ F1-Score 93.93%[40]

Syed Q. และคณะทำการศึกษาโดยใช้ชุดข้อมูล ISIC2019[37, 41, 42] ซึ่งประกอบด้วยด้วยรูปภาพรอยโรคประมาณ 25,331 ภาพ แต่เพื่อแก้ปัญหา Imbalanced Data จึงเลือกใช้ภาพที่เป็นรอยโรค Melanoma 3670 ภาพ และรูปภาพที่เป็น Non-Melanoma 3323 ภาพ โดยแบ่งเป็น Train Set 70% Validation Set 15% และ Test Set 15% โดยใช้ Spiking VGG-13 model ในการ Train, 100 epochs, Learning Rate 0.003, SGD optimizer และ Batch Size เท่ากับ 8 ผลการทดลองพบว่า Model ให้ค่า Accuracy 0.9, Sensitivity 0.89, Precision 0.91, F1 score 0.90[43]

Duggani K. และคณะทำการศึกษาโดยใช้ชุดข้อมูล ISBI2016[44] ซึ่งเป็นส่วนหนึ่งของ ISIC Datasets โดยมีรูปภาพรอยโรคทั้งหมด 900 ภาพ แบ่งเป็น Train Set 733 ภาพ แบ่งเป็นรอยโรคที่เป็น Melanoma จำนวน 243 ภาพ และรอยโรคที่ไม่ใช่ Melanoma 490 ภาพ Test Set จำนวน 167 ภาพ แบ่งเป็น Melanoma จำนวน 30 ภาพ และ Non-Melanoma จำนวน 137 ภาพ โดยขนาดของรูปภาพมีตั้งแต่  $1022 \times 767$  ไปจนถึง  $4288 \times 2848$  วิธีการวิจัยใช้การเปลี่ยนขนาดรูปภาพจากภาพต้นฉบับเป็นขนาด  $224 \times 224$  หลังจากนั้นใช้ Technique Augmentation เพื่อแก้ปัญหา Imbalanced Dataset โดยใช้ Pretrained-Model 2 ชนิดร่วมกันในการทำ Features Extraction (i) DenseNet-201 and MobileNet-v2, (ii) DenseNet-201 and ResNet-50 หลังจากนั้นใช้ SVM เป็น Classifier ในการทำนายจาก Features Vector ที่ได้ ผลที่ได้พบว่า เมื่อใช้ DenseNet-201 and MobileNet-v2 ทำหน้าที่ Features extraction ร่วมกับใช้ SVM เป็น classifier ร่วมกับ RMSProp Optimizer และ Tran model ทั้งสิ้น 30 epoch จะให้ผลลัพธ์ที่ดีที่สุด คือ Accuracy 88.02%, Sensitivity 98.54%, Precision 88.24% และ F1-Score 93.10%[45]

### บทที่ 3

## แนวคิดและวิธีวิจัย

งานวิจัยนี้มุ่งเน้นค้นหาแบบจำลองที่มีประสิทธิภาพสูงสุดในการทำนายมะเร็งผิวหนังชนิดเมลาโนมา(Melanoma) โดยใช้ Convolutional Neural Network(CNN) และประยุกต์ใช้การเรียนรู้แบบถ่ายทอด(Transfer Learning) ร่วมกับแบบจำลองชนิดต่างๆ ขั้นตอนการดำเนินงานวิจัยฉบับนี้ประกอบด้วย 4 ขั้นตอน



ภาพประกอบ 26 ขั้นตอนการทำวิจัย

#### การเก็บรวบรวมข้อมูล (Data Acquisition)

ชุดข้อมูลที่ใช้ในงานวิจัยฉบับนี้เป็นรูปภาพรอยโรคของผิวหนังที่ถ่ายจากกล้องส่องผิวหนัง(Dermoscopic Image) แต่จากงานวิจัยที่ผ่านมาพบว่าปัญหาสำคัญของงานวิจัยที่ใช้ Machine Learning หรือ CNN สำหรับ Melanoma Detection ในอดีตคือการขาดข้อมูลที่เพียงพอสำหรับการฝึกสอนโมเดล รวมถึงข้อมูลที่มีประสบบัญญา Severe Imbalanced Data ทำให้ประสิทธิภาพของโมเดลลดลงอย่างมีนัยยะสำคัญ งานวิจัยฉบับนี้จึงมุ่งเน้นแก้ปัญหาทั้งสองปัญหาที่กล่าวมาตั้งแต่ต้นโดยการรวบรวมข้อมูลจากหลายๆชุดข้อมูลโดยชุดข้อมูลที่นำมาใช้งานเก็บรวบรวมจาก

##### 1. ISIC Archive

เป็นชุดข้อมูลซึ่งถูกเก็บรวบรวมโดย The International Skin Imaging Collaboration(ISIC) โดยข้อมูลในชุดข้อมูลนี้เป็นรูปภาพรอยโรคที่ผิวหนังที่ถ่ายจากกล้องส่องผิวหนัง(Dermoscopic Image) ที่ได้รับการวินิจฉัยว่าเป็นมะเร็งผิวหนังชนิดเมลาโนมา(Melanoma) จำนวน 6,701 ภาพ รูปภาพทั้งหมดเป็นไฟล์ JPEG

##### 2. 7-POINT CRITERIA EVALUATION DATABASE[46]

เป็นชุดข้อมูลที่ถูกจัดทำขึ้นเพื่อใช้ในการประเมินความสามารถของคอมพิวเตอร์ในการวินิจฉัยรอยโรคที่ผิวหนัง โดยชุดข้อมูลนี้มีลักษณะเป็นภาพถ่ายรอยโรคที่ผิวหนัง ซึ่งถ่ายจากกล้องส่องผิวหนัง(Dermoscopic Image) จำนวน 1,011 ภาพ แบ่งเป็น 2 Class ได้แก่ Melanoma จำนวน 252 ภาพ และ Non-Melanoma จำนวน 759 ภาพ โดยงานวิจัยฉบับนี้



เลือกใช้เฉพาะ Melanoma Class จำนวน 252 ภาพเท่านั้น เพื่อเพิ่มจำนวน Minority Class ให้กับชุดข้อมูลรวมทั้งหมด


### 3. PH2 Dataset[30]

เป็นชุดข้อมูลที่รวบรวมขึ้นโดย The Dermatology Service of Hospital Pedro Hispano (Matosinhos, Portugal) โดยเป็นภาพ Dermoscopic Image จำนวน 200 ภาพ แบ่งได้เป็น 3 Class ได้แก่ Common Nevi 80 ภาพ, Atypical Nevi 80 ภาพ และ Melanoma 40 ภาพ ซึ่งในงานวิจัยฉบับนี้จะเลือกใช้เฉพาะภาพ Melanoma เท่านั้น

### 4. ISIC Challenge 2020[37, 41, 42]

เป็นชุดข้อมูลสำหรับการแข่งขัน SIIM-ISIC Melanoma Classification บนเว็บไซต์ Kaggle โดยเป็นรูปภาพรอยโรคที่ผิวหนังที่ถ่ายจากกล้องส่องผิวหนัง (Dermoscopic Image) ทั้งหมด 33,126 ภาพ แบ่งเป็น 2 Class ได้แก่ Malignant 584 ภาพ และ Benign 32,542 ภาพ โดยในงานวิจัยฉบับนี้จะสุ่มเลือกเฉพาะ Benign Class มาจำนวน 6,953 ภาพ รูปภาพทั้งหมดเป็นไฟล์ JPEG

ชุดข้อมูลทั้งหมดที่นำมาใช้ในการฝึกสอนโมเดลในครั้งนี้ มีทั้งหมด 13,986 ภาพ เป็นไฟล์ประเภท JPEG โดยแบ่งเป็น 2 Class คือ Malignant 6,993 ภาพ และ Benign 6,333 ภาพ



ภาพประกอบ 27 ตัวอย่างชุดข้อมูลที่นำมาใช้ฝึกสอนโมเดลที่ใช้ในงานวิจัยนี้


## การเตรียมข้อมูล (Pre-Processing)

### 1. Prepare Data

ข้อมูลทั้งหมดในงานวิจัยนี้อยู่ในรูปแบบไฟล์ JPEG จำนวน 13,906 ภาพ แบ่งเป็น 2 Class ได้แก่ Malignant 6,993 ภาพ และ Benign 6,993 ภาพ ทำการแบ่งชุดข้อมูลดังกล่าวเป็น Train Set, Validation Set และ Test Set ในอัตราส่วน 80:10:10 และทำการสร้าง Folder สำหรับฝึกสอน Model โดยมี Folder หลัก 3 Folder คือ Train, Test, Validate และในแต่ละ Folder หลัก จะมี Folder ย่อยจำนวน 2 Folder ตามจำนวน Class คือ Malignant และ Benign

### 2. Data Augmentation

ดำเนินการย่อขนาดของรูปจนเหลือขนาด 225\*225 pixel และทำ Data Augmentation สำหรับข้อมูลที่อยู่ใน Train Folder เพื่อเป็นการเพิ่มความหลากหลาย และเพิ่มจำนวนให้กับชุดข้อมูลที่ใช้ในการฝึกสอนโมเดล โดยทำการสุ่มหมุนภาพ (Random Rotation Range), กลับภาพซ้าย-ขวา (Horizontal Image Flipping) และกลับภาพบนล่าง (Vertical Image Flipping)



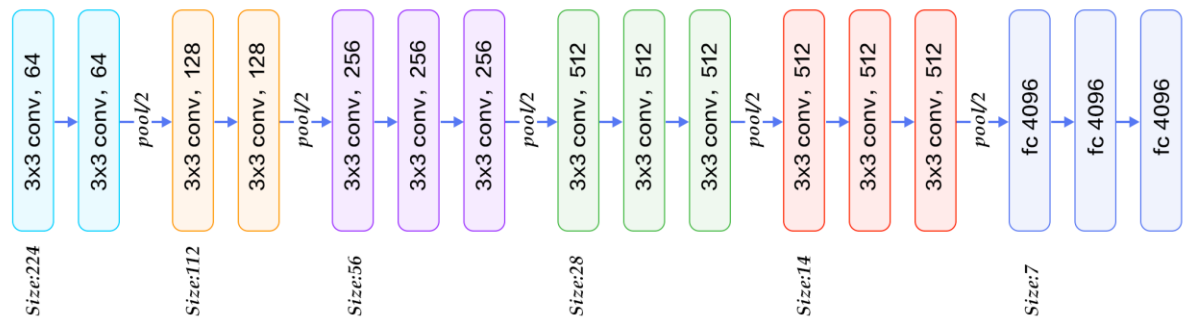
ภาพประกอบ 28 ตัวอย่างข้อมูลที่ผ่านการทำ Data Augmentation

## การสร้างแบบจำลอง (Modeling)

ในงานวิจัยฉบับนี้จะเลือกใช้โครงสร้าง Convolutional Neural Network หลายๆแบบ เพื่อพยายามหา Model หรือโครงสร้าง CNN ที่ให้ผลลัพธ์ที่ดีที่สุดสำหรับการคัดกรองมะเร็งผิวหนังชนิดเมลาโนมา(Melanoma) โดยโครงสร้างที่ใช้ มีรายละเอียดดังต่อไปนี้

### 1.VGG16

VGG 16 Architecture ถูกพัฒนาขึ้นในช่วงปี 2014 และตีพิมพ์ในปี 2015 ในบทความวิจัยชื่อ VERY DEEP CONVOLUTIONAL NETWORKS FOR LARGE-SCALE IMAGE RECOGNITION[47]โดยตัวเลข 16 บ่งบอกว่าตัวโมเดลมีทั้งหมด 16 ชั้น ทั้งหมด 138.4 ล้านพารามิเตอร์ และประกอบด้วย Set ของ Convolutional Layers จำนวน 5 Set เมื่อทดสอบกับชุดข้อมูล ImageNet พบว่า Top-5 Accuracy เท่ากับ 90.1%




ภาพประกอบ 29 VGG16 Architecture[27]

