

การจำแนกระดับความผิดปกติของมะเร็งปากมดลูกจากภาพถ่ายคอลโปสโคป:
กรณีศึกษา โรงพยาบาลจุฬารัตน์ เขตหลักสี่ กรุงเทพมหานคร

CLASSIFICATION OF CERVICAL CANCER SCREENING FROM
COLPOSCOPY IMAGE: A CASE STUDY OF CHULABHORN HOSPITAL,
LAK SI DISTRICT, BANGKOK METROPOLITAN



การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูลและการวิเคราะห์
ศูนย์วิเคราะห์ข้อมูลดิจิทัลอัจฉริยะพระจอมเกล้าลาดกระบัง
คณะวิทยาศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2566

KMITL-2023-SC-M-017-032

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

CLASSIFICATION OF CERVICAL CANCER SCREENING FROM
COLPOSCOPY IMAGE: A CASE STUDY OF CHULABHORN HOSPITAL,
LAK SI DISTRICT, BANGKOK METROPOLITAN



AN INDEPENDENT STUDY SUBMITTED IN PARTIAL FULFILLMENT OF THE
REQUIREMENT FOR THE DEGREE OF MASTER OF SCIENCE
IN DATA SCIENCE AND ANALYTICS
KMUTL DIGITAL ANALYTICS AND INTELLIGENCE CENTER SCHOOL OF SCIENCE
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG
2023
KMUTL-2023-SC-M-017-032

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2023

SCHOOL OF SCIENCE

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อการค้นคว้าอิสระ	การจำแนกระดับความผิดปกติของมะเร็งปากมดลูกจากภาพถ่ายคอลโปสโคป: กรณีศึกษา โรงพยาบาลจุฬารัตน์ เขตหลักสี่ กรุงเทพมหานคร
ชื่อนักศึกษา	นายณัฐศิษฐ์ ลัดหลวง
รหัสประจำตัว	64605042
ปริญญา	วิทยาศาสตรมหาบัณฑิต (วิทยาการข้อมูลและการวิเคราะห์) ศูนย์วิเคราะห์ข้อมูลดิจิทัลอัจฉริยะพระจอมเกล้าลาดกระบัง
พ.ศ.	2566
อาจารย์ที่ปรึกษา	รองศาสตราจารย์ ดร.ละออ บุญเกษม

บทคัดย่อ

การค้นคว้าอิสระนี้ได้นำเสนอการประยุกต์ใช้งานระบบโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network: CNN) เพื่อช่วยในการจำแนกระดับของความผิดปกติของภาพถ่ายคอลโปสโคปที่เป็นรอยโรคของมะเร็งปากมดลูก เพื่อช่วยลดภาระในการคัดกรองของแพทย์พยาธิวิทยาและเพิ่มประสิทธิภาพความถูกต้องในการจำแนกระดับความผิดปกติ โดยใช้สถาปัตยกรรม MobileNetV2, ResNet50 และ VGG16 โดยใช้ภาพถ่ายเยื่อผิวภายในบริเวณปากมดลูก ทั้งหมด 1,500 ภาพต่อชุดในการสร้างตัวแบบ โดยมีการแบ่งชุดข้อมูลภาพถ่ายออกเป็น 4 ชุดตามเทคนิคที่ใช้ในการเพิ่มปริมาณภาพถ่าย ตัวแบบจะถูกทดสอบประสิทธิภาพโดยการใช้มาตรวัด Accuracy, Sensitivity, Specificity, Area Under Curve และ Confusion Matrix สรุปผลการทดลองคือ สถาปัตยกรรม ResNet50 มีประสิทธิภาพสูงสุดในทุกชุดข้อมูลภาพถ่าย โดยตัวแบบสถาปัตยกรรม ResNet50 ที่สร้างจากตัวแบบข้อมูลภาพถ่ายชุดที่ 1 มีผลลัพธ์ที่ดีที่สุดที่ 62.22%

คำสำคัญ : การเรียนรู้เชิงลึก โครงข่ายประสาทเทียมแบบสังวัตนาการ ภาพถ่ายคอลโปสโคป มะเร็งปากมดลูก

Title	Classification of Cervical Cancer Screening from Colposcopy Image: A Case Study of Chulabhorn Hospital, Lak Si District, Bangkok Metropolitan
Student	Nattasit Ladluang
Student ID	64604042
Degree	Master of Science (Data Science and Analytics) KMITL-Digital Analytics and Intelligence Center
Year	2023
Advisor	Assoc.Prof.Dr. Laor Boongasame

Abstract

This research has presents the application of Convolutional Neural Network (CNN) in order to assist in classifying the severity of abnormalities in cervical cancer colposcopy images. The goal is to reduce the burden of screening for pathologists and improve the accuracy of abnormality classification. The MobileNetV2, ResNet50, and VGG16 architectures were utilized, using 1,500 colposcopy images to create the models. The dataset was divided into 4 sets using image augmentation techniques. The models were evaluated using metrics such as Accuracy, Sensitivity, Specificity, Area Under Curve and Confusion Matrix. The experimental results show that the ResNet50 architecture performs the best on all datasets. The ResNet50 model constructed from the 1st dataset achieves the highest result at 62.22%.

Keywords : Cervical Cancer, Colposcopy Images, Convolutional Neural Network, Deep Learning

กิตติกรรมประกาศ

การค้นคว้าอิสระเรื่องการจำแนกระดับความผิดปกติของมะเร็งปากมดลูกจากภาพถ่ายคอลโปสโคป: กรณีศึกษา โรงพยาบาลจุฬารัตน์ เขตหลักสี่ กรุงเทพมหานคร สามารถสำเร็จลุล่วงไปด้วยดี ผู้จัดทำขอขอบพระคุณอาจารย์ที่ปรึกษา รศ.ดร.ละออ บุญเกษม และ ดร.อัคเดช อุดมชัยพร ที่ได้ให้ความรู้ คำชี้แนะ และให้ความช่วยเหลือในการประยุกต์ใช้ความรู้ต่างๆ เพื่อแก้ไขปัญหาที่พบเจอในการจัดทำ การค้นคว้าอิสระฉบับนี้

ขอขอบพระคุณคณาจารย์ผู้ควบคุมการสอบการค้นคว้าอิสระ ผศ.ดร.วรางคณา กัมปาน และ ผศ.ดร.ยุวดี กล่อมวิเศษ ที่ช่วยตรวจสอบ คำชี้แนะและคำแนะนำเพื่อให้การค้นคว้าอิสระฉบับนี้มีความสมบูรณ์

ขอขอบพระคุณโรงพยาบาลจุฬารัตน์ ที่สนับสนุนข้อมูลภาพถ่ายคอลโปสโคปและข้อมูลการวินิจฉัยภาพจากพยาธิแพทย์

ท้ายนี้ ขอขอบพระคุณสถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง และบุคลากรของข้าพเจ้าที่มอบโอกาสทางการศึกษา ซึ่งทำให้ข้าพเจ้าได้รับความรู้และประสบการณ์ที่มีประโยชน์ เพื่อนำไปประยุกต์ใช้ในด้านอื่นๆ ต่อไปในอนาคต

ณัฐศิษฏ์ ลัดหลวง

สารบัญ

หน้า

บทคัดย่อภาษาไทย.....	ก
บทคัดย่อภาษาอังกฤษ.....	ข
กิตติกรรมประกาศ.....	ค
สารบัญตาราง.....	ณ
สารบัญรูป.....	ฉ
บทที่ 1 บทนำ	1
1.1 ความสำคัญและที่มา	1
1.2 วัตถุประสงค์ของงานวิจัย	2
1.3 ขอบเขตการดำเนินงาน	2
1.4 ขั้นตอนการดำเนินงาน	3
1.5 ประโยชน์ที่คาดว่าจะได้รับ	3
1.6 ระยะเวลาดำเนินงาน	4
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	6
2.1 คอลโปสโคปี (Colposcopy)	6
2.2 ระดับของภาวะก่อนมะเร็งปากมดลูก	6
2.3 ระบบโครงข่ายประสาทเทียม (Artificial Neural Network: ANN)	8
2.4 Softmax Function	12
2.5 Rectified Linear Unit Function (ReLU)	13
2.6 การเรียนรู้เชิงลึก (Deep Learning)	13
2.7 ระบบโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network: CNN)	14
2.8 งานวิจัยที่เกี่ยวข้อง.....	17
2.8.1 Multi-Feature Fusion with Convolutional Neural Network for Ship Classification in Optical Images	17

สารบัญ (ต่อ)

หน้า

2.8.2 MSCI: A multistate dataset for colposcopy image classification of cervical cancer screening.....	18
2.8.3 Deep learning based cervical screening by the cross-modal integration of colposcopy, cytology, and HPV test	18
2.8.4 Classification of Cervical Intraepithelial Neoplasia (CIN) using fine-tuned Convolutional Neural Networks	19
2.8.5 MobileNetV2 Ensemble for Cervical Precancerous Lesions Classification. 19	
2.8.6 MDFI: Muli-CNN Decision Feature Integration for Diagnosis of Cervical Precancerous Lesions.....	19
บทที่ 3 วิธีการดำเนินงานวิจัย	21
3.1 ระเบียบวิธีวิจัย.....	21
3.1.1 ศึกษาทฤษฎีที่เกี่ยวข้องและวิธีการจำแนกระดับความผิดปกติของเนื้อเยื่อปากมดลูก	23
3.1.2 การรวบรวมข้อมูลผู้ป่วยตามการอ่านผลโดยพยาธิแพทย์	23
3.1.3 การเตรียมข้อมูลและคัดกรองข้อมูล	23
3.1.4 ทดลองเพิ่มจำนวนข้อมูลด้วยวิธีการพลิกรูปภาพ/ เพิ่มความเข้มของสี/ ขยายภาพ/ ปรับสีเป็นขาวดำ.....	23
3.1.5 ทดลองการจำแนกระดับความผิดปกติของเนื้อเยื่อปากมดลูก กับวิธีการเรียนรู้จากระบบโครงข่ายประสาทเทียม.....	23
3.1.6 ทดลองปรับค่าพารามิเตอร์ที่ใช้ในการสร้างตัวแบบในการจำแนกระดับความผิดปกติของเนื้อเยื่อปากมดลูก	24
3.1.7 ประเมินผลการทดลองการจำแนกระดับความผิดปกติของเนื้อเยื่อปากมดลูก.....	24
3.1.8 วิเคราะห์และสรุปผลการทดลอง	24
3.2 ขั้นตอนวิธีการรวบรวมข้อมูลผู้ป่วย.....	24
3.2.1 การรวบรวมข้อมูลภาพถ่ายเยื่อปากมดลูกภายในบริเวณปากมดลูก	24

สารบัญ (ต่อ)