### 2.DenseNet201

DenseNet201 Architecture ถูกตีพิมพ์ในงานวิจัยชื่อ Densely Connected Convolutional Networks[47] ถูกออกแบบมาเพื่อพยายามแก้ปัญหา Gradient Vanishing กล่าวคือโมเดลแบบเดิมจะรับ Input Data จากชั้นก่อนหน้าเท่านั้น ทำให้เมื่อจำนวน Layer เพิ่มขึ้น Gradient จะไม่สามารถผ่านไปจนถึง Layer ท้ายได้ ทำให้เกิดการสูญหายของข้อมูลชั้นส่งผลโดยตรงต่อประสิทธิภาพของโมเดล โดย DenseNet Architecture เพิ่มการเชื่อมต่อจาก Dense Layer ก่อนหน้าไปยังทุกๆ Layer ที่อยู่ถัดลงมา

DenseNet201 มีความลึกทั้งหมด 402 ชั้น ประกอบด้วย 20.2 ล้านพารามิเตอร์ และเมื่อทดสอบกับชุดข้อมูล ImageNet จะได้ค่า Top-5 Accuracy เท่ากับ 93.6%



ภาพประกอบ 30 DenseNet Architecture[47]

Layers	Output Size	DenseNet-121	DenseNet-169	DenseNet-201	DenseNet-264
Convolution	112 × 112	7 × 7 conv, stride 2			
Pooling	56 × 56	3 × 3 max pool, stride 2			
Dense Block (1)	56 × 56	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$
Transition Layer (1)	56 × 56	1 × 1 conv			
	28 × 28	2 × 2 average pool, stride 2			
Dense Block (2)	28 × 28	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$
Transition Layer (2)	28 × 28	1 × 1 conv			
	14 × 14	2 × 2 average pool, stride 2			
Dense Block (3)	14 × 14	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 24$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 64$
Transition Layer (3)	14 × 14	1 × 1 conv			
	7 × 7	2 × 2 average pool, stride 2			
Dense Block (4)	7 × 7	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 16$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$
Classification Layer	1 × 1	7 × 7 global average pool			
		1000D fully-connected, softmax			

ภาพประกอบ 31 จำนวน Layer ของ DenseNet Architecture[47]

### 3.ResNet152V2

ResNet Architecture ถูกตีพิมพ์ในงานวิจัยชื่อ Identity Mappings in Deep Residual Networks[48] ออกแบบมาเพื่อพยายามแก้ปัญหา Gradient Vanishing โดยเพิ่มการทำ Residual Mapping

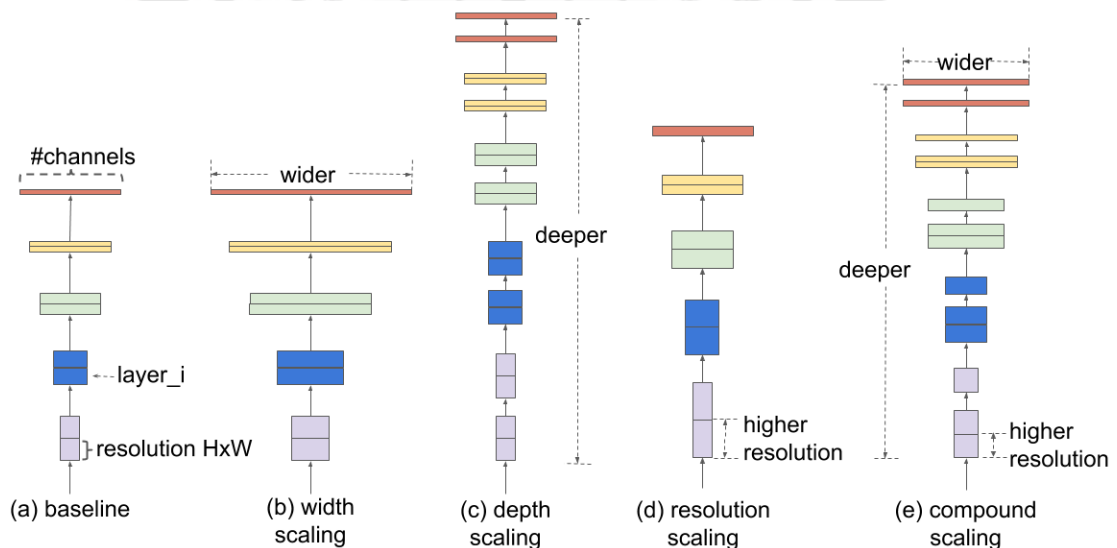
ResNet152V2 มีความลึกทั้งหมด 307 ชั้น ประกอบด้วย 60.4 ล้านพารามิเตอร์ และเมื่อทำการทดสอบกับชุดข้อมูล ImageNet จะได้ค่า Top-5 Accuracy เท่ากับ 94.2%

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
		3×3 max pool, stride 2				
conv2.x	56×56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3.x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4.x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5.x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		$1.8 \times 10^9$	$3.6 \times 10^9$	$3.8 \times 10^9$	$7.6 \times 10^9$	$11.3 \times 10^9$


ภาพประกอบ 32 จำนวน Layer ของ ResNet Architecture[49]

#### 4.EfficientNetB5

EfficientNet Architecture ถูกตีพิมพ์ครั้งแรกในงานวิจัยชื่อ EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks [29] โดยพัฒนาจาก Conventional Scaling Method แบบเดิมที่ต้องว่าจะเพิ่มความกว้าง, ความลึก หรือเพิ่มขนาดความละเอียดของรูปภาพที่จะนำมาฝึกสอนโมเดลเพื่อเพิ่มประสิทธิภาพของโมเดล มาเป็นการใช้ Compound Scaling ซึ่งมีการปรับขนาดไปพร้อมๆกันด้วย Scaling Coefficient[16]



ภาพประกอบ 33 (b)-(d) Conventional Scaling Method, (e) compound Scaling in EfficientNet Architecture[29]



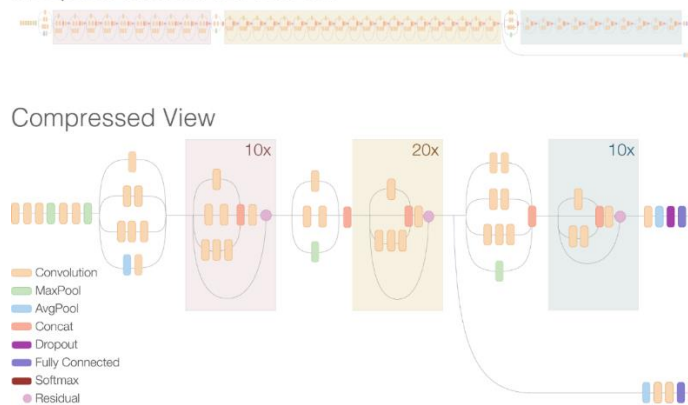
ภาพประกอบ 34 Performance ของ EffientNet Architecture [29]

EfficientNetB5 มีความลึก 312 ชั้น มีพารามิเตอร์ทั้งหมด 30.6 ล้านพารามิเตอร์ และเมื่อทำการทดสอบกับชุดข้อมูล ImageNet จะได้ Top-6 Accuracy เท่ากับ 96.7%

### 5. InceptionResNetV2

InceptionResNet Architecture ถูกตีพิมพ์ในงานวิจัยชื่อ Inception-ResNet and the Impact of Residual Connections on Learning [50] โดยเป็นการรวมกันระหว่าง Inception Architecture โดยเพิ่ม Residual Connections[49]เข้าไปในโครงสร้าง

Inception Resnet V2 Network



ภาพประกอบ 35 InceptionResNetV2 Architecture[51]

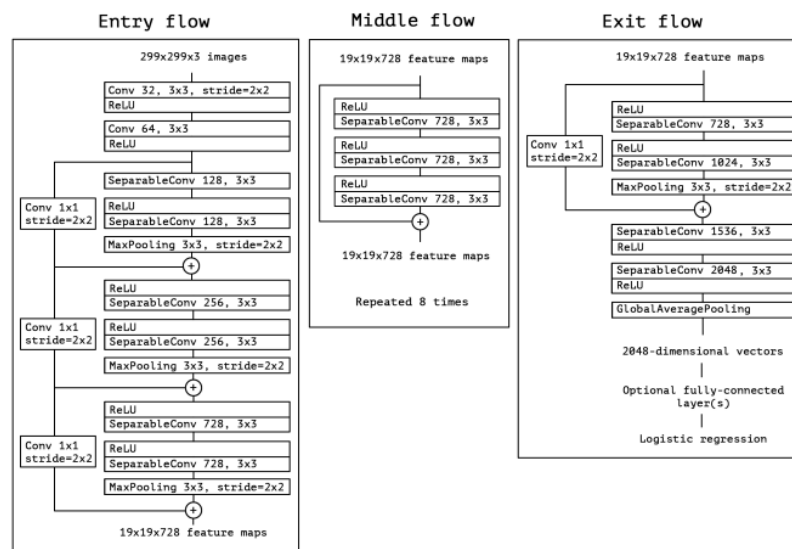


InceptionResNetV2 เมื่อทดสอบกับชุดข้อมูล ImageNet พบว่า Top-5 Accuracy เท่ากับ 95.3% และมีจำนวนพารามิเตอร์ 55.9 ล้านพารามิเตอร์

## 6.Xception

Xception Architecture ได้รับการตีพิมพ์ในงานวิจัยชื่อ Xception: Deep Learning with Depthwise Separable Convolutions[52] Xception มาจากชื่อ “Extreme Version of an Inception” โดยเป็นโครงสร้างแบบ Linear Stack ของ Depthwise Separable Convolutional Layers ซึ่งทำให้การสร้างหรือปรับปรุงโครงสร้างของโมเดลนั้นทำได้ง่าย ๆ ได้ โดยใช้ Code เพียง 30-40 บรรทัดมือใช้ High Level Library เช่น Keras หรือ Tensorflow

Xception Architecture มีความลึก 81 ชั้น และมีจำนวนพารามิเตอร์ 22.9 ล้านพารามิเตอร์ เมื่อนำ Xception Architecture ไปทดสอบกับชุดข้อมูล ImageNet พบว่าให้ค่า Top-5 Accuracy ที่ 94.5% และ Top-1 Accuracy ที่ 79.0%



ภาพประกอบ 36 Xception Architecture[52]

## การประเมินผลแบบจำลอง (Model Evaluation)

การประเมินผลในงานวิจัยฉบับนี้ใช้ค่าความถูกต้อง (accuracy) และความไว (Sensitivity or Recall) เนื่องจากปัญหาของงานวิจัยฉบับนี้เป็นการทำนายโรคมะเร็งผิวหนังที่เป็นอันตรายต่อชีวิตของมนุษย์ หากโมเดลทำนายผิดพลาดอาจส่งผลให้เกิดความเสียหายอย่างมาก

### 1. Confusion Matrix

Confusion Matrix เป็นการวัดที่ได้รับความนิยมเป็นอย่างมาก สามารถใช้ได้ทั้งปัญหา Binary Classification และ Multiclass Classification โดย Confusion Matrix แสดงการนับจำนวนผลการทำนายที่ได้จากโมเดลเปรียบเทียบกับ Label จริงของจุดข้อมูลนั้นๆ

		Predicted	
		Negative	Positive
Actual	Negative	TN	FP
	Positive	FN	TP

Confusion Matrix

**True Negative (TN)** คือ ผลตรวจทางการแพทย์พบว่า ไม่เป็นมะเร็งผิวหนัง และ Model ทำนายว่า ไม่เป็นมะเร็งผิวหนัง

**True Positive (TP)** คือ ผลตรวจทางการแพทย์พบว่า เป็นมะเร็งผิวหนัง และ Model ทำนายว่า เป็นมะเร็งผิวหนัง

**False Negative (FN)** คือ ผลตรวจทางการแพทย์พบว่า เป็นมะเร็งผิวหนัง และ Model ทำนายว่า ไม่เป็นมะเร็งผิวหนัง

**False Positive (FP)** คือ ผลตรวจทางการแพทย์พบว่า ไม่เป็นมะเร็งผิวหนัง และ Model ทำนายว่า เป็นมะเร็งผิวหนัง

[1]

### 2. Accuracy (ความถูกต้อง)

Accuracy หรือค่าความถูกต้อง เป็นค่าที่แสดงความสามารถของเครื่องมือวัดว่า สามารถวัดได้ถูกต้องใกล้เคียงกับค่าจริงเพียงใด มักจะคำนวณเป็นเปอร์เซ็นต์ความถูกต้อง สามารถคำนวณได้จาก จำนวนครั้งที่โมเดลทำนายถูกต้อง ทั้ง Positive และ Negative Class หากด้วยจำนวนครั้งที่ทำนายทั้งหมด

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

ภาพประกอบ 37 สมการที่ใช้ในการคำนวณค่า Accuracy (ความถูกต้อง)

### 3.Sensitivity หรือ Recall (ความไว)

Recall หรือในทางการแพทย์อาจใช้คำว่า Sensitivity (ความไว) เป็นเครื่องมือวัดที่นิยมใช้ในทางการแพทย์เพื่อการคัดกรองโรค กล่าวโดยรวมคือเมื่อค่า Sensitivity สูงมากขึ้นโอกาสที่จะเกิด False Negative Rate หรือโอกาสที่ Model จะทำนายคนที่เป็น “โรคมะเร็ง” ว่า “ไม่เป็นโรค” จะต่ำลง จึงเป็นสาเหตุให้เลือกใช้ Recall ในการวัดผล Model เพราะหากใช้โมเดลที่มี Recall ต่ำ ก็จะทำให้ค่า False Negative Rate สูง ทำให้โมเดลทำนายรอยโรคมะเร็งผิวหนังว่าไม่ใช่มะเร็ง อาจทำให้ผู้ป่วยเสียชีวิตได้ ค่า Recall สามารถคำนวณได้จาก จำนวนที่ Model ทำนาย Positive Class ถูกต้อง (True Positive) หารด้วยผลรวมของ Model ทำนาย Positive Class ถูกต้อง (True Positive) และจำนวนที่ Model ทำนาย Positive Class ผิด (False Negative)

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

ภาพประกอบ 38 สมการที่ใช้ในการคำนวณค่า Recall (ความไว)

## บทที่ 4

### การทดลองและผลการศึกษา

งานวิจัยฉบับนี้เป็นการศึกษาทดลองใช้การเรียนรู้เชิงลึก (Deep Learning) โดยใช้เทคนิคการเรียนรู้แบบถ่ายทอด (Pretrained Model with transfer learning) โดยใช้ชุดข้อมูลเปิด โดยข้อมูลทั้งหมดเป็นภาพถ่ายเดอร์โมสโคปีกรอยโรคของผิวหนัง (Dermoscopic Skin Images) จำนวน 13,986 ภาพ และทำการแบ่งชุดข้อมูลออกเป็น Train Set, Test Set, Validation Set ในอัตราส่วน 80:10:10 ตามลำดับ หลังจากนั้นใช้ Train Set ในการฝึกสอนโมเดลแบบต่างๆ ทั้งสิ้นจำนวน 6 โมเดล VGG16, DenseNet201, ResNet152V2, EfficientNetB5, InceptionResNetV2, Xception โดยทำการปรับพารามิเตอร์แบบละเอียดทั้งสิ้น 3 พารามิเตอร์ ได้แก่

#### 1. Optimizer

- 1.1 Stochastic Gradient Descent (SGD)
- 1.2 Adaptive Moment Estimation (Adam)
- 1.3 Root Mean Squared Propagation (RMSprop)
- 1.4 Nesterov-Accelerated Adaptive Moment Estimation (Nadam)

#### 2. Learning Rate

- 2.1 Learning Rate 0.01
- 2.2 Learning Rate 0.001
- 2.3 Learning Rate 0.0001
- 2.4 Schedule Learning Rate

#### 3. Batch Size

- 3.1 Batch Size 16
- 3.2 Batch Size 32
- 3.3 Batch Size 64
- 3.4 Batch Size 128

กล่าวโดยสรุปคือในการศึกษาฉบับนี้ผู้วิจัยได้ทำการฝึกสอนโมเดลทั้งสิ้น 384 โมเดล และทำการทดสอบกับชุดข้อมูล Test Data ผลการทดสอบสามารถแสดง ดังต่อไปนี้

## 1. VGG16 Architecture

ในการศึกษาครั้งนี้ได้ทำการฝึกสอนโมเดลโดยใช้การเรียนรู้แบบถ่ายทอด VGG16 with Pretrained ImageNet Weight โดยทำการฝึกสอนทั้งหมด 64 โมเดล

### 1.1 ผลการทดลองเมื่อใช้ VGG16 with SGD Optimizer แสดงในตาราง 1

ตาราง 1 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ VGG16 ร่วมกับ SGD Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
SGD	16	0.01	0.90	0.87	0.89
SGD	16	0.001	0.90	0.90	0.90
SGD	16	0.0001	0.87	0.78	0.85
SGD	16	Schedule	0.90	0.91	0.90
SGD	32	0.01	0.89	0.82	0.88
SGD	32	0.001	0.88	0.94	0.88
SGD	32	0.0001	0.86	0.84	0.86
SGD	32	Schedule	0.90	0.87	0.90
SGD	64	0.01	0.90	0.87	0.89
SGD	64	0.001	0.88	0.90	0.88
SGD	64	0.0001	0.83	0.85	0.83
SGD	64	Schedule	0.89	0.84	0.88
SGD	128	0.01	0.90	0.87	0.90
SGD	128	0.001	0.87	0.85	0.87
SGD	128	0.0001	0.77	0.63	0.73
SGD	128	Schedule	0.90	0.86	0.90

จากตาราง 1 จะเห็นว่าเมื่อใช้ VGG16 ร่วมกับ SGD Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงสุดคือ เมื่อใช้ Batch size เท่ากับ 16 และเลือกใช้ Schedule Learning Rate ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.90, 0.91 และ 0.90 ตามลำดับ

### 1.2 ผลการทดลองเมื่อใช้ VGG16 with RMSprop Optimizer แสดงในตาราง 2

ตาราง 2 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ VGG16 ร่วมกับ RMSprop Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
RMSprop	16	0.01	0.86	0.80	0.85
RMSprop	16	0.001	0.88	0.94	0.89
RMSprop	16	0.0001	0.90	0.88	0.86
RMSprop	16	Schedule	0.89	0.82	0.88
RMSprop	32	0.01	0.89	0.85	0.89
RMSprop	32	0.001	0.90	0.86	0.90
RMSprop	32	0.0001	0.91	0.89	0.87
RMSprop	32	Schedule	0.89	0.82	0.88
RMSprop	64	0.01	0.89	0.85	0.88
RMSprop	64	0.001	0.90	0.84	0.90
RMSprop	64	0.0001	0.91	0.88	0.91
RMSprop	64	Schedule	0.89	0.85	0.88
RMSprop	128	0.01	0.89	0.86	0.89
RMSprop	128	0.001	0.90	0.88	0.90
RMSprop	128	0.0001	0.90	0.90	0.90
RMSprop	128	Schedule	0.86	0.80	0.86

จากตาราง 2 จะเห็นว่าเมื่อใช้ VGG16 ร่วมกับ RMSprop Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงที่สุดคือ เมื่อใช้ Batch size เท่ากับ 16 และเลือกใช้ Learning Rate 0.001 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.88, 0.94 และ 0.89 ตามลำดับ

### 1.3 ผลการทดลองเมื่อใช้ VGG16 with Adam Optimizer แสดงในตาราง 3

ตาราง 3 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ VGG16 ร่วมกับ Adam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Adam	16	0.01	0.90	0.87	0.89
Adam	16	0.001	0.91	0.89	0.91



ตารางที่ 3 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ VGG16 ร่วมกับ Adam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Adam	16	0.0001	0.91	0.88	0.90
Adam	16	Schedule	0.90	0.88	0.90
Adam	32	0.01	0.90	0.86	0.89
Adam	32	0.001	0.92	0.89	0.91
Adam	32	0.0001	0.91	0.87	0.90
Adam	32	Schedule	0.89	0.86	0.89
Adam	64	0.01	0.90	0.90	0.90
Adam	64	0.001	0.90	0.88	0.90
Adam	64	0.0001	0.91	0.87	0.90
Adam	64	Schedule	0.90	0.90	0.90
Adam	128	0.01	0.91	0.89	0.91
Adam	128	0.001	0.91	0.89	0.91
Adam	128	0.0001	0.90	0.87	0.90
Adam	128	Schedule	0.89	0.84	0.88

จากตาราง 3 จะเห็นว่าเมื่อใช้ VGG16 ร่วมกับ Adam Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงสุดคือ เมื่อใช้ Batch size เท่ากับ 32 และเลือกใช้ Learning Rate 0.001 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.92, 0.89 และ 0.91 ตามลำดับ

#### 1.4 ผลการทดลองเมื่อใช้ VGG16 with Nadam Optimizer แสดงในตาราง 4

ตาราง 4 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ VGG16 ร่วมกับ Nadam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Nadam	16	0.01	0.88	0.86	0.88
Nadam	16	0.001	0.91	0.87	0.91
Nadam	16	0.0001	0.91	0.88	0.91

ตาราง 4 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ VGG16 ร่วมกับ Nadam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Nadam	16	Schedule	0.91	0.87	0.90
Nadam	32	0.01	0.50	1.00	0.67
Nadam	32	0.001	0.90	0.85	0.90
Nadam	32	0.0001	0.90	0.87	0.90
Nadam	32	Schedule	0.81	0.64	0.77
Nadam	64	0.01	0.50	1.00	0.67
Nadam	64	0.001	0.90	0.87	0.90
Nadam	64	0.0001	0.90	0.87	0.90
Nadam	64	Schedule	0.89	0.84	0.88
Nadam	128	0.01	0.90	0.87	0.90
Nadam	128	0.001	0.90	0.87	0.90
Nadam	128	0.0001	0.90	0.88	0.90
Nadam	128	Schedule	0.84	0.96	0.86

จากตาราง 4 จะเห็นว่าเมื่อใช้ VGG16 ร่วมกับ Nadam Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงสุดคือ เมื่อใช้ Batch size เท่ากับ 16 และเลือกใช้ Learning Rate 0.0001 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.91, 0.88 และ 0.91 ตามลำดับ

## 2. DenseNet201 Architecture

ในการศึกษาครั้งนี้ได้ทำการฝึกสอนโมเดลโดยใช้การเรียนรู้แบบถ่ายทอด DenseNet201 with Pretrained ImageNet Weight โดยทำการฝึกสอนทั้งหมด 64 โมเดล

### 2.1 ผลการทดลองเมื่อใช้ DenseNet201 with SGD แสดงในตาราง 5

ตาราง 5 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ DenseNet201 ร่วมกับ SGD Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
SGD	16	0.01	0.92	0.87	0.91
SGD	16	0.001	0.91	0.85	0.90

ตาราง 5 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ DenseNet201 ร่วมกับ SGD Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
SGD	16	0.0001	0.91	0.87	0.91
SGD	16	Schedule	0.90	0.82	0.89
SGD	32	0.01	0.91	0.88	0.91
SGD	32	0.001	0.91	0.87	0.90
SGD	32	0.0001	0.89	0.83	0.89
SGD	32	Schedule	0.91	0.87	0.91
SGD	64	0.01	0.91	0.89	0.91
SGD	64	0.001	0.91	0.85	0.90
SGD	64	0.0001	0.89	0.83	0.88
SGD	64	Schedule	0.91	0.88	0.90
SGD	128	0.01	0.91	0.90	0.91
SGD	128	0.001	0.89	0.81	0.89
SGD	128	0.0001	0.87	0.81	0.86
SGD	128	Schedule	0.92	0.91	0.92

จากตาราง 5 จะเห็นว่าเมื่อใช้ DenseNet201 ร่วมกับ SGD Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงที่สุดคือ เมื่อใช้ Batch size เท่ากับ 128 และเลือกใช้ Schedule Learning Rate ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.92, 0.91 และ 0.92 ตามลำดับ

## 2.2 ผลการทดลองเมื่อใช้ DenseNet201 with RMSprop แสดงในตาราง 6

ตาราง 6 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ DenseNet201 ร่วมกับ RMSprop Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
RMSprop	16	0.01	0.50	1.00	0.67
RMSprop	16	0.001	0.90	0.82	0.89
RMSprop	16	0.0001	0.89	0.81	0.88