หน้า

3.2.2	เลือกภาพถ่ายเยื่อหูฝัวภายในบริเวณปากมดลูก	25
3.3	การใช้เทคนิคในการเพิ่มปริมาณภาพถ่าย.....	26
3.4	ขั้นตอนการจำแนกระดับความผิดปกติของเนื้อเยื่อหูฝัว.....	26
3.4.1	เตรียมภาพถ่ายเยื่อหูฝัวภายในบริเวณปากมดลูก.....	27
3.4.1.1	เทคนิคการพลิกรูปภาพ (Flip).....	28
3.4.1.2	เทคนิคการเพิ่มความเข้มของสี (Increase saturation)	29
3.4.1.3	เทคนิคการขยายภาพ (Zoom)	30
3.4.1.4	เทคนิคการปรับรูปภาพสีเป็นรูปภาพสเกลสีเทา (Convert to grayscale)...30	
3.4.1.5	ปรับโครงสร้างการจัดเก็บภาพถ่าย.....	36
3.4.1.5.1	โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 1	36
3.4.1.5.2	โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 2	38
3.4.1.5.3	โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 3	41
3.4.1.5.4	โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 4	43
3.4.1.6	แบ่งชุดข้อมูลเพื่อการสร้างตัวแบบในการทำนาย	46
3.4.2	จัดเตรียมตัวแบบในการจำแนกความผิดปกติของเนื้อเยื่อหูฝัว	47
3.4.3	ทดสอบประสิทธิภาพของตัวแบบที่ได้	53
3.4.4	วิเคราะห์และสรุปผลการทดลอง	53
บทที่ 4	ผลการดำเนินงานและการอภิปรายผล	54
4.1	การทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรมทั้ง 3 แบบ	54
4.1.1	ผลการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม MobileNetV2	54
4.1.2	ผลการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม ResNet50.....	58
4.1.3	ผลการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม VGG16.....	62
4.1.4	การอภิปรายผลการทดลองตัวแบบที่ได้จากข้อมูลภาพถ่ายชุดที่ 1.....	66
4.2	การทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรมทั้ง 3 แบบ	66
4.2.1	ผลการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม MobileNetV2	66

สารบัญ (ต่อ)

หน้า

4.2.2 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม ResNet50.....	70
4.2.3 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม VGG16.....	74
4.2.4 การอภิปรายผลการทดลองตัวแบบที่ได้จากข้อมูลภาพถ่ายชุดที่ 2.....	78
4.3 การทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรมทั้ง 3 แบบ.....	78
4.3.1 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม MobileNetV2	79
4.3.2 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม ResNet50.....	83
4.3.3 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม VGG16.....	87
4.3.4 การอภิปรายผลการทดลองตัวแบบที่ได้จากข้อมูลภาพถ่ายชุดที่ 3.....	91
4.4 การทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรมทั้ง 3 แบบ.....	92
4.4.1 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม MobileNetV2	92
4.4.2 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม ResNet50.....	96
4.4.3 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม VGG16.....	100
4.4.4 การอภิปรายผลการทดลองตัวแบบที่ได้จากข้อมูลภาพถ่ายชุดที่ 4.....	104
4.5 การอภิปรายผลการทดลอง	105
4.6 ปัญหาที่พบในการสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อปอด.....	106
4.6.1 ปัญหาด้านจำนวนของภาพถ่าย.....	106
4.6.2 ปัญหาด้านเทคนิคและมุมมองของภาพถ่าย.....	106
4.6.3 ปัญหาด้านการคัดเลือกภาพถ่ายที่เหมาะสม.....	107
4.6.4 ปัญหาด้านทรัพยากรในการสร้างตัวแบบ	107
บทที่ 5 สรุปผลการดำเนินงานและข้อเสนอแนะ	108
5.1 สรุปผลการดำเนินงาน.....	108
5.2 ข้อเสนอแนะ	110
5.2.1 เพิ่มจำนวนภาพถ่ายของความผิดปกติแต่ละประเภท.....	110
5.2.2 เพิ่มการกำหนดจุดบ่งชี้ความผิดปกติของภาพถ่าย.....	110
5.2.3 เพิ่มการระบุตำแหน่งความผิดปกติที่ได้จากผลการจำแนก.....	110

สารบัญ (ต่อ)

	หน้า
บรรณานุกรม.....	111
ภาคผนวก	114
ภาคผนวก ก.....	115
ภาคผนวก ข.....	118
ภาคผนวก ค.....	120
ประวัติผู้เขียน.....	124



สารบัญตาราง

ตารางที่	หน้า
1.1 ระยะเวลาการดำเนินงาน.....	4
2.1 การเปรียบเทียบการแบ่งระดับความผิดปกติของเซลล์เยื่อบุผิว ทางเซลล์วิทยา และทางพยาธิวิทยาตามระบบต่างๆ.....	7
3.1 จำนวนภาพถ่ายที่แบ่งตามระดับความผิดปกติของเนื้อเยื่อบุผิวตามมาตรฐาน Bethesda Classification 2001 ของกลุ่มตัวอย่าง ระหว่างเดือน มีนาคม 2564 ถึง ธันวาคม 2565.....	25
3.2 จำนวนภาพถ่ายที่ผ่านการคัดเลือกด้วยมือเพื่อสร้างตัวแบบ แบ่งตามระดับความผิดปกติของเนื้อเยื่อบุผิว.....	28
3.3 รายละเอียดภาพถ่ายที่ผ่านการเพิ่มปริมาณโดยเทคนิคการเพิ่มปริมาณ ชุดที่ 1.....	32
3.4 รายละเอียดภาพถ่ายที่ผ่านการเพิ่มปริมาณโดยเทคนิคการเพิ่มปริมาณ ชุดที่ 2.....	33
3.5 รายละเอียดภาพถ่ายที่ผ่านการเพิ่มปริมาณโดยเทคนิคการเพิ่มปริมาณ ชุดที่ 3.....	34
3.6 รายละเอียดภาพถ่ายที่ผ่านการเพิ่มปริมาณโดยเทคนิคการเพิ่มปริมาณ ชุดที่ 4.....	35
3.7 ค่า Hyperparameter ที่ใช้ในสถาปัตยกรรม MobileNetV2, ResNet50 และ VGG16.....	47
4.1 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม MobileNetV2.....	55
4.2 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม ResNet50.....	59
4.3 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม VGG16.....	63
4.4 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม MobileNetV2.....	67
4.5 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม ResNet50.....	71
4.6 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม VGG16.....	75
4.7 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม MobileNetV2.....	80
4.8 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม ResNet50.....	84
4.9 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม VGG16.....	88
4.10 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม MobileNetV2.....	93
4.11 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม ResNet50.....	97
4.12 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม VGG16.....	101

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4.13	105



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป

รูปที่	หน้า
2.1 โครงข่ายระบบประสาทในทางชีววิทยา.....	9
2.2 ตัวอย่างฟังก์ชันกระตุ้น (Activation function) ทั่วไปที่ใช้ในระบบโครงข่ายประสาทเทียม	11
2.3 แสดงการเปรียบเทียบแนวคิดระหว่างระบบประสาททางชีววิทยากับระบบโครงข่ายประสาทเทียม ...	12
2.4 เปรียบเทียบความแตกต่างของระบบโครงข่ายประสาทเทียม และระบบโครงข่ายประสาทเทียมแบบสังวัตนาการที่ประกอบด้วยชั้นนำเข้า, ชั้นซ่อน และชั้นส่งออก.....	14
2.5 ระบบโครงข่ายประสาทเทียมแบบสังวัตนาการแบบทั่วไป ที่ประกอบด้วยชั้นแบ่งแยกคุณลักษณะจำนวน 2 ชั้น, ชั้นจำแนก จำนวน 2 ชั้น และฟังก์ชันกระตุ้น Softmax.....	15
2.6 วิธีการทำคอนโวลูชัน	16
2.7 วิธีการเลือกข้อมูลมากที่สุด และวิธีการเลือกข้อมูลแบบเฉื่อย.....	16
3.1 ระเบียบวิธีวิจัยการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนัง	22
3.2 ข้อมูลแสดงจำนวนภาพถ่ายที่มีในแต่ละครั้งของการวินิจฉัย.....	26
3.3 ขั้นตอนการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนัง	27
3.4 คำสั่งในการดำเนินการพลีกรูภาพ	28
3.5 ผลการดำเนินการพลีกรูภาพ	29
3.6 คำสั่งในการเพิ่มความเข้มของสี.....	29
3.7 ผลการดำเนินการเพิ่มความเข้มของสี.....	29
3.8 คำสั่งในการขยายภาพ	30
3.9 ผลการดำเนินการขยายภาพ	30
3.10 คำสั่งในการปรับรูปภาพสีเป็นรูปภาพสเกลสีเทา.....	31
3.11 ผลการดำเนินการปรับรูปภาพสีเป็นรูปภาพสเกลสีเทา.....	31
3.12 โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 1 และเทคนิคที่ใช้ในการเพิ่มปริมาณภาพถ่าย	36
3.13 ภาพถ่ายเยื่อผิวหนังภายในบริเวณปากมดลูก จากข้อมูลภาพถ่ายชุดที่ 1 หลังใช้เทคนิคการเพิ่มปริมาณภาพ.....	38
3.14 โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 2 และเทคนิคที่ใช้ในการเพิ่มปริมาณภาพถ่าย	39

สารบัญรูป (ต่อ)

รูปที่	หน้า
3.15 ภาพถ่ายเยื่อบุผิวภายในบริเวณปากมดลูก จากข้อมูลภาพถ่ายชุดที่ 2 หลังใช้เทคนิคการเพิ่มปริมาณภาพ.....	40
3.16 โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 3 และเทคนิคที่ใช้ในการเพิ่มปริมาณภาพถ่าย	41
3.17 ภาพถ่ายเยื่อบุผิวภายในบริเวณปากมดลูก จากข้อมูลภาพถ่ายชุดที่ 3 หลังใช้เทคนิคการเพิ่มปริมาณภาพ.....	43
3.18 โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 4 และเทคนิคที่ใช้ในการเพิ่มปริมาณภาพถ่าย	44
3.19 ภาพถ่ายเยื่อบุผิวภายในบริเวณปากมดลูก จากข้อมูลภาพถ่ายชุดที่ 4 หลังใช้เทคนิคการเพิ่มปริมาณภาพ.....	45
3.20 คำสั่งในการปรับขนาดภาพถ่ายและแบ่งชุดข้อมูลออกเป็นชุดข้อมูลเรียนรู้ และชุดข้อมูลทดสอบ	46
3.21 คำสั่งในการสร้างตัวแบบ MobileNetV2 เพื่อจำแนกระดับความผิดปกติของเนื้อเยื่อบุผิว	49
3.22 คำสั่งในการสร้างตัวแบบ ResNet50 เพื่อจำแนกระดับความผิดปกติของเนื้อเยื่อบุผิว	50
3.23 คำสั่งในการสร้างตัวแบบ VGG16 เพื่อจำแนกระดับความผิดปกติของเนื้อเยื่อบุผิว	51
3.24 คำสั่งในการปรับค่า Learning Rate โดย ReduceLRonPlateau ของสถาปัตยกรรม MobileNetV2.....	52
3.25 คำสั่งในการปรับค่า Learning Rate โดย ReduceLRonPlateau ของสถาปัตยกรรม ResNet50 .	52
3.26 คำสั่งในการปรับค่า Learning Rate โดย ReduceLRonPlateau ของสถาปัตยกรรม VGG16.....	52
4.1 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม MobileNetV2.....	56
4.2 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม MobileNetV2.....	56
4.3 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม MobileNetV2.....	57
4.4 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จาก สถาปัตยกรรม MobileNetV2.....	57
4.5 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม ResNet50.....	60