ตาราง 6 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ DenseNet201 ร่วมกับ RMSprop Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
RMSprop	16	Schedule	0.92	0.91	0.92
RMSprop	32	0.01	0.88	0.83	0.88
RMSprop	32	0.001	0.87	0.76	0.85
RMSprop	32	0.0001	0.89	0.82	0.89
RMSprop	32	Schedule	0.90	0.83	0.89
RMSprop	64	0.01	0.89	0.85	0.89
RMSprop	64	0.001	0.92	0.88	0.91
RMSprop	64	0.0001	0.90	0.84	0.89
RMSprop	64	Schedule	0.91	0.84	0.90
RMSprop	128	0.01	0.93	0.91	0.93
RMSprop	128	0.001	0.91	0.85	0.91
RMSprop	128	0.0001	0.92	0.91	0.92
RMSprop	128	Schedule	0.92	0.88	0.91

จากตาราง 6 จะเห็นว่าเมื่อใช้ DenseNet201 ร่วมกับ RMSprop Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงที่สุดคือ เมื่อใช้ Batch size เท่ากับ 128 และเลือกใช้ Learning Rate 0.01 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.93, 0.91 และ 0.93 ตามลำดับ

### 2.3 ผลการทดลองเมื่อใช้ DenseNet201 with Adam แสดงในตาราง 7

ตาราง 7 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ DenseNet201 ร่วมกับ Adam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Adam	16	0.01	0.86	0.82	0.85
Adam	16	0.001	0.92	0.87	0.91
Adam	16	0.0001	0.91	0.85	0.90
Adam	16	Schedule	0.89	0.81	0.88

ตาราง 7 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ DenseNet201 ร่วมกับ Adam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Adam	32	0.01	0.50	0.00	Error
Adam	32	0.001	0.90	0.84	0.90
Adam	32	0.0001	0.92	0.87	0.91
Adam	32	Schedule	0.91	0.86	0.91
Adam	64	0.01	0.91	0.87	0.90
Adam	64	0.001	0.90	0.84	0.90
Adam	64	0.0001	0.90	0.86	0.90
Adam	64	Schedule	0.90	0.85	0.90
Adam	128	0.01	0.90	0.86	0.89
Adam	128	0.001	0.88	0.79	0.87
Adam	128	0.0001	0.91	0.86	0.91
Adam	128	Schedule	0.90	0.83	0.89

จากตาราง 7 จะเห็นว่าเมื่อใช้ DenseNet201 ร่วมกับ Adam Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงสุดคือ เมื่อใช้ Batch size เท่ากับ 16 และเลือกใช้ Learning Rate 0.001 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.92, 0.87 และ 0.91 ตามลำดับ

## 2.4 ผลการทดลองเมื่อใช้ DenseNet201 with Nadam แสดงในตาราง 8

ตาราง 8 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ DenseNet201 ร่วมกับ Nadam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Nadam	16	0.01	0.90	0.85	0.89
Nadam	16	0.001	0.91	0.88	0.91
Nadam	16	0.0001	0.92	0.91	0.92
Nadam	16	Schedule	0.90	0.88	0.89
Nadam	32	0.01	0.89	0.88	0.89

ตาราง 8 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ DenseNet201 ร่วมกับ Nadam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Nadam	32	0.001	0.90	0.87	0.90
Nadam	32	0.0001	0.91	0.88	0.91
Nadam	32	Schedule	0.92	0.89	0.91
Nadam	64	0.01	0.87	0.76	0.86
Nadam	64	0.001	0.90	0.84	0.90
Nadam	64	0.0001	0.89	0.83	0.89
Nadam	64	Schedule	0.88	0.82	0.88
Nadam	128	0.01	0.90	0.85	0.89
Nadam	128	0.001	0.89	0.81	0.88
Nadam	128	0.0001	0.91	0.84	0.90
Nadam	128	Schedule	0.91	0.84	0.90

จากตาราง 8 จะเห็นว่าเมื่อใช้ DenseNet201 ร่วมกับ Nadam Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงสุดคือ เมื่อใช้ Batch size เท่ากับ 16 และเลือกใช้ Learning Rate 0.0001 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.92, 0.91 และ 0.92 ตามลำดับ

### 3. ResNet152V2 Architecture

ในการศึกษาค้นคว้าครั้งนี้ได้ทำการฝึกสอนโมเดลโดยใช้การเรียนรู้แบบถ่ายทอด ResNet152V2 with Pretrained ImageNet Weight โดยทำการฝึกสอนทั้งหมด 64 โมเดล

#### 3.1 ผลการทดลองเมื่อใช้ ResNet152V2 with SGD แสดงในตาราง 9

ตาราง 9 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ ResNet152V2 ร่วมกับ SGD Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
SGD	16	0.01	0.92	0.91	0.92
SGD	16	0.001	0.91	0.87	0.90
SGD	16	0.0001	0.91	0.86	0.90



ตาราง 9 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ ResNet152V2 ร่วมกับ SGD Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
SGD	16	Schedule	0.92	0.92	0.92
SGD	32	0.01	0.91	0.87	0.91
SGD	32	0.001	0.92	0.90	0.92
SGD	32	0.0001	0.90	0.88	0.90
SGD	32	Schedule	0.92	0.90	0.92
SGD	64	0.01	0.92	0.93	0.92
SGD	64	0.001	0.91	0.92	0.91
SGD	64	0.0001	0.89	0.91	0.89
SGD	64	Schedule	0.92	0.92	0.92
SGD	128	0.01	0.92	0.91	0.92
SGD	128	0.001	0.92	0.90	0.91
SGD	128	0.0001	0.88	0.89	0.88
SGD	128	Schedule	0.92	0.90	0.91

จากตาราง 9 จะเห็นว่าเมื่อใช้ ResNet152V2 ร่วมกับ SGD Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงสุดคือ เมื่อใช้ Batch size เท่ากับ 64 และเลือกใช้ Learning Rate 0.01 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.92, 0.93 และ 0.92 ตามลำดับ

### 3.2 ผลการทดลองเมื่อใช้ ResNet152V2 with RMSprop แสดงในตาราง 10

ตาราง 10 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ ResNet152V2 ร่วมกับ RMSprop Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
RMSprop	16	0.01	0.71	0.46	0.62
RMSprop	16	0.001	0.91	0.89	0.91
RMSprop	16	0.0001	0.92	0.93	0.92
RMSprop	16	Schedule	0.91	0.88	0.91

ตาราง 10 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ ResNet152V2 ร่วมกับ RMSprop Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
RMSprop	32	0.01	0.50	0.00	Error
RMSprop	32	0.001	0.91	0.86	0.91
RMSprop	32	0.0001	0.91	0.84	0.90
RMSprop	32	Schedule	0.92	0.89	0.92
RMSprop	64	0.01	0.91	0.87	0.91
RMSprop	64	0.001	0.91	0.90	0.91
RMSprop	64	0.0001	0.91	0.87	0.91
RMSprop	64	Schedule	0.92	0.86	0.91
RMSprop	128	0.01	0.91	0.87	0.91
RMSprop	128	0.001	0.91	0.88	0.91
RMSprop	128	0.0001	0.92	0.88	0.91
RMSprop	128	Schedule	0.92	0.91	0.92

จากตาราง 10 จะเห็นว่าเมื่อใช้ ResNet152V2 ร่วมกับ RMSprop Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงที่สุดคือ เมื่อใช้ Batch size เท่ากับ 16 และเลือกใช้ Learning Rate 0.0001 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.92, 0.93 และ 0.92 ตามลำดับ

### 3.3 ผลการทดลองเมื่อใช้ ResNet152V2 with Adam แสดงในตาราง 11

ตาราง 11 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ ResNet152V2 ร่วมกับ Adam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Adam	16	0.01	0.50	0.00	Error
Adam	16	0.001	0.90	0.84	0.90
Adam	16	0.0001	0.92	0.88	0.92
Adam	16	Schedule	0.92	0.91	0.92
Adam	32	0.01	0.50	0.00	Error

ตาราง 11 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ ResNet152V2 ร่วมกับ Adam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Adam	32	0.001	0.92	0.88	0.91
Adam	32	0.0001	0.93	0.89	0.93
Adam	32	Schedule	0.92	0.88	0.92
Adam	64	0.01	0.50	0.00	Error
Adam	64	0.001	0.93	0.91	0.92
Adam	64	0.0001	0.91	0.92	0.91
Adam	64	Schedule	0.92	0.89	0.91
Adam	128	0.01	0.90	0.85	0.90
Adam	128	0.001	0.92	0.89	0.92
Adam	128	0.0001	0.92	0.89	0.92
Adam	128	Schedule	0.93	0.89	0.92

จากตาราง 11 จะเห็นว่าเมื่อใช้ ResNet152V2 ร่วมกับ Adam Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงที่สุดคือ เมื่อใช้ Batch size เท่ากับ 64 และเลือกใช้ Learning Rate 0.001 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.93, 0.91 และ 0.92 ตามลำดับ

### 3.4 ผลการทดลองเมื่อใช้ ResNet152V2 with Nadam แสดงในตาราง 12

ตาราง 12 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ ResNet152V2 ร่วมกับ Nadam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Nadam	16	0.01	0.50	1.00	0.67
Nadam	16	0.001	0.91	0.86	0.91
Nadam	16	0.0001	0.92	0.88	0.92
Nadam	16	Schedule	0.92	0.90	0.92
Nadam	32	0.01	0.50	1.00	0.67
Nadam	32	0.001	0.92	0.89	0.92

ตาราง 12 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ ResNet152V2 ร่วมกับ Nadam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Nadam	32	0.0001	0.91	0.86	0.91
Nadam	32	Schedule	0.92	0.89	0.92
Nadam	64	0.01	0.49	0.00	Error
Nadam	64	0.001	0.92	0.91	0.92
Nadam	64	0.0001	0.92	0.88	0.91
Nadam	64	Schedule	0.92	0.90	0.91
Nadam	128	0.01	0.91	0.89	0.91
Nadam	128	0.001	0.92	0.90	0.92
Nadam	128	0.0001	0.92	0.93	0.92
Nadam	128	Schedule	0.91	0.90	0.91

จากตาราง 12 จะเห็นว่าเมื่อใช้ ResNet152V2 ร่วมกับ Nadam Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงสุดคือ เมื่อใช้ Batch size เท่ากับ 128 และเลือกใช้ Learning Rate 0.0001 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.92, 0.93 และ 0.92 ตามลำดับ

#### 4. EfficentNetB5 Architecture

ในการศึกษาครั้งนี้ได้ทำการฝึกสอนโมเดลโดยใช้การเรียนรู้แบบถ่ายทอด EfficentNetB5 with Pretrained ImageNet Weight โดยทำการฝึกสอนทั้งหมด 64 โมเดล

##### 4.1 ผลการทดลองเมื่อใช้ EfficentNetB5 with SGD แสดงในตาราง 13

ตาราง 13 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ EfficentNetB5 ร่วมกับ SGD Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
SGD	16	0.01	0.94	0.93	0.94
SGD	16	0.001	0.94	0.93	0.94
SGD	16	0.0001	0.93	0.92	0.93
SGD	16	Schedule	0.93	0.91	0.93

ตาราง 13 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ EfficientNetB5 ร่วมกับ SGD Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
SGD	32	0.01	0.94	0.93	0.94
SGD	32	0.001	0.94	0.93	0.94
SGD	32	0.0001	0.93	0.91	0.93
SGD	32	Schedule	0.94	0.91	0.94
SGD	64	0.01	0.93	0.93	0.93
SGD	64	0.001	0.93	0.93	0.93
SGD	64	0.0001	0.93	0.93	0.93
SGD	64	Schedule	0.93	0.93	0.93
SGD	128	0.01	0.92	0.91	0.92
SGD	128	0.001	0.94	0.93	0.94
SGD	128	0.0001	0.92	0.90	0.92
SGD	128	Schedule	0.93	0.93	0.93

จากตาราง 13 จะเห็นว่าเมื่อใช้ EfficientNetB5 ร่วมกับ SGD Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงสุดคือ เมื่อใช้ Batch size เท่ากับ 32 และเลือกใช้ Learning Rate 0.001 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.94, 0.93 และ 0.94 ตามลำดับ

#### 4.2 ผลการทดลองเมื่อใช้ EfficientNetB5 with RMSprop แสดงในตาราง 14

ตาราง 14 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ EfficientNetB5 ร่วมกับ RMSprop Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
RMSprop	16	0.01	0.93	0.93	0.93
RMSprop	16	0.001	0.91	0.87	0.91
RMSprop	16	0.0001	0.92	0.92	0.92
RMSprop	16	Schedule	0.70	0.40	0.57
RMSprop	32	0.01	0.93	0.92	0.93

ตาราง 14 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ EfficientNetB5 ร่วมกับ RMSprop Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
RMSprop	32	0.001	0.93	0.89	0.93
RMSprop	32	0.0001	0.93	0.92	0.93
RMSprop	32	Schedule	0.81	0.64	0.77
RMSprop	64	0.01	0.93	0.91	0.93
RMSprop	64	0.001	0.93	0.87	0.92
RMSprop	64	0.0001	0.94	0.92	0.94
RMSprop	64	Schedule	0.88	0.79	0.87
RMSprop	128	0.01	0.94	0.93	0.94
RMSprop	128	0.001	0.93	0.89	0.93
RMSprop	128	0.0001	0.94	0.92	0.94
RMSprop	128	Schedule	0.90	0.81	0.89

จากตาราง 14 จะเห็นว่าเมื่อใช้ EfficientNetB5 ร่วมกับ RMSprop Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงที่สุดคือ เมื่อใช้ Batch size เท่ากับ 128 และเลือกใช้ Learning Rate 0.01 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.94, 0.93 และ 0.94 ตามลำดับ

#### 4.3 ผลการทดลองเมื่อใช้ EfficientNetB5 with Adam แสดงในตาราง 15

ตาราง 15 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ EfficientNetB5 ร่วมกับ Adam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Adam	16	0.01	0.93	0.93	0.93
Adam	16	0.001	0.92	0.86	0.91
Adam	16	0.0001	0.94	0.92	0.94
Adam	16	Schedule	0.89	0.81	0.88
Adam	32	0.01	0.93	0.92	0.93
Adam	32	0.001	0.94	0.91	0.93



ตาราง 15 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ EfficientNetB5 ร่วมกับ Adam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Adam	32	0.0001	0.93	0.91	0.92
Adam	32	Schedule	0.90	0.84	0.90
Adam	64	0.01	0.94	0.94	0.94
Adam	64	0.001	0.93	0.92	0.93
Adam	64	0.0001	0.94	0.93	0.94
Adam	64	Schedule	0.92	0.90	0.92
Adam	128	0.01	0.94	0.92	0.94
Adam	128	0.001	0.93	0.92	0.93
Adam	128	0.0001	0.93	0.92	0.93
Adam	128	Schedule	0.92	0.92	0.92

จากตาราง 15 จะเห็นว่าเมื่อใช้ EfficientNetB5 ร่วมกับ Adam Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงที่สุดคือ เมื่อใช้ Batch size เท่ากับ 64 และเลือกใช้ Learning Rate 0.01 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.94, 0.94 และ 0.94 ตามลำดับ

#### 4.4 ผลการทดลองเมื่อใช้ EfficientNetB5 with Nadam แสดงในตาราง 16

ตาราง 16 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ EfficientNetB5 ร่วมกับ Nadam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Nadam	16	0.01	0.93	0.92	0.93
Nadam	16	0.001	0.93	0.90	0.93
Nadam	16	0.0001	0.93	0.91	0.93
Nadam	16	Schedule	0.88	0.84	0.88
Nadam	32	0.01	0.93	0.93	0.93
Nadam	32	0.001	0.92	0.89	0.92
Nadam	32	0.0001	0.93	0.93	0.93

ตาราง 16 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ EfficientNetB5 ร่วมกับ Nadam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Nadam	32	Schedule	0.91	0.87	0.90
Nadam	64	0.01	0.92	0.93	0.92
Nadam	64	0.001	0.93	0.90	0.93
Nadam	64	0.0001	0.92	0.92	0.92
Nadam	64	Schedule	0.91	0.89	0.91
Nadam	128	0.01	0.93	0.93	0.93
Nadam	128	0.001	0.93	0.91	0.93
Nadam	128	0.0001	0.94	0.92	0.94
Nadam	128	Schedule	0.93	0.91	0.93

จากตาราง 16 จะเห็นว่าเมื่อใช้ EfficientNetB5 ร่วมกับ Nadam Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงที่สุดคือ เมื่อใช้ Batch size เท่ากับ 32 และเลือกใช้ Learning Rate 0.01 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.93, 0.93 และ 0.93 ตามลำดับ

### 5. InceptionResNetV2 Architecture

ในการศึกษาค้นคว้าครั้งนี้ได้ทำการฝึกสอนโมเดลโดยใช้การเรียนรู้แบบถ่ายทอด InceptionResNetV2 with Pretrained ImageNet Weight โดยทำการฝึกสอนทั้งหมด 64 โมเดล

#### 5.1 ผลการทดลองเมื่อใช้ InceptionResNetV2 with SGD แสดงในตาราง 17

ตาราง 17 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ InceptionResNetV2 ร่วมกับ SGD Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
SGD	16	0.01	0.91	0.88	0.91
SGD	16	0.001	0.91	0.89	0.91
SGD	16	0.0001	0.90	0.86	0.90
SGD	16	Schedule	0.90	0.85	0.90
SGD	32	0.01	0.91	0.90	0.91

ตาราง 17 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ InceptionResNetV2 ร่วมกับ SGD Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
SGD	32	0.001	0.91	0.90	0.91
SGD	32	0.0001	0.88	0.92	0.89
SGD	32	Schedule	0.91	0.87	0.91
SGD	64	0.01	0.93	0.93	0.93
SGD	64	0.001	0.93	0.93	0.93
SGD	64	0.0001	0.88	0.84	0.87
SGD	64	Schedule	0.91	0.87	0.90
SGD	128	0.01	0.91	0.91	0.91
SGD	128	0.001	0.91	0.90	0.91
SGD	128	0.0001	0.87	0.88	0.87
SGD	128	Schedule	0.91	0.90	0.91

จากตาราง 17 จะเห็นว่าเมื่อใช้ InceptionResNetV2 ร่วมกับ SGD Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงที่สุดคือ เมื่อใช้ Batch size เท่ากับ 64 และเลือกใช้ Learning Rate 0.01 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.93, 0.93 และ 0.93 ตามลำดับ

## 5.2 การทดลองเมื่อใช้ InceptionResNetV2 with RMSprop แสดงในตาราง 18

ตาราง 18 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ InceptionResNetV2 ร่วมกับ RMSprop Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
RMSprop	16	0.01	0.84	0.87	0.84
RMSprop	16	0.001	0.86	0.74	0.84
RMSprop	16	0.0001	0.90	0.86	0.90
RMSprop	16	Schedule	0.90	0.92	0.90
RMSprop	32	0.01	0.50	1.00	0.67
RMSprop	32	0.001	0.90	0.84	0.90

ตาราง 18 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ InceptionResNetV2 ร่วมกับ RMSprop Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
RMSprop	32	0.0001	0.90	0.92	0.91
RMSprop	32	Schedule	0.91	0.87	0.91
RMSprop	64	0.01	0.50	0.00	Error
RMSprop	64	0.001	0.90	0.82	0.89
RMSprop	64	0.0001	0.90	0.84	0.89
RMSprop	64	Schedule	0.92	0.89	0.92
RMSprop	128	0.01	0.91	0.87	0.91
RMSprop	128	0.001	0.92	0.90	0.92
RMSprop	128	0.0001	0.90	0.86	0.90
RMSprop	128	Schedule	0.92	0.90	0.91

จากตาราง 18 จะเห็นว่าเมื่อใช้ InceptionResNetV2 ร่วมกับ RMSprop Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงที่สุดคือ เมื่อใช้ Batch size เท่ากับ 16 และเลือกใช้ Schedule Learning Rate 0.01 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.90, 0.92 และ 0.90 ตามลำดับ

### 5.3 ผลการทดลองเมื่อใช้ InceptionResNetV2 with Adam แสดงในตาราง 19

ตาราง 19 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ InceptionResNetV2 ร่วมกับ Adam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Adam	16	0.01	0.85	0.88	0.86
Adam	16	0.001	0.91	0.87	0.91
Adam	16	0.0001	0.91	0.87	0.91
Adam	16	Schedule	0.91	0.87	0.90

ตาราง 19 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ InceptionResNetV2 ร่วมกับ Adam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Adam	32	0.01	0.90	0.89	0.90
Adam	32	0.001	0.90	0.85	0.89
Adam	32	0.0001	0.91	0.88	0.91
Adam	32	Schedule	0.91	0.89	0.91
Adam	64	0.01	0.91	0.89	0.91
Adam	64	0.001	0.90	0.84	0.89
Adam	64	0.0001	0.91	0.89	0.91
Adam	64	Schedule	0.91	0.90	0.91
Adam	128	0.01	0.50	0.00	0.01
Adam	128	0.001	0.90	0.86	0.90
Adam	128	0.0001	0.91	0.88	0.91
Adam	128	Schedule	0.90	0.86	0.90

จากตาราง 19 จะเห็นว่าเมื่อใช้ InceptionResNetV2 ร่วมกับ Adam Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงสุดคือ เมื่อใช้ Batch size เท่ากับ 64 และเลือกใช้ Schedule Learning Rate ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.91, 0.90 และ 0.91 ตามลำดับ

#### 5.4 การทดลองเมื่อใช้ InceptionResNetV2 with Nadam แสดงในตาราง 20

ตาราง 20 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ InceptionResNetV2 ร่วมกับ Nadam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Nadam	16	0.01	0.87	0.87	0.87
Nadam	16	0.001	0.91	0.90	0.91
Nadam	16	0.0001	0.91	0.87	0.90
Nadam	16	Schedule	0.90	0.88	0.90
Nadam	32	0.01	0.90	0.87	0.89

ตาราง 20 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ InceptionResNetV2 ร่วมกับ Nadam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Nadam	32	0.001	0.91	0.88	0.91
Nadam	32	0.0001	0.92	0.90	0.92
Nadam	32	Schedule	0.91	0.88	0.91
Nadam	64	0.01	0.90	0.87	0.90
Nadam	64	0.001	0.90	0.91	0.90
Nadam	64	0.0001	0.89	0.88	0.89
Nadam	64	Schedule	0.91	0.87	0.91
Nadam	128	0.01	0.90	0.87	0.90
Nadam	128	0.001	0.91	0.87	0.91
Nadam	128	0.0001	0.90	0.84	0.89
Nadam	128	Schedule	0.91	0.88	0.91

จากตาราง 20 จะเห็นว่าเมื่อใช้ InceptionResNetV2 ร่วมกับ Nadam Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงที่สุดคือ เมื่อใช้ Batch size เท่ากับ 64 และเลือกให้ Learning Rate 0.001 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.90, 0.91 และ 0.90 ตามลำดับ

## 6. Xception Architecture

ในการศึกษาครั้งนี้ได้ทำการฝึกสอนโมเดลโดยใช้การเรียนรู้แบบถ่ายทอด Xception with Pretrained ImageNet Weight โดยทำการฝึกสอนทั้งหมด 64 โมเดล

### 6.1 ผลการทดลองเมื่อใช้ Xception with SGD แสดงในตาราง 21

ตาราง 21 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ Xception ร่วมกับ SGD Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
SGD	16	0.01	0.90	0.88	0.90
SGD	16	0.001	0.90	0.92	0.91



ตาราง 21 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ Xception ร่วมกับ SGD Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
SGD	16	0.0001	0.90	0.88	0.90
SGD	16	Schedule	0.91	0.89	0.91
SGD	32	0.01	0.91	0.91	0.91
SGD	32	0.001	0.89	0.83	0.89
SGD	32	0.0001	0.89	0.89	0.89
SGD	32	Schedule	0.90	0.89	0.90
SGD	64	0.01	0.90	0.87	0.90
SGD	64	0.001	0.88	0.81	0.87
SGD	64	0.0001	0.88	0.85	0.88
SGD	64	Schedule	0.89	0.84	0.89
SGD	128	0.01	0.91	0.92	0.91
SGD	128	0.001	0.90	0.91	0.90
SGD	128	0.0001	0.86	0.89	0.87
SGD	128	Schedule	0.91	0.90	0.91

จากตาราง 21 จะเห็นว่าเมื่อใช้ Xception ร่วมกับ SGD Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงที่สุดคือ เมื่อใช้ Batch size เท่ากับ 128 และเลือกใช้ Learning Rate 0.01 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.91, 0.92 และ 0.91 ตามลำดับ