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.6 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม ResNet50.....	60
4.7 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม ResNet50.....	61
4.8 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จาก สถาปัตยกรรม ResNet50	61
4.9 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม VGG16.....	64
4.10 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม VGG16.....	64
4.11 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม VGG16.....	65
4.12 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จาก สถาปัตยกรรม VGG16	65
4.13 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม MobileNetV2.....	68
4.14 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม MobileNetV2.....	68
4.15 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม MobileNetV2.....	69
4.16 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จาก สถาปัตยกรรม MobileNetV2.....	69
4.17 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม ResNet50.....	72
4.18 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม ResNet50.....	72
4.19 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม ResNet50.....	73

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.20 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จาก สถาปัตยกรรม ResNet50	73
4.21 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จาก สถาปัตยกรรม VGG16.....	76
4.22 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จาก สถาปัตยกรรม VGG16.....	76
4.23 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม VGG16.....	77
4.24 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จาก สถาปัตยกรรม VGG16	77
4.25 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จาก สถาปัตยกรรม MobileNetV2.....	81
4.26 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จาก สถาปัตยกรรม MobileNetV2.....	81
4.27 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม MobileNetV2.....	82
4.28 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จาก สถาปัตยกรรม MobileNetV2.....	82
4.29 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จาก สถาปัตยกรรม ResNet50.....	85
4.30 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จาก สถาปัตยกรรม ResNet50.....	85
4.31 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม ResNet50.....	86
4.32 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จาก สถาปัตยกรรม ResNet50	86
4.33 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จาก สถาปัตยกรรม VGG16.....	89

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.34 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม VGG16.....	89
4.35 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม VGG16.....	90
4.36 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จาก สถาปัตยกรรม VGG16	90
4.37 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม MobileNetV2.....	94
4.38 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม MobileNetV2.....	94
4.39 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม MobileNetV2.....	95
4.40 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จาก สถาปัตยกรรม MobileNetV2.....	95
4.41 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม ResNet50.....	98
4.42 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม ResNet50.....	98
4.43 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม ResNet50.....	99
4.44 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จาก สถาปัตยกรรม ResNet50	99
4.45 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม VGG16.....	102
4.46 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม VGG16.....	102
4.47 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม VGG16.....	103

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.48 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จาก สถาปัตยกรรม VGG16	103
4.49 กราฟแสดงผลการทดลองตัวแบบที่ดีที่สุดการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนังจากชุดข้อมูล ภาพถ่ายชุดที่ 1 – 4.....	106



บทที่ 1

บทนำ

1.1 ความสำคัญและที่มา

มะเร็งปากมดลูกเป็นมะเร็งที่พบบ่อยเป็นอันดับ 2 ของสตรีทั่วโลก (Clifford GM, 2003) ในปี 2018 มีผู้ป่วยที่ได้รับการวินิจฉัยเป็นมะเร็งปากมดลูก 570,000 ราย และทำให้สตรีเสียชีวิตกว่า 311,000 ราย โดยมีแนวโน้มเพิ่มมากขึ้นภายในปี 2030 มีแนวโน้มที่จะมีผู้ป่วยที่ได้รับการวินิจฉัยเป็นมะเร็งปากมดลูกกว่า 700,000 ราย และทำให้สตรีเสียชีวิตกว่า 400,000 ราย (World Health Organization, 2020) ข้อมูลการรายงานอุบัติการณ์มะเร็งทุกชนิดจากหนังสือ Cancer in Thailand (Vol.VI - X) ในประเทศไทย โดยใช้ข้อมูลทะเบียนมะเร็งชุมชนจากแหล่งต่างๆ ทั่วประเทศ ระหว่างปี พ.ศ. 2547 - 2549 พบค่าอัตราอุบัติการณ์ของมะเร็งปากมดลูก (Age Standardized Rate, ASR) เท่ากับ 17.7 ต่อประชากรแสนคนต่อปี ซึ่งเป็นอันดับ 3 รองลงมาจากมะเร็งตับและท่อน้ำดี และมะเร็งเต้านม (Khuhaprema et al., 2012) ข้อมูลระหว่างปี พ.ศ. 2550 - 2552 พบค่า ASR 16.7 ต่อประชากรแสนคนต่อปี เป็นอันดับ 2 รองลงมาจากมะเร็งเต้านม (Khuhaprema et al., Cancer in Thailand Vol. VII, 2013) ข้อมูลระหว่างปี พ.ศ. 2553 - 2555 พบค่า ASR 14.4 ต่อประชากรแสนคนต่อปี เป็นอันดับ 2 รองลงมาจากมะเร็งเต้านม (Imsamran et al., 2015) ข้อมูลระหว่างปี พ.ศ. 2556 - 2558 พบค่า ASR 11.7 ต่อประชากรแสนคนต่อปี เป็นอันดับ 3 รองลงมาจากมะเร็งเต้านมและมะเร็งตับและท่อน้ำดี (Imsamran et al., Cancer in Thailand Vol.IX, 2018) และข้อมูลระหว่างปี พ.ศ. 2559 - 2561 พบค่า ASR 11.1 ต่อประชากรแสนคนต่อปี เป็นอันดับ 5 รองลงมาจากมะเร็งเต้านม มะเร็งลำไส้ใหญ่และไส้ตรง มะเร็งตับและท่อน้ำดีและมะเร็งปอด ตามลำดับ (Rojanamatrin et al., 2021)

มะเร็งปากมดลูกเป็นโรคที่สามารถป้องกันได้แต่เป็นสาเหตุของการเสียชีวิตของสตรีทั่วโลกโดยมีสาเหตุหลักมาจากการขาดการป้องกันการติดเชื้อไวรัสเอชพีวี (Human papilloma virus: HPV) และการตรวจคัดกรองมะเร็งปากมดลูกเพื่อรักษาตั้งแต่ระยะเริ่มแรกของโรค (World Health Organization, Comprehensive cervical cancer control: a guide to essential practice, 2nd ed, 2022) ซึ่งสามารถวิเคราะห์ความผิดปกติได้จากการตรวจด้วยคอลโปสโกปี

ภาพถ่ายเนื้อเยื่อที่ได้มานั้นอาจยังมีสิ่งรบกวนภายในรูปภาพ (Noise) ซึ่งทำให้ภาพไม่ชัดเจน ส่งผลให้การวิเคราะห์ด้วยสายตามนุษย์อาจจะเกิดความคลาดเคลื่อนได้ งานวิจัยชิ้นนี้จึงได้นำเสนอแนวทางในการใช้คอมพิวเตอร์ช่วยในการตัดสินใจด้วยระบบโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network: CNN) (Humphrey & Bello, 2012) ถูกพัฒนาจากระบบโครงข่ายประสาทเทียม (Neural Network) เป็นโครงข่ายที่สามารถจำลองหลักการทำงานของโครงข่ายประสาทสมองมนุษย์ได้ และระบบโครงข่ายประสาทเทียมแบบสังวัตนาการยังสามารถจำลองการมองเห็นของมนุษย์ ซึ่งมีประสิทธิภาพในการจำแนกรูปภาพได้อย่างถูกต้อง

1.2 วัตถุประสงค์ของงานวิจัย

1. เพื่อช่วยในการคัดกรองและวิเคราะห์ภาพถ่ายคอลโปสโคปที่มีความผิดปกติบริเวณปากมดลูกหรือไม่ หากมีความผิดปกติแล้ว ความผิดปกตินั้นจัดอยู่ในระดับใด
2. เพื่อลดภาระงานของบุคลากรทางการแพทย์ในการประเมินความผิดปกติของภาพถ่ายเนื้อเยื่อบุผิว
3. เพื่อลดความผิดพลาดของการระบุสถานะความผิดปกติของภาพถ่ายเนื้อเยื่อบุผิวที่เกิดจากมนุษย์

1.3 ขอบเขตการดำเนินงาน

1. ข้อมูลภาพถ่ายที่ใช้ทดสอบอังกอร์ทิมี เป็นข้อมูลภาพถ่ายคอลโปสโคปของกลุ่มผู้ป่วยที่เข้ารับการคัดกรองที่โรงพยาบาลจุฬารัตน์ จำนวน 417 ภาพ ระหว่างเดือน มีนาคม 2564 ถึง ธันวาคม 2565 รหัสอนุมัติโครงการที่ EC021/2566 โดยมีภาพถ่าย 4 ประเภทคือ
 - 1) ภาพถ่ายเนื้อเยื่อบุผิวภายในบริเวณปากมดลูก แบบซัลโมปากมดลูกด้วยน้ำเกลือ (Normal Saline Solution)
 - 2) ภาพถ่ายเนื้อเยื่อบุผิวภายในบริเวณปากมดลูก แบบย้อมตัวอย่างด้วยกรดแอสติก (Acetic Acid)
 - 3) ภาพถ่ายเนื้อเยื่อบุผิวภายในบริเวณปากมดลูก แบบย้อมตัวอย่างด้วยไอโอดีนบริสุทธิ์ (Iodine Solution)
 - 4) ภาพถ่ายเนื้อเยื่อบุผิวภายในบริเวณปากมดลูก ผ่านฟิลเตอร์สีเขียว (Green Filter)