## 6.2 ผลการทดลองเมื่อใช้ Xception with RMSprop แสดงในตาราง 22

ตาราง 22 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ Xception ร่วมกับ RMSprop Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
RMSprop	16	0.01	0.88	0.88	0.88
RMSprop	16	0.001	0.90	0.87	0.90
RMSprop	16	0.0001	0.89	0.83	0.88

ตาราง 22 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ Xception ร่วมกับ RMSprop Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
RMSprop	16	Schedule	0.91	0.90	0.91
RMSprop	32	0.01	0.89	0.85	0.88
RMSprop	32	0.001	0.90	0.93	0.91
RMSprop	32	0.0001	0.89	0.95	0.90
RMSprop	32	Schedule	0.91	0.92	0.91
RMSprop	64	0.01	0.90	0.88	0.90
RMSprop	64	0.001	0.91	0.93	0.92
RMSprop	64	0.0001	0.91	0.92	0.91
RMSprop	64	Schedule	0.90	0.90	0.90
RMSprop	128	0.01	0.90	0.90	0.90
RMSprop	128	0.001	0.91	0.89	0.91
RMSprop	128	0.0001	0.90	0.89	0.90
RMSprop	128	Schedule	0.89	0.83	0.88

จากตาราง 22 จะเห็นว่าเมื่อใช้ Xception ร่วมกับ RMSprop Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงสุดคือ เมื่อใช้ Batch size เท่ากับ 32 และเลือกใช้ Learning Rate 0.001 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.90, 0.93 และ 0.91 ตามลำดับ

### 6.3 ผลการทดลองเมื่อใช้ Xception with Adam แสดงในตาราง 23

ตาราง 23 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ Xception ร่วมกับ Adam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Adam	16	0.01	0.86	0.85	0.86
Adam	16	0.001	0.90	0.89	0.90
Adam	16	0.0001	0.91	0.89	0.91
Adam	16	Schedule	0.90	0.88	0.90

ตาราง 23 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ Xception ร่วมกับ Adam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Adam	32	0.01	0.50	0.00	Error
Adam	32	0.001	0.90	0.84	0.89
Adam	32	0.0001	0.91	0.88	0.91
Adam	32	Schedule	0.90	0.85	0.90
Adam	64	0.01	0.90	0.87	0.90
Adam	64	0.001	0.90	0.89	0.90
Adam	64	0.0001	0.91	0.89	0.90
Adam	64	Schedule	0.90	0.90	0.90
Adam	128	0.01	0.90	0.89	0.90
Adam	128	0.001	0.90	0.91	0.90
Adam	128	0.0001	0.91	0.91	0.91
Adam	128	Schedule	0.91	0.91	0.91

จากตาราง 23 จะเห็นว่าเมื่อใช้ Xception ร่วมกับ Adam Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงสุดคือ เมื่อใช้ Batch size เท่ากับ 128 และเลือกใช้ Learning Rate 0.0001 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.91, 0.91 และ 0.91 ตามลำดับ

#### 6.4 ผลการทดลองเมื่อใช้ Xception with Nadam แสดงในตาราง 24

ตาราง 24 แสดงประสิทธิภาพเมื่อใช้ตัวแบบ Xception ร่วมกับ Nadam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Nadam	16	0.01	0.84	0.84	0.84
Nadam	16	0.001	0.91	0.91	0.91
Nadam	16	0.0001	0.91	0.89	0.91
Nadam	16	Schedule	0.91	0.91	0.91

ตาราง 24 (ต่อ) แสดงประสิทธิภาพเมื่อใช้ตัวแบบ Xception ร่วมกับ Nadam Optimizer

Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
Nadam	32	0.01	0.89	0.88	0.89
Nadam	32	0.001	0.90	0.92	0.90
Nadam	32	0.0001	0.90	0.93	0.90
Nadam	32	Schedule	0.91	0.89	0.91
Nadam	64	0.01	0.90	0.90	0.90
Nadam	64	0.001	0.90	0.85	0.89
Nadam	64	0.0001	0.90	0.87	0.90
Nadam	64	Schedule	0.91	0.90	0.91
Nadam	128	0.01	0.91	0.90	0.91
Nadam	128	0.001	0.90	0.88	0.90
Nadam	128	0.0001	0.90	0.88	0.90
Nadam	128	Schedule	0.89	0.82	0.88

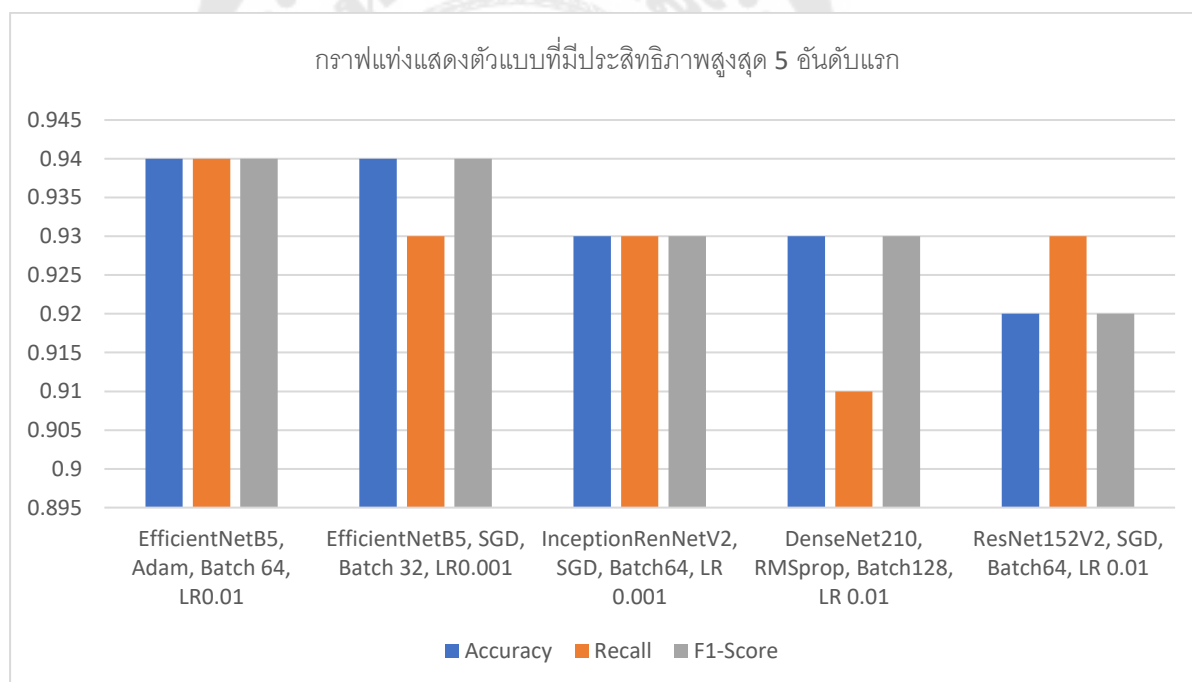
จากตาราง 24 จะเห็นว่าเมื่อใช้ Xception ร่วมกับ Nadam Optimizer ตัวแบบที่ให้ประสิทธิภาพสูงสุดคือ เมื่อใช้ Batch size เท่ากับ 32 และเลือกใช้ Learning Rate 0.0001 ซึ่งจะให้ Accuracy, Recall และ F1-Score ที่ 0.90, 0.93 และ 0.90 ตามลำดับ

เมื่อนำผลการทดลองทั้งหมดมาพิจารณาจะพบว่าประสิทธิภาพของตัวแบบมีแนวโน้มที่จะเพิ่มมากขึ้นเมื่อความซับซ้อนของตัวแบบเพิ่มมากขึ้น ตัวอย่างเช่น ตัวแบบที่ได้จาก EfficientNetB5 มักจะประสิทธิภาพสูงกว่าตัวแบบที่ได้จาก VGG-16 นอกจากนั้นเมื่อพิจารณาในกลุ่มที่ใช้ตัวแบบชนิดเดียวกันแต่ใช้ Optimizer คนละชนิดกันจะพบว่าประสิทธิภาพของตัวแบบที่ได้มีความใกล้เคียงกัน เมื่อนำผลการทดลองทั้งหมดมาสรุปและจัดอันดับโมเดลที่มีประสิทธิภาพสูงสุด 5 ลำดับแรก แสดงได้ดังนี้

ตาราง 25 แสดงตัวแบบที่มีประสิทธิภาพสูงสุด 5 อันดับแรก

Architecture	Optimizer	Batch Size	Learning Rate	Accuracy	Recall	F1-Score
EfficientNetB5	Adam	64	0.01	0.94	0.94	0.94
EfficientNetB5	SGD	32	0.001	0.94	0.93	0.94
InceptionResNetV2	SGD	64	0.001	0.93	0.93	0.93
DenseNet201	RMSprop	128	0.01	0.93	0.91	0.93
ResNet152V2	SGD	64	0.01	0.92	0.93	0.92

จากตาราง 25 จะเห็นได้ว่าโมเดลที่มีประสิทธิภาพในการทำนายมะเร็งผิวหนังชนิดเมลาโนมาจากภาพเดอริโมสโคปิก คือ EfficientNetB5 with Adam, Batch Size 64, Learning Rate 0.01 โดยให้ค่า Accuracy, Recall, และ F1-Score เท่ากันที่ 0.94



ภาพประกอบ 39 ภาพแสดงแผนภูมิแท่งแสดงประสิทธิภาพของตัวแบบสูงสุด 5 ลำดับแรก

ภาพประกอบ 39 แสดงประสิทธิภาพของตัวแบบสูงสุด 5 ลำดับแรก โดยจะพบว่าค่า Recall ของตัวแบบทั้ง 5 มีความใกล้เคียงกันอยู่ในช่วง 0.91-0.94 และค่า F1-Score อยู่ในช่วง 0.92-0.94 ซึ่งหมายความว่าเมื่อพิจารณากลุ่มที่เป็นรอยโรคของมะเร็งผิวหนังชนิดเมลาโนมาทั้งหมดตัวแบบสามารถทำนายรอยโรคได้ถูกต้องประมาณ 91%-94%

## บทที่ 5

### สรุปผลการศึกษา

#### 5.1 สรุปและอภิปรายผลการศึกษา


มะเร็งผิวหนังชนิดเมลาโนมาเป็นมะเร็งผิวหนังชนิดที่พบได้เพียง 1% ของจำนวนผู้ป่วยมะเร็งผิวหนังทั้งหมด อย่างไรก็ตามมะเร็งผิวหนังชนิดนี้กลับมีอัตราการเสียชีวิตสูงที่สุดในบรรดามะเร็งผิวหนังทั้งหมด โดยหากมะเร็งผิวหนังชนิดนี้ยังไม่เข้าสู่ระยะแพร่กระจายสามารถทำการรักษาให้หายขาดได้ แต่หากมะเร็งผิวหนังชนิดนี้เข้าสู่ระยะแพร่กระจายไปแล้ว โอกาสรักษาให้หายขาดนั้นมีค่อนข้างน้อย อีกทั้งผู้ป่วยยังต้องทุกข์ทรมานจากผลข้างเคียงของการรักษาไม่ว่าจะเป็นการผ่าตัด การให้เคมีบำบัดหรือการฉายแสงและนำไปสู่การสูญเสียชีวิตในท้ายที่สุด นอกจากนี้ตามการคาดการณ์ขององค์การอนามัยโลกพบว่า มะเร็งผิวหนังจะกลายเป็นปัญหาที่สำคัญของระบบสาธารณสุขทั่วโลกในเวลาไม่กี่ปีข้างหน้า ทำให้การวินิจฉัยมะเร็งผิวหนังชนิดนี้ให้ได้ตั้งแต่ในระยะที่ยังไม่มีการแพร่กระจายกลายเป็นปัจจัยที่สำคัญที่สุดในการวินิจฉัยและรักษามะเร็งผิวหนังชนิดนี้ อย่างไรก็ตามพบว่าด้วยปริมาณแพทย์ที่ไม่เพียงพอในปัจจุบัน รวมถึงการคัดกรองรอยโรคที่ผิวหนังในปัจจุบันยังอาศัยการมองด้วยตาเปล่า ทำให้การวินิจฉัยเป็นเรื่องยากลำบาก และอาจต้องสิ้นเปลืองค่าใช้จ่ายของผู้ป่วยเนื่องจากการต้องส่งผู้ป่วยพบแพทย์เฉพาะทางด้วยผิวหนังเพื่อให้การวินิจฉัยที่ถูกต้อง

งานวิจัยนี้มุ่งเน้นการสร้างแบบจำลองเพื่อใช้ในการสร้างเครื่องมือในการคัดกรองรอยโรคบริเวณผิวหนังของผู้ป่วยอย่างมีประสิทธิภาพ โดยพยายามแก้ไขปัญหา Imbalanced Data ที่พบในงานวิจัยก่อนหน้าโดยการนำข้อมูลมาสร้างแบบจำลองจากหลายแหล่งข้อมูลได้แก่ ISIC Archive, 7-Point Criteria evaluation database, PH2 Dataset และ ISIC Challenge 2020 โดยได้ทำการรวบรวมข้อมูลที่เป็นรูปภาพเดอริมอสโคปิก (Dermoscopic Image) ทั้งหมดจำนวน 13,968 ภาพ แบ่งออกเป็น Melanoma Classes หรือกลุ่มที่เป็นภาพของมะเร็งผิวหนังชนิดเมลาโนมา จำนวน 6,993 ภาพ และ Benign Class หรือกลุ่มที่เป็นภาพที่ไม่ใช่มะเร็งผิวหนัง จำนวน 6,993 ภาพ จากนั้นทำการแบ่ง ข้อมูลที่ได้ออกเป็น Train Set, Test Set และ Validation Set ในอัตราส่วน 80,10,10 ตามลำดับ กล่าวโดยสรุปจะได้ข้อมูลในแต่ละคลาสประกอบด้วย Train Set จำนวน 5,995 ภาพ, Test Set จำนวน 699 ภาพ และ Validation Set จำนวน 699 ภาพ หลังจากนั้นทำการปรับขนาดรูปภาพเป็นขนาด 225\*225 pixels และใช้ Augmentation technique เพิ่มปริมาณความหลากหลายของรูปภาพ แล้วจึงทำการฝึกสอนแบบจำลองโดยใช้เทคนิคการเรียนรู้แบบถ่ายทอด (Transfer Learning) โดยในการศึกษาค้นคว้าครั้งนี้ใช้โครงสร้างตัวแบบทั้งสิ้น 6 ชนิด ได้แก่



VGG16, DenseNet201, ResNet152V2, EfficientNetB5, InceptionResNetV2, และ Xception ร่วมกับการปรับตั้งค่าพารามิเตอร์ทั้งสิ้น 3 ชนิด คือ Optimizer, Learning Rate, และ Batch Size ทำให้มีการฝึกสอยตัวแบบทั้งสิ้น 384 ตัวแบบ และทำการทดสอบกับชุดข้อมูล Test Set

เมื่อพิจารณาจากผลการวิจัยทั้งหมดพบว่า ตัวแบบที่มีประสิทธิภาพในการคัดกรองมะเร็งผิวหนังชนิดเมลาโนมาสูงที่สุดคือตัวแบบที่ใช้โครงสร้างของ EfficientNetB5 ร่วมกับ Adam Optimization โดยใช้ Batch Size, Learning Rate เท่ากับ 64 และ 0.01 ตามลำดับ โดยตัวแบบดังกล่าวให้ค่า Accuracy, Recall, และ F1-Score เท่ากันที่ 0.94



ภาพประกอบ 40 ภาพแสดง Confusion Matrix ของตัวแบบที่ให้ประสิทธิภาพสูงที่สุด

	precision	recall	f1-score	support
0	0.94	0.93	0.94	699
1	0.93	0.94	0.94	699
accuracy			0.94	1398
macro avg	0.94	0.94	0.94	1398
weighted avg	0.94	0.94	0.94	1398


ภาพประกอบ 41 ภาพแสดง Classification Report ของตัวแบบที่ให้ประสิทธิภาพสูงที่สุด

จากภาพแสดง Confusion Matrix(ภาพประกอบ 40) และ Classification Report (ภาพประกอบ 41) สำหรับโมเดลที่มีประสิทธิภาพสูงที่สุดในการศึกษาคั้งนี้ แสดงให้เห็นว่าโมเดลมีประสิทธิภาพในการตรวจจจับ Melanoma class ได้ถูกต้อง 655 ภาพจากทั้งหมด 699 ภาพ คิด

เป็น 94% โดยเมื่อพิจารณาในกลุ่ม Positive Predictions หรือกลุ่มที่โมเดลทำนายว่าเป็น Melanoma class ทั้งหมด 701 ภาพ พบว่าโมเดลสามารถทำนาย Positive Class ได้ถูกต้องทั้งสิ้น 655 ภาพ คิดเป็น 93.44% ของกลุ่ม Positive Prediction ทั้งหมด

เมื่อพิจารณาผลการศึกษาร่วมกับตัวแบบที่นำมาใช้ฝึกสอนพบว่า ยิ่งตัวแบบที่นำมาใช้ในการฝึกสอนมีความซับซ้อนมากยิ่งขึ้น ประสิทธิภาพของตัวแบบที่ได้ยิ่งมีประสิทธิภาพตามไปด้วย แต่ต้องแลกมากับเวลาที่ใช้ในการฝึกสอนโมเดลที่มากยิ่งขึ้น อย่างไรก็ตามเนื่องจากการศึกษานี้เป็นการศึกษาที่เกี่ยวข้องกับชีวิตของมนุษย์ เช่น หากตัวแบบทำนายผิดพลาดจากรอยโรคที่เป็นมะเร็งกลับทำนายว่าไม่ใช่รอยโรคของมะเร็ง สิ่งที่เกิดตามมาคือการเสียชีวิต ดังนั้นการยอมสูญเสียเวลาในการฝึกสอนตัวแบบเพื่อให้ได้ตัวแบบที่มีประสิทธิภาพสูงที่สุดจึงเป็นสิ่งที่ยอมรับได้ในการศึกษาครั้งนี้

การเรียนรู้เชิงลึกหรือ Deep Learning เป็นเหมือนกล่องดำในการที่จะรู้ว่าเพราะเหตุใดหรือพื้นที่ใดที่ทำให้ตัวแบบตัดสินใจทำนายด้วยคำตอบดังกล่าว ซึ่งเป็นสิ่งที่ยอมรับได้ยากในทางการแพทย์ เพราะเมื่อแพทย์ต้องตัดสินใจอย่างใดอย่างหนึ่ง เป็นการตัดสินใจบนชีวิตของมนุษย์ อาจเป็นเรื่องยากที่จะตัดสินใจหากไม่มีเหตุผลสนับสนุนที่เพียงพอว่าเหตุใดตัวแบบจึงตัดสินใจเช่นนั้น ผู้วิจัยจึงได้นำ Grad-Cam Visualization เข้ามาช่วยในการแสดงพื้นที่ที่ตัวแบบให้ความสนใจและใช้ในการทำนายผลเพื่อช่วยเพิ่มความมั่นใจว่าการทำนายดังกล่าวอยู่บนพื้นฐานของรอยโรคที่ผิวหนังจริง ไม่ได้เกิดจากการทำนายบนพื้นที่ที่เป็นผิวหนังปกติดังตัวอย่างภาพประกอบ 42



ภาพประกอบ 42 รูปภาพเปรียบเทียบ ภาพต้นฉบับรอยโรคที่เป็นมะเร็ง(ซ้าย) และภาพที่ใช้ Grad-Cam Visualization(ขวา)

นอกจากนี้เมื่อพิจารณารูปภาพที่นำมาใช้ในการศึกษาครั้งนี้พบว่า มีรูปภาพส่วนหนึ่งที่มีสัญญาณรบกวนอยู่ในรูปภาพ เช่น รอยปากกา เส้นผม หรือเส้นขน ผู้วิจัยคาดว่าสัญญาณรบกวน

ดังกล่าวน่าจะมีผลกระทบต่อประสิทธิภาพของตัวแบบที่ได้ โดยอาจทำให้ประสิทธิภาพของตัวแบบลดลงเนื่องจากตัวแบบให้ความสำคัญกับสัญญาณรบกวนดังกล่าว อย่างไรก็ตามเมื่อพิจารณาผลการศึกษานำเสนอไปแล้วนั้นพบว่า แม้ว่ารูปภาพจะมีสัญญาณรบกวนอยู่ ตัวแบบก็ยังคงสามารถทำนายรอยโรคที่มีโอกาสเป็นมะเร็งผิวหนังชนิดเมลานินมาได้ถูกต้องเป็นส่วนใหญ่

เมื่อเปรียบเทียบประสิทธิภาพของตัวแบบที่ได้จากการศึกษาในครั้งนี้กับประสิทธิภาพของตัวแบบจากงานวิจัยที่ผ่านมาในอดีตแสดงได้ดังตารางต่อไปนี้

ตาราง 26 ตารางเปรียบเทียบประสิทธิภาพของตัวแบบกับงานวิจัยที่ผ่านมาในอดีต

Reference	Method	Dataset	Accuracy	Sensitivity
Esteva A, 2017[53]	InceptionV3	2,032 diseases 129,450 Images	72.1%	-
Khan M, 2019[32]	SVM	Melanoma 146 Images Nevus 251 Images	96%	97%
Zia Ur Rehman M, 2022[39]	DenseNet201	Malignant 1,497 Images Benign 1,800 Images	91.68%	91.09%
Tahir M, 2023[40]	DCC_Net	BCC 510 Images, MEL 1,686 Images, MN 2,007 Images, SCC 97 Images	94.17%	94.28%
Qasim G., 2023[43]	Spiking VGG-13	Melanoma 3,670 Images Non-Melanoma 3,323 Image	90%	89%
Keerthana D, 2023[45]	CNN with SVM	Melanoma 243 Images Non-Melanoma 490 Image	88.02%	98.54%
Proposed Model	EfficientNetB5	Melanoma 6,993 Images Benign 6,993 Images	94%	94%


AKLEC: Actinic Keratosis, BCC: Basal Cell Carcinoma, BKL: Benign Keratosis, DF: Dermatofibroma, NV: Melanocytic Nevi, Mel: Melanoma, VASC: Vascular Skin Lesions

จากตารางที่ 26 จะเห็นได้ว่าเมื่อเปรียบเทียบกับการศึกษาในอดีตในการศึกษานี้มีการแก้ปัญหา Imbalanced Data และจำนวนข้อมูลที่มีไม่เพียงพอด้วยการรวบรวมข้อมูลจากหลายแหล่งข้อมูล เมื่อสร้างตัวแบบและทำการทดสอบตัวแบบพบว่าตัวแบบที่ได้มีประสิทธิภาพดีกว่าการศึกษาในอดีต อย่างไรก็ตามมีบางการศึกษาที่ตัวแบบที่ได้ในครั้งนี้มีประสิทธิภาพต่ำกว่า อย่างไรก็ตามจำเป็นจะต้องคำนึงถึงจำนวนข้อมูลที่นำมาฝึกสอนตัวแบบ และจำนวนข้อมูลที่นำมาใช้ทดสอบด้วย ซึ่งจะพบว่าในกลุ่มที่ตัวแบบมีประสิทธิภาพสูงกว่าประสิทธิภาพของตัวแบบที่ได้จากการศึกษาครั้งนี้ พบว่าทั้งหมดมีจำนวนข้อมูลที่นำมาใช้น้อยกว่า นอกจากนี้ชุดข้อมูลที่นำมาใช้ยังคงมีปัญหา Imbalanced Data อีกด้วย

## 5.2 ข้อเสนอแนะและการศึกษาในอนาคต

5.2.1 ข้อมูลที่นำมาใช้ในการศึกษานี้ทั้งหมดเป็นภาพของชาวยุโรปหรืออเมริกาที่มีผิวขาว จึงอาจทำให้ตัวแบบที่ได้ไม่มีความสามารถในการคัดกรองมะเร็งในชาวเอเชียหรือแอฟริกา ซึ่งมีสีผิวโทนสีเหลืองไปจนถึงคล้ำ ในอนาคตหากมีข้อมูลที่มีความหลากหลายด้านเชื้อชาติและสีผิวมากขึ้น คาดว่าจะได้ตัวแบบที่มีประสิทธิภาพมากยิ่งขึ้น