2. การระบุระดับความผิดปกติของเนื้อเยื่อบุผิว มาจากการอ่านผลโดยพยาธิแพทย์ตามมาตรฐานของ The 2001 Bethesda System terminology ที่มีการระบุระดับของเนื้อเยื่อบุผิวไว้ 4 ระดับ ได้แก่ Normal, Low Grade Lesion (LGL), High Grade Lesion (HGL) และ Cancer
3. การตรวจสอบความถูกต้องของการวิเคราะห์ภาพถ่ายเพื่อจำแนกลักษณะความผิดปกติของเนื้อเยื่อบุผิว จะใช้การทดสอบภาพที่แยกไว้เป็นชุดข้อมูลทดสอบ โดยภาพถ่ายที่ใช้ทดสอบนี้จะมีการระบุระดับของเนื้อเยื่อบุผิวว่าจัดอยู่ในระดับใด

1.4 ขั้นตอนการดำเนินงาน

1. ค้นคว้าและศึกษางานวิจัยและเอกสารที่เกี่ยวข้องพร้อมทั้งระบุขอบเขตของปัญหาให้ชัดเจน
2. ศึกษาเทคนิคที่เกี่ยวข้องและวิธีการปรับปรุงภาพถ่ายเนื้อเยื่อบุผิวเพื่อนำไปสร้างตัวแบบในการจำแนกภาพถ่ายเนื้อเยื่อบุผิวว่าอยู่ในสถานะใด
3. ศึกษาเครื่องมือที่จะนำมาใช้ในการจำแนกสถานะของภาพถ่ายเนื้อเยื่อบุผิว
4. ขออนุมัติทำการวิจัยในคนจากคณะกรรมการจริยธรรมการวิจัยในคน เพื่อพิจารณาอนุมัติ
5. วิเคราะห์และออกแบบตัวแบบที่ใช้ในการจำแนกสถานะของภาพถ่ายเนื้อเยื่อบุผิว โดยใช้ระบบโครงข่ายประสาทเทียมแบบสังวัตนาการ
6. พัฒนาตัวแบบการจำแนกสถานะของภาพถ่ายเนื้อเยื่อบุผิว โดยใช้ระบบโครงข่ายประสาทเทียมแบบสังวัตนาการ
7. ทดสอบตัวแบบการจำแนกสถานะของภาพถ่ายเนื้อเยื่อบุผิว โดยใช้ระบบโครงข่ายประสาทเทียมแบบสังวัตนาการ
8. สรุปและวิเคราะห์ผลการจำแนกจากตัวแบบที่สร้าง
9. จัดทำเอกสารประกอบการวิจัย

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1. สามารถใช้ระบบคอมพิวเตอร์เพื่อช่วยในการคัดกรองและวิเคราะห์ภาพถ่ายคอลโปสโคปว่ามีความผิดปกติหรือไม่ หากมีความผิดปกติของเนื้อเยื่อบุผิวแล้ว ความผิดปกตินั้นจัดอยู่ในระดับใด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2. สามารถลดภาระงานของบุคลากรทางการแพทย์ในการประเมินความผิดปกติของภาพถ่ายเนื้อเยื่อบุผิวได้
3. สามารถลดความผิดพลาดของการระบุสถานะความผิดปกติของภาพถ่ายเนื้อเยื่อบุผิวที่เกิดจากมนุษย์ได้

1.6 ระยะเวลาดำเนินงาน

ใช้เวลาดำเนินงาน 12 เดือนระหว่าง กันยายน 2565 ถึง สิงหาคม 2566 แสดงดังตารางที่ 1.1

ตารางที่ 1.1 ระยะเวลาการดำเนินงาน

ขั้นตอนการดำเนินงาน	เดือน												
	2565				2566								
	9	10	11	12	1	2	3	4	5	6	7	8	
1. ค้นคว้าและศึกษางานวิจัยและเอกสารที่เกี่ยวข้องพร้อมทั้งระบุขอบเขตของปัญหาให้ชัดเจน													
2. ศึกษาเทคนิคที่เกี่ยวข้องและวิธีการปรับปรุงภาพถ่ายเนื้อเยื่อบุผิวเพื่อนำไปสร้างตัวแบบในการจำแนกภาพถ่ายเนื้อเยื่อบุผิวว่าอยู่ในสถานะใด													
3. ศึกษาเครื่องมือที่จะนำมาใช้ในการจำแนกสถานะของภาพถ่ายเนื้อเยื่อบุผิว													
4. ขออนุมัติทำการวิจัยในคนจากคณะกรรมการจริยธรรมการวิจัยในคน เพื่อพิจารณาอนุมัติ													

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ขั้นตอนการดำเนินงาน	เดือน											
	2565				2566							
	9	10	11	12	1	2	3	4	5	6	7	8
5. วิเคราะห์และออกแบบตัวแบบที่ใช้ในการจำแนกสถานะของภาพถ่ายเนื้อเยื่อผิวหนัง โดยใช้ CNN												
6. พัฒนาตัวแบบการจำแนกสถานะของภาพถ่ายเนื้อเยื่อผิวหนัง โดยใช้ CNN												
7. ทดสอบตัวแบบการจำแนกสถานะของภาพถ่ายเนื้อเยื่อผิวหนัง โดยใช้ CNN												
8. สรุปและวิเคราะห์ผลการจำแนกจากตัวแบบที่สร้าง												
9. จัดทำเอกสารประกอบการวิจัย												

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึงทฤษฎีที่ใช้ในการพัฒนาระบบการใช้คอมพิวเตอร์ช่วยในการจำแนกระดับของมะเร็งปากมดลูกด้วยระบบโครงข่ายประสาทเทียมแบบสังวัตนาการ เพื่อให้สามารถแบ่งแยกระดับของความผิดปกติของเนื้อเยื่อปากมดลูก

2.1 คอลโปสโคปี (Colposcopy)

คอลโปสโคปี เป็นการตรวจเยื่อปากมดลูกภายในบริเวณปากมดลูก ช่องคลอด ปากช่องคลอด และทวารหนักด้วยการส่องกล้องขยาย เพื่อการค้นหารอยโรค (Pierce JG Jr, Bright S, 2013) อาจมีการทาหรือขโหมด้วยน้ำยาเฉพาะ เพื่อตรวจหาความผิดปกติที่เกี่ยวข้องกับมะเร็ง หรือเพื่อตรวจยืนยันความปกติของเนื้อเยื่อปากมดลูก หัตถการที่อาจจะทำร่วมกับการตรวจ คือ การตัดชิ้นเนื้อที่สงสัยเพื่อการวินิจฉัย (Targeting biopsies) จากบริเวณที่มีความผิดปกติรุนแรงที่สุด (ศูนย์สูติ-นรีเวช, 2022) ซึ่งความผิดปกติของเนื้อเยื่อปากมดลูกเป็นภาวะที่เซลล์ปากมดลูกเจริญผิดปกติแต่ยังไม่ใช่มะเร็ง (Squamous intraepithelial lesions: SIL หรือ Cervical of intraepithelial neoplasia: CIN) (ไกรพิบูลย์, ซีไอเอ็น: ระยะก่อนมะเร็งปากมดลูก (CIN: Cervical of intraepithelial neoplasia), 2021)

2.2 ระดับของภาวะก่อนมะเร็งปากมดลูก

ภาวะก่อนมะเร็งปากมดลูก คือโรค/ภาวะที่เซลล์ปากมดลูกเจริญผิดปกติแต่ยังไม่ใช่มะเร็ง ซึ่งถ้ายังเจริญผิดปกติแบบนี้ไปเรื่อยๆต่อเนื่องนานหลายปี เซลล์เหล่านี้สามารถพัฒนาไปเป็นมะเร็งปากมดลูกได้ (ไกรพิบูลย์, ซีไอเอ็น: ระยะก่อนมะเร็งปากมดลูก (CIN: Cervical of intraepithelial neoplasia), 2021) การดำเนินของโรคจากเซลล์ที่ติดเชื้อไวรัส HPV จนกลายเป็นมะเร็งนั้นจะใช้เวลาโดยเฉลี่ย ประมาณ 10-15 ปีโดยเซลล์เริ่มแรกที่ผิดปกติจะเป็นเซลล์ที่อยู่ในชั้น basal epithelium จากนั้นความผิดปกติจะเพิ่มสูงขึ้น ความผิดปกติของเซลล์ที่อยู่ในระดับหนึ่งในสามของชั้นเยื่อปากมดลูกเรียกว่า Mild dysplasia, Low-grade Squamous Intraepithelial Lesion (LSIL) หรือ CIN 1 ความผิดปกติของเซลล์ที่อยู่ในระดับสองในสามของชั้นเยื่อปากมดลูกเรียกว่า Moderate dysplasia หรือ High-grade Squamous Intraepithelial Lesion (HSIL) ความผิดปกติของเซลล์ที่อยู่ในระดับเกินสองในสามของชั้นเยื่อปากมดลูกเรียกว่า Severe dysplasia หรือ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

High-grade Squamous Intraepithelial Lesion (HSIL) เมื่อเซลล์ที่ผิดปกติเจริญจนเต็มชั้นเยื่อผิวแล้ว จะมีการลุกลามผ่านชั้น basement membrane เข้าสู่ชั้น stroma ของปากมดลูก เรียกว่ามะเร็ง หรือ Carcinoma (ศรีใจพระเจริญ, 2015) การเรียกความผิดปกติของเซลล์ในชั้นเยื่อผิวมีหลายระบบ ดังสรุป ในตารางที่ 2.1

ตารางที่ 2.1 การเปรียบเทียบการแบ่งระดับความผิดปกติของเซลล์เยื่อผิว ทางเซลล์วิทยา และทางพยาธิวิทยาตามระบบต่างๆ

ระดับ	ลักษณะของเซลล์	Bethesda Classification 2001 (Cytology)	WHO Terminology (Cytology)	Colposcopy Impression (Cytology)	Cervical Intraepithelial Neoplasia (Histology)
1.1.	เซลล์แตกต่างจากเซลล์ปกติไปบ้าง แต่ระดับการเสื่อมสภาพนั้นยังไม่รุนแรง	Atypical squamous cells of undetermined significance (ASC-US)		Normal	
1.2.	มีการเปลี่ยนแปลงของเซลล์แต่ยังไม่สามารถระบุความรุนแรงได้ชัดเจน	Atypical squamous cells cannot exclude high-grade squamous intraepithelial lesion (ASC-H)		Low grade lesion (LGL)	
2.	มีความผิดปกติของเซลล์ที่อยู่ในระดับหนึ่งในสามของชั้นเยื่อผิว	low-grade squamous intraepithelial lesion (LSIL)	Mild dysplasia	Low grade lesion (LGL)	CIN 1