5.2.2 ข้อมูลที่นำมาใช้ในครั้งนี้บางรูปภาพมีลักษณะของสิ่งรบกวนอยู่ในรูปภาพ เช่น มาร์กเกอร์ เส้นผม เส้นขน รอยปากกาดังแสดงในภาพประกอบ 43 ซึ่งอาจจะส่งผลกระทบต่อประสิทธิภาพของตัวแบบได้ ในอนาคตควรวางวิธีในการจัดการสัญญาณรบกวนเหล่านี้ ก่อนทำการฝึกสอนตัวแบบน่าจะสามารถเพิ่มประสิทธิภาพของตัวแบบได้



ภาพประกอบ 43 ภาพแสดงสัญญาณรบกวนในภาพถ่ายเดอร์โมสโคปิก

5.2.3 ข้อมูลที่นำมาใช้ในครั้งนี้บางรูปภาพ ความแตกต่างระหว่างรอยโรคที่ผิวหนังและผิวหนังปกติมีความคล้ายคลึงกันมากทำให้บางครั้งตัวแบบทำการทำนายบนพื้นที่ที่เป็นผิวปกติ ส่งผลต่อประสิทธิภาพของโมเดล ในอนาคตหากมีการทำ Segmentation เฉพาะส่วนขอรอยโรค ก่อนที่จะทำการฝึกสอนตัวแบบน่าจะช่วยลดปัญหาการทำนายบนพื้นที่ที่เป็นผิวหนังปกติได้

## บรรณานุกรม

- [1] M. Arnold *et al.*, "Global Burden of Cutaneous Melanoma in 2020 and Projections to 2040," *JAMA Dermatology*, vol. 158, no. 5, pp. 495-503, 2022/5// 2022, doi: 10.1001/jamadermatol.2022.0160.
- [2] A. Oakley, "Superficial spreading melanoma," in *DermNet*, ed, 2021.
- [3] A. Oakley, "Nodular melanoma," in *DermNet*, ed, 2011.
- [4] A. Oakley, "Lentigo maligna and lentigo maligna melanoma," in *DermNet*, ed, 2011.
- [5] C. Mahon, A. Oakley, and I. Coulson, "Acral lentiginous melanoma," in *DermNet*, ed, 2023.
- [6] M. Ramezani, A. Karimian, and P. Moallem, "Automatic Detection of Malignant Melanoma using Macroscopic Images," *Journal of medical signals and sensors*, vol. 4, no. 4, pp. 281-90, 2014/10// 2014.
- [7] Kausalya, "Melanoma skin cancer: Symptoms, Causes, & Treatment," in *scientificanimations*, ed, 2020.
- [8] G. Tchernev, V. Malev, J. W. Patterson, and T. Lotti, "A novel surgical margin (1 cm) might be from benefit for patients with dysplastic nevi, thin melanomas, and melanoma in situ: Analysis based on clinical cases," *Dermatologic Therapy*, vol. 33, no. 2, 2020/3// 2020, doi: 10.1111/dth.13261.
- [9] P. Kolimi, S. Narala, D. Nyavanandi, A. A. A. Youssef, and N. Dudhipala, "Innovative Treatment Strategies to Accelerate Wound Healing: Trajectory and Recent Advancements," in *Cells* vol. 11, ed: MDPI, 2022.
- [10] K. J. Karen and L. R. Moy, "Basal Cell Carcinoma Risk Factors," in *The Skin Cancer Foundation*, ed, 2019.
- [11] M. Cives *et al.*, "Non-melanoma skin cancers: Biological and clinical features," in *International Journal of Molecular Sciences* vol. 21, ed: MDPI AG, 2020, pp. 1-24.
- [12] E. Hale, "Squamous Cell Carcinoma Warning Signs," in *Hanke, C. William*, ed, 2022.
- [13] S. Angelo and P. Nghiem, "Merkel Cell Carcinoma Overview," in *The Skin Cancer*

*Foundation*, ed, 2022.

- [14] J. Heistein, U. Acharya, and S. K. R. Mukkamalla, "Malignant Melanoma," *StatPearls [Internet]*, 2023/5// 2023.
- [15] D. Rigel, "WHAT TO LOOK FOR: ABCDES OF MELANOMA," in *American Academy of Dermatology Association*, ed.
- [16] C. H. Allan, A. M. Ashfaq, and R. Ofer, "Melanoma Warning Signs," in <https://www.skincancer.org/skin-cancer-information/melanoma/melanoma-warning-signs-and-images/>, ed, 2021.
- [17] A. Halpern, A. Marghoob, and O. Reiter, "Melanoma Stages," in *The Skin Cancer Foundation*, ed, 2022.
- [18] L. Brochez, E. Verhaeghe, L. Bleyen, and J. M. Naeyaert, "Diagnostic ability of general practitioners and dermatologists in discriminating pigmented skin lesions," *Journal of the American Academy of Dermatology*, vol. 44, no. 6, pp. 979-986, 2001, doi: 10.1067/mjd.2001.113442.
- [19] J. Dodson and P. Lio, "Dermoscopy: Past and Present," 2023/1// 2023.
- [20] J. Dinnes *et al.*, "Dermoscopy, with and without visual inspection, for diagnosing melanoma in adults," in *Cochrane Database of Systematic Reviews* vol. 2018, ed: John Wiley and Sons Ltd, 2018.
- [21] A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, 2nd Edition*, 2 ed. CA 95472: O'Reilly Media, Inc., 2023.
- [22] A. Reynolds, "Convolutional Neural Networks (CNNs)," ed, 2019.
- [23] N. Kumar, "Understanding Convolution Neural Networks: CNN— the ELI5 way," in *Towards Data Science*, ed, 2019.
- [24] "Convolutional Neural Network In PyTorch," in *javatpoint*, ed, 2020.
- [25] L. Cun *et al.*, "Handwritten Digit Recognition with a Back-Propagation Network," 1989.
- [26] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Communications of the ACM*, vol. 60, no. 6, pp. 84-90, 2017/5// 2017, doi: 10.1145/3065386.



- [27] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," 2014/9// 2014. [Online]. Available: <http://arxiv.org/abs/1409.1556>.
- [28] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," 2015/12// 2015. [Online]. Available: <http://arxiv.org/abs/1512.03385>.
- [29] M. Tan and Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," 2019/5// 2019. [Online]. Available: <http://arxiv.org/abs/1905.11946>.
- [30] T. Mendonca, P. M. Ferreira, J. S. Marques, A. R. S. Marcal, and J. Rozeira, "PH2 - A dermoscopic image database for research and benchmarking," in *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2013/7// 2013: IEEE, pp. 5437-5440, doi: 10.1109/EMBC.2013.6610779.
- [31] K. M. Hosny, M. A. Kassem, and M. M. Foad, "Skin Cancer Classification using Deep Learning and Transfer Learning," in *2018 9th Cairo International Biomedical Engineering Conference (CIBEC)*, 2018/12// 2018: IEEE, pp. 90-93, doi: 10.1109/CIBEC.2018.8641762.
- [32] M. Q. Khan *et al.*, "Classification of Melanoma and Nevus in Digital Images for Diagnosis of Skin Cancer," *IEEE Access*, vol. 7, pp. 90132-90144, 2019, doi: 10.1109/ACCESS.2019.2926837.
- [33] J. O. Emuoyibofarhe and D. Ajisafe, "Early Skin Cancer Detection Using Deep Convolutional Neural Networks on Mobile Smartphone," *International Journal of Information Engineering and Electronic Business*, vol. 12, no. 2, pp. 21-27, 2020/4// 2020, doi: 10.5815/ijieeb.2020.02.04.
- [34] M. M. Mijwil, "Skin cancer disease images classification using deep learning solutions," *Multimedia Tools and Applications*, vol. 80, no. 17, pp. 26255-26271, 2021/7// 2021, doi: 10.1007/s11042-021-10952-7.
- [35] V. Rotemberg *et al.*, "A patient-centric dataset of images and metadata for identifying melanomas using clinical context," *Scientific Data*, vol. 8, no. 1, pp. 34-

- 34, 2021/1// 2021, doi: 10.1038/s41597-021-00815-z.
- [36] J. Rashid *et al.*, "Skin Cancer Disease Detection Using Transfer Learning Technique," *Applied Sciences*, vol. 12, no. 11, pp. 5714-5714, 2022/6// 2022, doi: 10.3390/app12115714.
- [37] P. Tschandl, C. Rosendahl, and H. Kittler, "The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions," *Scientific Data*, vol. 5, no. 1, pp. 180161-180161, 2018/8// 2018, doi: 10.1038/sdata.2018.161.
- [38] K. Ali, Z. A. Shaikh, A. A. Khan, and A. A. Laghari, "Multiclass skin cancer classification using EfficientNets – a first step towards preventing skin cancer," *Neuroscience Informatics*, vol. 2, no. 4, pp. 100034-100034, 2022/12// 2022, doi: 10.1016/j.neuri.2021.100034.
- [39] M. Zia Ur Rehman, F. Ahmed, S. A. Alsuhibany, S. S. Jamal, M. Zulfiqar Ali, and J. Ahmad, "Classification of Skin Cancer Lesions Using Explainable Deep Learning," *Sensors*, vol. 22, no. 18, pp. 6915-6915, 2022/9// 2022, doi: 10.3390/s22186915.
- [40] M. Tahir, A. Naeem, H. Malik, J. Tanveer, R. A. Naqvi, and S.-W. Lee, "DSCC\_Net: Multi-Classification Deep Learning Models for Diagnosing of Skin Cancer Using Dermoscopic Images," *Cancers*, vol. 15, no. 7, 2023/4// 2023, doi: 10.3390/cancers15072179.
- [41] M. Combalia *et al.*, "BCN20000: Dermoscopic Lesions in the Wild," 2019/8// 2019.
- [42] N. C. F. Codella *et al.*, "Skin Lesion Analysis Toward Melanoma Detection: A Challenge at the 2017 International Symposium on Biomedical Imaging (ISBI), Hosted by the International Skin Imaging Collaboration (ISIC)," 2017/10// 2017.
- [43] S. Qasim Gilani, T. Syed, M. Umair, and O. Marques, "Skin Cancer Classification Using Deep Spiking Neural Network," *Journal of digital imaging*, vol. 36, no. 3, pp. 1137-1147, 2023/6// 2023, doi: 10.1007/s10278-023-00776-2.
- [44] D. Gutman *et al.*, "Skin Lesion Analysis toward Melanoma Detection: A Challenge at the International Symposium on Biomedical Imaging (ISBI) 2016, hosted by the International Skin Imaging Collaboration (ISIC)," 2016/5// 2016.

- [45] D. Keerthana, V. Venugopal, M. K. Nath, and M. Mishra, "Hybrid convolutional neural networks with SVM classifier for classification of skin cancer," *Biomedical Engineering Advances*, vol. 5, pp. 100069-100069, 2023/6// 2023, doi: 10.1016/j.bea.2022.100069.
- [46] J. Kawahara, S. Daneshvar, G. Argenziano, and G. Hamarneh, "Seven-Point Checklist and Skin Lesion Classification Using Multitask Multimodal Neural Nets," *IEEE Journal of Biomedical and Health Informatics*, vol. 23, no. 2, pp. 538-546, 2019/3// 2019, doi: 10.1109/JBHI.2018.2824327.
- [47] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely Connected Convolutional Networks," in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017/7// 2017: IEEE, pp. 2261-2269, doi: 10.1109/CVPR.2017.243.
- [48] K. He, X. Zhang, S. Ren, and J. Sun, "Identity Mappings in Deep Residual Networks," 2016/3// 2016.
- [49] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016/6// 2016: IEEE, pp. 770-778, doi: 10.1109/CVPR.2016.90.
- [50] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. Alemi, "Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning," 2016/2// 2016.
- [51] A. Alemi, "Improving Inception and Image Classification in TensorFlow," in *googleblog*, ed, 2016.
- [52] F. Chollet, "Xception: Deep Learning with Depthwise Separable Convolutions," in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017/7// 2017: IEEE, pp. 1800-1807, doi: 10.1109/CVPR.2017.195.
- [53] K. B. Esteva A, Novoa RA, Ko J, Swetter SM, Blau HM, Thrun S., "Dermatologist-level classification of skin cancer with deep neural networks," *Nature*, pp. 115-118, 2017, doi: 10.1038/nature21056.





ประวัติผู้เขียน