ระดับ	ลักษณะของเซลล์	Bethesda Classification 2001 (Cytology)	WHO Terminology (Cytology)	Colposcopy Impression (Cytology)	Cervical Intraepithelial Neoplasia (Histology)
3.1.	มีความผิดปกติของเซลล์ที่อยู่ในระดับสองในสามของชั้นเยื่อบุผิว	high-grade squamous intraepithelial lesion (HSIL)	Moderate dysplasia	High grade lesion (HGL)	CIN 2
3.2.	มีความผิดปกติของเซลล์ที่อยู่ในระดับสองในสามของชั้นเยื่อบุผิว	high-grade squamous intraepithelial lesion (HSIL)	Severe dysplasia	High grade lesion (HGL)	CIN 3
4.	มีความผิดปกติของเซลล์ที่อยู่ในเต็มทั้งชั้นเยื่อบุผิว	high-grade squamous intraepithelial lesion (HSIL)	Carcinoma in situ	High grade lesion (HGL)	CIS
5.	มีความผิดปกติเจริญจนเต็มชั้นเยื่อบุผิวแล้วจะมีการลุกลามผ่านชั้น basement membrane เข้าสู่ชั้น stroma ของปากมดลูก	Cancer	Carcinoma	Cancer	Cancer

2.3 ระบบโครงข่ายประสาทเทียม (Artificial Neural Network: ANN)

ระบบโครงข่ายประสาทเทียม คือการพัฒนาคอมพิวเตอร์ให้สามารถเลียนแบบกระบวนการคิดของมนุษย์ ซึ่งจะมีลักษณะคล้ายกับระบบโครงข่ายประสาทของสมอง (Neurons) แสดงดังรูปที่ 2.1 เรียกว่าระบบโครงข่ายประสาทเทียม (BISHOP, 1995) รูปแบบของระบบโครงข่ายประสาทเทียมขั้นพื้นฐานจะ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประกอบด้วยเซลล์ประสาท (Neuron) เพียง 1 เซลล์ เรียกว่าสถาปัตยกรรมเพอร์เซปตรอน (Perceptron Architecture) (Miller, Sutton, & Werbos, 1990) โดยที่ข้อมูลนำเข้าจะถูกส่งผ่านไปโดยใยประสาทนำเข้า (Dendrites) เพื่อเข้าสู่เซลล์ประสาทเพื่อประมวลผลและส่งออกข้อมูลออกมาทางแกนประสาท (Axon) โดยการประมวลผลจะใช้ผลรวมของผลคูณ (Sum of Product) ของข้อมูลนำเข้าและค่าน้ำหนัก (Weight) ที่ส่วนจุดประสานประสาท (Synapse) ที่ได้จากกระบวนการเรียนรู้ในการประมวลผล โดยจะใช้ในการจดจำข้อมูลอื่นๆที่อยู่ในรูปแบบเดียวกันเพื่อปรับค่าถ่วงน้ำหนักในการถ่ายทอดไปยังโครงข่ายประสาทอื่น



รูปที่ 2.1 โครงข่ายระบบประสาทในทางชีววิทยา (Lee, et al., 2017)

โดยหลักการทำงานของระบบโครงข่ายประสาทเทียมจะมี 3 ส่วนคือชั้นนำเข้า (Input Layer), ชั้นซ่อน (Hidden Layer) และ ชั้นส่งออก (Output Layer) ดังนี้

1) ชั้นนำเข้า (Input Layer) คือส่วนรับเข้าข้อมูลหรือรูปภาพที่เหมือนกับการมองเห็นของมนุษย์ ชั้นข้อมูลนำเข้านี้จะต้องนำข้อมูลที่มีคุณลักษณะของข้อมูลที่สนใจเข้าไปในระบบ เช่น ข้อมูลภาพถ่ายคอลโปสโคป

2) ชั้นซ่อน (Hidden Layer) คือส่วนการประมวลผลเป็นชั้นๆ ซึ่งเหมือนกับการทำงานสมองของมนุษย์ที่เรียกว่าระบบโครงข่ายประสาทเทียม เพื่อให้เกิดการเรียนรู้และการจำแนกประเภทของข้อมูลที่นำเข้า โดยในชั้นซ่อนของระบบโครงข่ายประสาทเทียมจะมีจำนวนที่ชั้นและจำนวนที่ Node ก็ได้ ซึ่งการเพิ่มจำนวนชั้นและ Node จะส่งผลต่อ

การทำงานของตัวแบบในจากการจำแนกคุณลักษณะจากข้อมูลที่นำเข้ามาจากชั้นนำเข้า โดยในชั้นซ่อนจะมีฟังก์ชันกระตุ้น (Activation Function) ในการประมวลผลค่าจากชั้นข้อมูลนำเข้าทั้งหมดเพื่อพิจารณาเป็นค่าเดียว ซึ่งข้อมูลนำเข้าจะถูกส่งไปคำนวณค่าผลรวมของผลคูณ (Sum of Product) ของข้อมูลนำเข้าและค่าน้ำหนัก (Weight) แสดงดังสมการที่ 1


$$\sum_{i=0}^n x_{ij}w_{ij} \quad (1)$$

x_{ij} คือ ข้อมูลนำเข้าที่ i โดยที่ $i = 1, 2, \dots, n$ ไปยัง Node ของชั้นซ่อนที่ j โดยที่ $j = 1, 2, \dots, n$

w_{ij} คือ ค่าน้ำหนักจากข้อมูลนำเข้าที่ i โดยที่ $i = 1, 2, \dots, n$ ไปยัง Node ของชั้นซ่อนที่ j โดยที่ $j = 1, 2, \dots, n$

โดยที่ $n =$ จำนวน Node ของข้อมูลนำเข้า

เมื่อได้ค่าผลรวมของผลคูณข้อมูลนำเข้าแล้ว จะถูกส่งไปยังฟังก์ชันกระตุ้น (Activation function/ Transfer function) เพื่อปรับค่าที่ได้เพื่อส่งไปยังชั้นส่งออก เพื่อเป็นตัวแทนของ Node ซึ่งมีหลายประเภท เช่น Sigmoid, Tanh, ReLU, Softmax เป็นต้น ซึ่งแต่ละประเภทจะมีลักษณะการใช้งานที่แตกต่างกันออกไป แสดงดังรูปที่ 2.2




รูปที่ 2.2 ตัวอย่างฟังก์ชันกระตุ้น (Activation function) ทั่วไปที่ใช้ในระบบโครงข่ายประสาทเทียม (Johnson, et al., 2020)

โดยในงานวิจัยนี้จะใช้ Softmax Function เป็นฟังก์ชันกระตุ้น ที่เป็นตัวเลือกยอดนิยมในการจำแนกผลลัพธ์ที่มากกว่า 1 ประเภท (Multiclass Classification) (Google Machine Learning Education, 2022) และค่าที่ผ่านการคำนวณค่าเสร็จสิ้นจะถูกส่งต่อไปในส่วนชั้นส่งออก (SHARMA, 2017)

3) ชั้นส่งออก (Output Layer) คือส่วนแสดงผล (Label) การจำแนกประเภทของข้อมูลที่นำเข้า เป็นผลมาจากการใช้ชั้นซ่อนมาวิเคราะห์จนได้ผลลัพธ์ที่ทำนายจากคุณลักษณะของข้อมูลที่นำเข้า สามารถเปรียบเทียบชั้นส่งอกกับส่วน Axon ในระบบประสาททางชีววิทยา

โดยมีการเปรียบเทียบแนวคิดระหว่างระบบประสาททางชีววิทยากับระบบโครงข่ายประสาทเทียม แสดงดังรูปที่ 2.3

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.3 แสดงการเปรียบเทียบแนวคิดระหว่างระบบประสาททางชีววิทยากับระบบโครงข่ายประสาทเทียม (Lee, et al., 2017)

ระบบโครงข่ายประสาทเทียมมีการเรียนรู้อยู่ 2 ประเภทคือ การเรียนรู้แบบมีผู้สอน (Supervised Learning) และการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) ดังนี้

1. การเรียนรู้แบบมีผู้สอน (Supervised Learning) เป็นการเรียนรู้ข้อมูลจากข้อมูลนำเข้าที่มีคำตอบอยู่แล้ว เพื่อให้ระบบโครงข่ายประสาทเทียมได้ทำการปรับตัวแบบที่เกิดจากการเรียนรู้จากชุดข้อมูลนำเข้า เมื่อนำตัวแบบไปใช้งานกับข้อมูลที่มีลักษณะแตกต่างจากที่ตัวแบบเคยเรียนรู้ ก็จะทำให้ใช้พื้นฐานจากตัวแบบในการทำนายคำตอบ หากคำตอบไม่ถูกต้องระบบโครงข่ายประสาทเทียมก็จะทำการปรับตัวแบบเพื่อให้ได้ความถูกต้องที่สูงขึ้น
2. การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) เป็นการเรียนรู้ข้อมูลจากข้อมูลนำเข้าที่ไม่มีคำตอบของข้อมูลนั้น เพื่อให้ระบบโครงข่ายประสาทเทียมทำการเรียนรู้ตัวแบบเพื่ออธิบายโครงสร้างที่ซ่อนอยู่ในข้อมูล เพื่อแบ่งแยกข้อมูลออกเป็นกลุ่มตามลักษณะที่คล้ายคลึงกัน

2.4 Softmax Function

Softmax Function คือ ฟังก์ชันที่ทำการเปลี่ยนค่าของข้อมูลที่ได้รับเข้าจากจำนวนจริง ไม่ว่าจะ เป็นค่าบวก ลบ หรือเท่ากับศูนย์ เพื่อค่าความน่าจะเป็นที่มีผลรวมเท่ากับ 1 โดย Softmax Function จะใช้งานได้ดีในการจำแนกประเภทของข้อมูลที่มีมากกว่า 1 ประเภท (Multiclass Classification) โดยมีรูปแบบการคำนวณดังสมการที่ 2 (Banerjee, et al., 2020)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (2)$$

z_i คือ ค่าผลรวมของผลคูณที่ i โดยที่ $i = 1, 2, \dots, n$

n = จำนวน Node ของข้อมูลนำเข้า

z_j คือ ค่าผลรวมของผลคูณที่ j โดยที่ $j = 1, 2, \dots, K$

K = จำนวนประเภทของข้อมูลในชั้นส่งออก

2.5 Rectified Linear Unit Function (ReLU)

Rectified Linear Unit Function คือ ฟังก์ชันที่ทำการเปลี่ยนค่าของข้อมูลที่ได้รับให้เป็นค่าที่มากกว่าหรือเท่ากับศูนย์ โดยมีแนวคิดที่ว่าหากค่าที่ได้รับเป็นค่าที่ติดลบจะถูกปรับปรุงให้นำหน้าเป็นศูนย์ ซึ่งแปลว่าจะไม่มีการส่งค่าไปยัง Node ถัดไป ซึ่ง Rectified Linear Unit Function สามารถช่วยป้องกันการเกิดปัญหา Vanishing Gradients ได้ดี โดยมีรูปแบบการคำนวณดังสมการที่ 3 (g Zhang, Chichun, Junding, & Chaosheng, 2018)

$$\max(0, x) \quad (3)$$

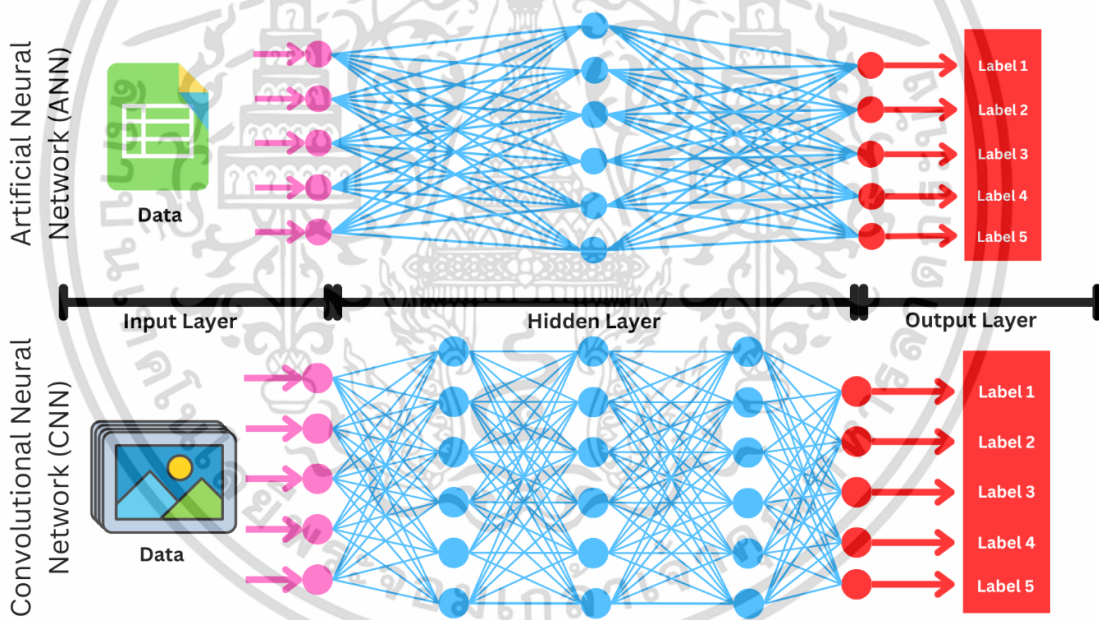
x คือ ค่าของข้อมูลนำเข้าที่ได้รับจาก Node ก่อนหน้า

2.6 การเรียนรู้เชิงลึก (Deep Learning)

การเรียนรู้เชิงลึก จะมีลักษณะคล้ายกับระบบโครงข่ายประสาทเทียม ซึ่งการเรียนรู้เชิงลึกสามารถสร้างตัวแบบจากการเรียนรู้ของชุดข้อมูลนำเข้าเพื่อหาคำตอบจากการประมวลผลของชั้นของระบบโครงข่ายประสาทเทียมที่มีชั้นซ่อนมากกว่า 2 ชั้น ทำให้ได้ตัวแบบที่ลึกมากขึ้นจึงเกิดการวิเคราะห์ข้อมูลอย่างละเอียดในการจำแนกคุณลักษณะ โดยที่ระบบการเรียนรู้เชิงลึกสามารถเรียนรู้ว่าคุณลักษณะของข้อมูลใดที่ส่งผลต่อผลลัพธ์ได้เองจากข้อมูลนำเข้า โดยที่ไม่จำเป็นต้องมีความรู้พื้นฐานก่อน ซึ่งข้อมูลนำเข้าจะถูกนำไปใช้ในการตรวจจบบรูปแบบ (Pattern) หรือจำแนกข้อมูล (Classify)

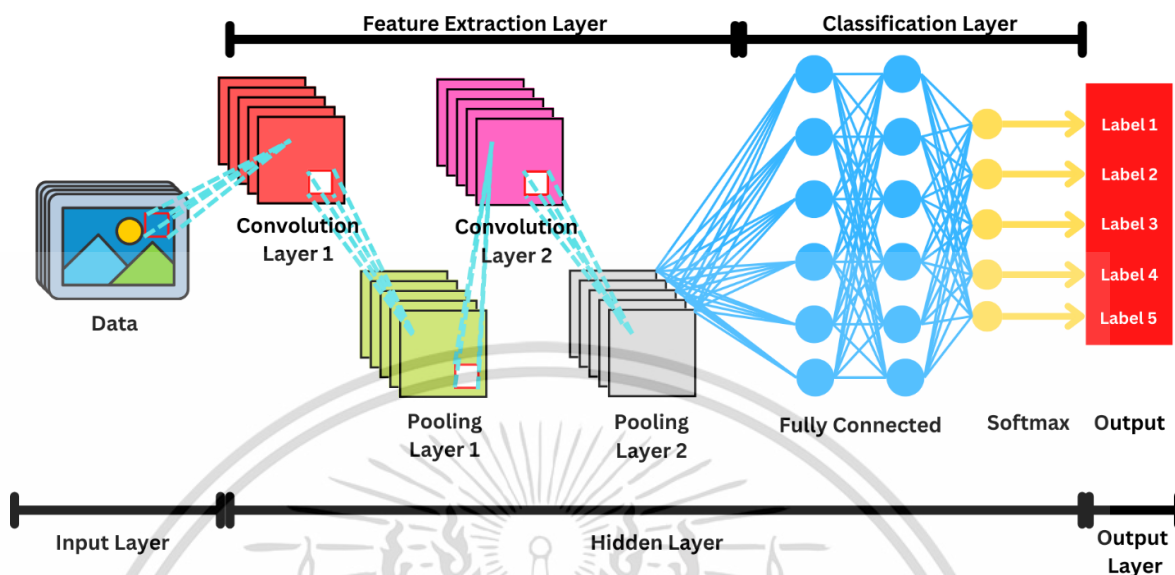
2.7 ระบบโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network: CNN)

ระบบโครงข่ายประสาทเทียมแบบสังวัตนาการ (Humphrey & Bello, 2012) เป็นวิธีการจำลองการมองเห็นของมนุษย์ที่สามารถแยกแยะคุณลักษณะ (Features) ของวัตถุที่มองเห็น เช่น สี รูปร่าง ลักษณะ กรอบรูปภาพ และนำคุณลักษณะทั้งหมดมาประกอบกันเพื่อระบุคุณสมบัติของสิ่งที่อยู่ภายในรูปภาพนั้นในการเรียนรู้เพื่อสร้างตัวแบบ เช่น ภาพถ่ายคอลโปสโคปเพื่อจำแนกความผิดปกติของเซลล์เยื่อหุ้มสมองที่อยู่ในระดับใด ซึ่งชั้นของระบบโครงข่ายประสาทเทียมแบบสังวัตนาการมีลักษณะเช่นเดียวกับระบบโครงข่ายประสาทเทียม ประกอบด้วยชั้นนำเข้า, ชั้นซ่อน และชั้นส่งออก (เมธาเฉลิมพัฒน์, 2022) แต่ในชั้นซ่อนจะประกอบด้วยชั้นชนิดอื่นอีกหลายชั้น ซึ่งมีความแตกต่างจากระบบโครงข่ายประสาทเทียม แสดงดังรูปที่ 2.4




รูปที่ 2.4 เปรียบเทียบความแตกต่างของระบบโครงข่ายประสาทเทียม และระบบโครงข่ายประสาทเทียมแบบสังวัตนาการที่ประกอบด้วยชั้นนำเข้า, ชั้นซ่อน และชั้นส่งออก

ซึ่งระบบโครงข่ายประสาทเทียมแบบสังวัตนาการแบบทั่วไป จะมีการเพิ่มเติมชั้นอีก 2 ส่วนเข้ามาในชั้นซ่อน คือชั้นแบ่งแยกคุณลักษณะ (Feature Extraction Layer) และชั้นจำแนก (Classification Layer) แสดงดังรูปที่ 2.5




รูปที่ 2.5 ระบบโครงข่ายประสาทเทียมแบบสังวัตนาการแบบทั่วไป ที่ประกอบด้วยชั้นแบ่งแยกคุณลักษณะ จำนวน 2 ชั้น, ชั้นจำแนก จำนวน 2 ชั้น และฟังก์ชันกระตุ้น Softmax

1. ชั้นแบ่งแยกคุณลักษณะ (Feature Extraction Layer) ประกอบด้วย
 - 1.1. ชั้นคอนโวลูชัน (Convolution Layer) เป็นชั้นที่มีหน้าที่สกัดเอาคุณลักษณะที่สำคัญของรูปภาพ โดยใช้ในการดำเนินการทางคณิตศาสตร์โดยการคูณพิกเซล (Pixel) ที่เรียกว่าการคูณเมทริกซ์ (Dot Matrix) ที่อยู่ใกล้เคียงกันเป็นพารามิเตอร์ที่ใช้เรียนรู้ เรียกว่าฟิลเตอร์ (Filter) หรือเคอร์เนล (Kernel) ที่ใช้ร่วมกันในทศวรรษของภาพ แสดงดังรูปที่ 2.6 (Lee, et al., 2017) ซึ่งในชั้นคอนโวลูชันสามารถนำฟังก์ชันกระตุ้นมาใช้งานเพื่อปรับให้มีประสิทธิภาพสูงขึ้นได้ (Ren, Yang, Zhang, & Guo, 2019)



รูปที่ 2.6 วิธีการทำคอนโวลูชัน (Lee, et al., 2017)

- 1.2. ชั้นการรวม (Pooling Layer) เป็นชั้นที่รับค่าจากชั้นคอนโวลูชันมาและทำการลดขนาดของข้อมูลให้เหลือเฉพาะข้อมูลที่มีคุณลักษณะที่สำคัญเท่านั้น โดยทั่วไปจะใช้วิธีการเลือกข้อมูลมากที่สุด (Max Pooling) (กิตตินราทร, 2020) นอกจากนี้ยังมีวิธีการเลือกข้อมูลแบบเฉลี่ย (Average Pooling) ที่จะให้ผลลัพธ์ที่แตกต่างออกไป แสดงดังรูปที่ 2.7 โดยการเลือกข้อมูลจะนำมาจากแต่ละช่วงของเมตริกซ์เพื่อเป็นตัวแทนในการสร้างเป็นเมตริกซ์ขนาดเล็กเพื่อส่งไปยังขั้นถัดไป



รูปที่ 2.7 วิธีการเลือกข้อมูลมากที่สุด และวิธีการเลือกข้อมูลแบบเฉลี่ย (Lee, et al., 2017)

2. ชั้นจำแนก (Classification Layer) จะมีการเพิ่มชั้นเชื่อมโยงแบบสมบูรณ์ (Fully Connected) เป็นชั้นที่เชื่อมโยงระหว่างคุณลักษณะที่ผ่านการประมวลผลกับข้อมูลส่งออก โดยจะเป็นการทำซ้ำในชั้นแบ่งแยกคุณลักษณะจนเชื่อมต่อกันแบบสมบูรณ์ในทุก Node (Ren, Yang, Zhang, & Guo, 2019) ก่อนที่จะส่งค่าไปยังฟังก์ชันกระตุ้น (Activation function/ Transfer function) เพื่อจำแนกประเภทของภาพในชั้นส่งออกต่อไป

2.8 งานวิจัยที่เกี่ยวข้อง

ในบทย่อนี้จะกล่าวถึงงานวิจัยที่เกี่ยวข้องกับการจำแนกประเภทของรูปภาพด้วยระบบโครงข่ายประสาทเทียมแบบสังวัตนาการ เพื่อนำองค์ความรู้มาประยุกต์ใช้กับงานวิจัย ซึ่งมีหัวข้องานวิจัยที่สนใจทั้งหมด 6 งานวิจัย ได้แก่ Multi-Feature Fusion with Convolutional Neural Network for Ship Classification in Optical Images, MSCI: A multistate dataset for colposcopy image classification of cervical cancer screening, Deep learning based cervical screening by the cross-modal integration of colposcopy, cytology, and HPV test, Classification of Cervical Intraepithelial Neoplasia (CIN) using fine-tuned Convolutional Neural Networks, MobileNetV2 Ensemble for Cervical Precancerous Lesions Classification และ MDFI: Muli-CNN Decision Feature Integration for Diagnosis of Cervical Precancerous Lesions

2.8.1 Multi-Feature Fusion with Convolutional Neural Network for Ship Classification in Optical Images

Ren และคณะ นำเสนอเทคนิคการจำแนกภาพถ่ายของเรือ 6 ประเภทจากชุดข้อมูลที่จัดทำขึ้น และชุดข้อมูลสาธารณะ Visible And Infrared Spectrums (VAIS) ที่มีปัจจัยภายนอกที่ดำเนินการด้วยระบบโครงข่ายประสาทเทียมแบบสังวัตนาการ และทำการปรับปรุงระบบโครงข่ายประสาทเทียมแบบสังวัตนาการโดยการเพิ่มเติมชั้นซ่อนให้มีความละเอียดในการเรียนรู้โครงสร้างชั้นสูงได้ จากนั้นทำการสกัดคุณลักษณะโดยใช้วิธี Histogram of Oriented Gradients (HOG) และ local binary patterns (LBP) และจำแนกด้วยฟังก์ชันกระตุ้น Softmax โดยวิธีการที่นำเสนอมีความแม่นยำที่ 97.50% ในชุดข้อมูลที่จัดทำขึ้น และ 93.60% ในชุดข้อมูล VAIS

อย่างไรก็ตาม ชุดข้อมูล VAIS ที่ใช้ยังมีช่องว่างที่ยังสามารถปรับปรุงประสิทธิภาพเพิ่มเติมในการจำแนกของตัวแบบในงานวิจัยนี้ได้โดยใช้แหล่งข้อมูลอื่นเพิ่มเติม

2.8.2 MSCI: A multistate dataset for colposcopy image classification of cervical cancer screening

Yu และคณะ นำเสนอเทคนิคในการจำแนกภาพถ่ายคอลโปสโคปจากชุดข้อมูลสาธารณะ A Multistate dataset for Colposcopy Image (MSIC) ที่มีจำนวนระดับของการคัดกรอง 4 ระดับ จากชุดข้อมูลภาพถ่ายจำนวน 4753 ภาพ ที่ประกอบด้วยภาพถ่าย 3 รูปแบบคือ ภาพถ่ายที่ย้อมตัวอย่างด้วยกรดแอซีติก, ภาพถ่ายที่ผ่านฟิลเตอร์สีเขียวกับตัวอย่าง และภาพถ่ายที่ย้อมตัวอย่างด้วยไอโอดีนบรียูซี โดยดำเนินการด้วยระบบโครงข่ายประสาทเทียมแบบสังวัตนาการที่ผ่านการปรับปรุงด้วยวิธี a gated recurrent convolutional neural network (C-GCNN) โดยวิธีการที่นำเสนอมีความแม่นยำที่ 96.87% ค่าความไวที่ 95.68% และค่าความจำเพาะที่ 98.72%

ตัวแบบที่ได้ในงานวิจัยมีประสิทธิภาพสูงกว่าวิธีการสกัดคุณลักษณะด้วยมือและการเรียนรู้เชิงลึกแบบดั้งเดิม แต่การจำแนกรูปภาพไม่ได้นำข้อมูลส่วนตัวของผู้ป่วยมาประกอบการจำแนกระดับที่อาจจะมีความสำคัญในการพัฒนาประสิทธิภาพของตัวแบบ

2.8.3 Deep learning based cervical screening by the cross-modal integration of colposcopy, cytology, and HPV test

Fu และคณะ นำเสนอเทคนิคในการจำแนกภาพถ่ายคอลโปสโคปจากชุดข้อมูลจากผู้ที่ผ่านมาการคัดกรองมะเร็งปากมดลูก จำนวน 2160 ราย ซึ่งภาพถ่ายจากการคัดกรองจะมี 3 รูปแบบคือ ภาพถ่ายที่ใช้น้ำเกลือเช็ดล้าง, ภาพถ่ายที่ย้อมตัวอย่างด้วยกรดแอซีติก และภาพถ่ายที่ย้อมตัวอย่างด้วยไอโอดีนบรียูซี โดยดำเนินการด้วยระบบโครงข่ายประสาทเทียมแบบสังวัตนาการที่ใช้สถาปัตยกรรม VGG-16 ของรูปภาพแต่ละประเภท และใช้ตัวแบบที่สร้างโดย Multivariable Logistic Regression (MLR) เพื่อรวมรูปภาพทั้ง 3 รูปแบบเข้าด้วยกันและนำไปสร้างตัวแบบร่วมกับผล Cytology test และ HPV test ทำให้ได้ค่า AUC ที่ 0.921

ตัวแบบที่ได้ในงานวิจัยมีประสิทธิภาพสูงกว่าก่อนนำตัวแบบทั้งหมดรวมเข้าด้วยกัน แต่ยังสามารถพัฒนาตัวแบบเพิ่มเติมได้จากการเพิ่มจำนวนรูปภาพในระดับต่างๆจากองค์กรอื่น เพื่อหลีกเลี่ยงการเกิดปัญหาความเอนเอียงของข้อมูล ซึ่งส่งผลต่อประสิทธิภาพของตัวแบบ

2.8.4 Classification of Cervical Intraepithelial Neoplasia (CIN) using fine-tuned Convolutional Neural Networks

Aina และคณะ นำเสนอเทคนิคในการจำแนกภาพถ่ายคอลโปสโคปจากชุดข้อมูลจากผู้ที่ไม่ผ่านการคัดกรองมะเร็งปากมดลูก จำนวน 909 ภาพจากหลายแหล่ง ข้อมูลแต่ละประเภทมีจำนวนไม่เท่ากัน ทำให้เกิดปัญหาความไม่สมดุล (Imbalance) จึงใช้วิธีการแยกและแต่งเติมข้อมูล (Splitting and Augmentation) รวมไปถึงการใช้เทคนิค 1 Cycle Policy for Optimal Learning Rates Selection และ Discriminative Fine-Tuning ในการปรับใช้ค่า Learning Rates ที่ดีที่สุด และยังใช้วิธี Mixed Precision Training เพื่อเพิ่มความเร็วในการเรียนรู้ให้กับสถาปัตยกรรม DenseNet ทำให้ได้ค่าความแม่นยำที่ 96.3% ค่าความจำเพาะที่ 98.86% และค่าความไวที่ 94.97%

2.8.5 MobileNetV2 Ensemble for Cervical Precancerous Lesions Classification

Buiu และคณะ นำเสนอเทคนิคในการจำแนกภาพถ่ายคอลโปสโคปจากชุดข้อมูล IEEE Dataport cervigram image dataset จำนวน 3339 ภาพ ที่มาจากจำนวนการคัดกรอง 477 ครั้ง ทำให้รูปภาพมีความคล้ายคลึงกัน จึงทำการแต่งเติมข้อมูลโดยเทคนิคต่างๆ เพื่อทำให้รูปภาพมีความแตกต่างกัน โดยดำเนินการสร้างตัวแบบในการจำแนกโดยใช้ MobileNetV2 เพื่อเปรียบเทียบประสิทธิภาพกับ สถาปัตยกรรม DenseNet, ResNet18, ResNeXt-101 และ VGG19 ซึ่งสถาปัตยกรรม MobileNetV2 ผ่านการใช้ Ensemble fine-tuned มีค่าความถูกต้องที่ 83.33%

2.8.6 MDFI: Muti-CNN Decision Feature Integration for Diagnosis of Cervical Precancerous Lesions

Lup และคณะ นำเสนอเทคนิคในการจำแนกภาพถ่ายคอลโปสโคปจากชุดข้อมูลจากผู้ที่ไม่ผ่านการคัดกรองมะเร็งปากมดลูกจากโรงพยาบาลที่ให้ความร่วมมือ โดยมีจำนวนรูปภาพที่เป็นผลบวก 3920 ภาพ และจำนวนรูปภาพที่เป็นผลลบ 4337 ภาพ และทำการคัดเลือกรูปภาพเพื่อนำมาเป็นตัวแทนของการคัดกรอง จึงเหลือรูปภาพที่เป็นผลบวก 156 ภาพ และรูปภาพที่เป็นผลลบ 444 ภาพ โดยดำเนินการด้วยระบบโครงข่ายประสาทเทียมแบบสังวัตนาการที่ใช้สถาปัตยกรรม DenseNet121 และ ResNet50 ทำให้ได้ค่าความถูกต้องที่ 0.681 และ 0.604 ตามลำดับ

เนื่องจากค่าความถูกต้องมีค่าค่อนข้างน้อย เป็นผลจากชุดข้อมูลที่มีอยู่อย่างจำกัด หากมีการแต่งเติมข้อมูลด้วยเทคนิคต่างๆ จะทำให้ตัวแบบมีประสิทธิภาพที่สูงขึ้น



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


บทที่ 3

วิธีการดำเนินงานวิจัย

ในบทนี้จะกล่าวถึงระเบียบวิธีวิจัย ซึ่งเป็นขั้นตอนในการปฏิบัติงานทั้งหมดของงานวิจัยนี้ โดยการจำแนกระดับความผิดปกติของเนื้อเยื่อปากช่องจะใช้การจำแนกตามมาตรฐานของ The 2001 Bethesda System Terminology ที่มีการระบุระดับของเนื้อเยื่อปากช่องไว้ 4 ระดับ ได้แก่ Normal, Low-grade Squamous Intraepithelial Lesion (LSIL), High-grade Squamous Intraepithelial Lesion (HSIL) และ Squamous Cell Carcinoma (Cancer) ที่ผ่านการอ่านผลจากพยาธิแพทย์โดยให้ระดับความผิดปกติของเนื้อเยื่อปากช่องในรูปแบบของ Colposcopy Impression ตามระดับดังนี้ Normal, Low Grade Lesion (LGL), High Grade Lesion (HGL) และ Cancer ดังนั้นการดำเนินการวิจัยจึงประกอบไปด้วยขั้นตอนต่างๆ ตั้งแต่ระเบียบวิธีวิจัย การรวบรวมข้อมูลรูปภาพ การเตรียมข้อมูลรูปภาพ และขั้นตอนการสร้างตัวแบบจำแนกระดับความผิดปกติของเนื้อเยื่อปากช่องโดยละเอียด

3.1 ระเบียบวิธีวิจัย

ขั้นตอนการศึกษาทฤษฎี การทดลอง และการประเมินผล มีลำดับการดำเนินงาน แสดงดังรูปที่ 3.1



รูปที่ 3.1 ระเบียบวิธีวิจัยการจำแนกระดับความผิดปกติของเนื้อเยื่อผึ้ง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.1.1 ศึกษาทฤษฎีที่เกี่ยวข้องและวิธีการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนัง

ศึกษาทฤษฎีที่เกี่ยวข้องประกอบด้วย วิธีการปรับปรุงภาพและการดึงคุณลักษณะที่สำคัญของภาพถ่ายเยื่อผิวหนังภายในบริเวณปากมดลูก วิธีการแต่งเติมข้อมูล วิธีการสร้างตัวแบบในการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนัง และวิธีการประเมินประสิทธิภาพของตัวแบบ

3.1.2 การรวบรวมข้อมูลผู้ป่วยตามการอ่านผลโดยพยาธิแพทย์

รวบรวมข้อมูลภาพถ่ายเยื่อผิวหนังภายในบริเวณปากมดลูกและรายละเอียดการอ่านผลโดยพยาธิแพทย์ของกลุ่มตัวอย่างผ่านโปรแกรม EV Insite: DICOM Viewer Software version

3.1.3.0

3.1.3 การเตรียมข้อมูลและคัดกรองข้อมูล

คัดกรองข้อมูลภาพถ่ายเยื่อผิวหนังภายในบริเวณปากมดลูกให้เหลือข้อมูลภาพถ่ายเพียง 1 รูป และเป็นรูปภาพการตรวจประเภทเดียวกันต่อการคัดกรอง 1 ครั้ง เพื่อใช้เป็นชุดข้อมูลเรียนรู้ของตัวแบบเพื่อไม่ให้เกิดปัญหาการเรียนรู้ที่เกินพอดี

3.1.4 ทดลองเพิ่มจำนวนข้อมูลด้วยวิธีการพลิกรูปภาพ/ เพิ่มความเข้มของสี/ ขยายภาพ/ ปรับสีเป็นขาวดำ

เพิ่มจำนวนข้อมูลภาพถ่ายเยื่อผิวหนังภายในบริเวณปากมดลูกในระดับต่างๆ ให้มีจำนวนที่สมดุลกันในทุกๆระดับ เพื่อป้องกันปัญหาการเรียนรู้ที่เกินพอดี โดยใช้วิธีการพลิกรูปภาพ (Flip), การเพิ่มความเข้มของสี (Increase saturation), การขยายภาพ (Zoom) และการปรับรูปภาพสีเป็นรูปภาพสเกลสีเทา (Convert to grayscale)

3.1.5 ทดลองการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนัง กับวิธีการเรียนรู้จากระบบโครงข่ายประสาทเทียม

ทดลองฝึกสอนตัวแบบเพื่อหาคุณลักษณะที่สำคัญของภาพถ่ายเยื่อผิวหนังภายในบริเวณปากมดลูกที่มีประสิทธิภาพสูงสุด

3.1.6 ทดลองปรับค่าพารามิเตอร์ที่ใช้ในการสร้างตัวแบบในการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนัง

ทำการทดลองปรับค่าพารามิเตอร์ที่ใช้ในการสร้างตัวแบบในการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนัง เพื่อให้ได้ตัวแบบที่มีประสิทธิภาพสูงที่สุดในการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนัง

3.1.7 ประเมินผลการทดลองการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนัง

ทดสอบตัวแบบที่สร้างขึ้นโดยใช้ค่าความถูกต้องของชุดข้อมูลทดสอบ (Validation Accuracy) เป็นเกณฑ์ในการวัดประสิทธิภาพของตัวแบบ

3.1.8 วิเคราะห์และสรุปผลการทดลอง

รวบรวมผลลัพธ์ที่ได้จากการทดลองทั้งหมดมาวิเคราะห์และสรุปผลว่าตัวแบบใดที่มีประสิทธิภาพในการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนังสูงที่สุด

3.2 ขั้นตอนวิธีการรวบรวมข้อมูลผู้ป่วย

ขั้นตอนวิธีการรวบรวมข้อมูลผู้ป่วยที่เป็นกลุ่มตัวอย่างของงานวิจัย จะต้องทำการรวบรวมข้อมูลจากโปรแกรม EV Insite: DICOM Viewer Software version 3.13.3.0 ซึ่งเป็นโปรแกรมที่ใช้ในการอ่านผลภาพถ่ายเยื่อผิวหนังภายในบริเวณปากมดลูกที่มีรายละเอียดของภาพถ่ายต่างๆ (Metadata) ที่สามารถระบุถึงระดับความผิดปกติของเนื้อเยื่อผิวหนังที่มีการอ่านผลโดยพยาธิแพทย์ที่มีประสบการณ์ในการวินิจฉัย ที่ถูกจัดเก็บอยู่ในไฟล์รูปแบบบิตแมป (Bitmap) ที่มีความละเอียดของรูปภาพเท่ากับ 1920x1080 Pixel

3.2.1 การรวบรวมข้อมูลภาพถ่ายเยื่อผิวหนังภายในบริเวณปากมดลูก

ภาพถ่ายเยื่อผิวหนังภายในบริเวณปากมดลูกที่ใช้ในการศึกษาครั้งนี้คือภาพถ่ายจากที่มาจากการคัดกรอง โดยแพทย์จะทำการถ่ายภาพเยื่อผิวหนังรวมไปถึงการย้อมบริเวณเยื่อผิวหนังด้วยน้ำเกลือหรือไอโอดีน เพื่อให้ภาพถ่ายที่ได้มีความชัดเจนในการวินิจฉัยหากมีความผิดปกติเกิดขึ้นที่บริเวณเยื่อผิวหนัง ทำให้ได้จำนวนภาพถ่ายที่แบ่งตามระดับความผิดปกติของเนื้อเยื่อผิวหนังของกลุ่มตัวอย่างตามมาตรฐาน Bethesda Classification 2001 ระหว่างเดือน มีนาคม 2564 ถึง ธันวาคม 2565 โดยสามารถแบ่งข้อมูลออกเป็น 4 กลุ่ม คือ Normal จำนวน 701 ภาพ, Low Grade Lesion (LGL)

จำนวน 2,359 ภาพ, High Grade Lesion (HGL) จำนวน 498 ภาพ และ Cancer จำนวน 62 ภาพ แสดงดังตารางที่ 3.1

ตารางที่ 3.1 จำนวนภาพถ่ายที่แบ่งตามระดับความผิดปกติของเนื้อเยื่อผิวหนังตามมาตรฐาน Bethesda Classification 2001 ของกลุ่มตัวอย่าง ระหว่างเดือน มีนาคม 2564 ถึง ธันวาคม 2565

ความผิดปกติของเนื้อเยื่อผิวหนัง	จำนวน (ภาพ)		
	เดือน มีนาคม - ธันวาคม 2564	เดือน มกราคม - ธันวาคม 2565	รวม
Normal	224	477	701
LGL	877	1482	2359
HGL	168	330	498
Cancer	62	0	62
รวม	1331	2289	3620

3.2.2 เลือกภาพถ่ายเยื่อผิวหนังภายในบริเวณปากมดลูก

เนื่องจากภาพถ่ายเยื่อผิวหนังภายในบริเวณปากมดลูกที่ทำการถ่ายในการวินิจฉัยในแต่ละครั้งมีความแตกต่างกันตามดุลยพินิจของแพทย์ ทำให้จำนวนและประเภทของรูปภาพที่ได้มีความแตกต่างกันทั้งในด้านจำนวนและรูปแบบการเตรียมเยื่อผิวหนังภายในบริเวณปากมดลูก แสดงดังรูปที่ 3.2 จึงต้องทำการคัดเลือกภาพถ่ายเนื้อเยื่อผิวหนัง แบบซัลโมปากมดลูกด้วยน้ำเกลือ (Normal Saline Solution) ที่เป็นรูปแบบพื้นฐานของการถ่ายภาพเพื่อวินิจฉัย และคัดเลือกภาพถ่ายที่ได้จากการคัดกรองในแต่ละครั้งจำนวน 1 รูปภาพด้วยมือ เพื่อป้องกันปัญหาการเรียนรู้ที่เกินพอดีในการสร้างตัวแบบ

	A	B	C	D	E	F	G	H	I	J	K
1	No.	Patient ID	Patient sex	Study date and time	Patient age	Patient birthdate	Modality	Accession No.	Proc Description	Number of images	Grades
2	1	620141743	F	25-Feb-2022 10:58:00 AM	039Y	24-Dec-1982	ES	GY65021271-GY005	Colpo	4	Normal
3	2	640522864	F	23-Feb-2022 12:25:00 PM	029Y	30-Nov-1992	ES	GY65021113-GY005	Colpo	6	LGL
4	3	650003027	F	23-Feb-2022 11:30:00 AM	052Y	21-Jun-1969	ES	GY65021104-GY005	Colpo	3	LGL
5	4	650022856	F	22-Feb-2022 11:05:00 AM	033Y	25-Jun-1988	ES	GY65021050-GY005	Colpo	1	Normal
7	6	620270359	F	19-Feb-2022 2:59:00 PM	045Y	30-Oct-1976	ES	GY65020954-GY005	Colpo	7	LGL
9	8	640440508	F	18-Feb-2022 5:55:00 PM	061Y	15-Mar-1960	ES	GY65020918-GY005	Colpo	3	HGL
10	9	620019614	F	15-Feb-2022 12:20:00 PM	028Y	21-Nov-1993	ES	GY65020758-GY005	Colpo	7	LGL
11	10	620157373	F	14-Feb-2022 2:44:00 PM	046Y	21-Oct-1975	ES	GY65020717-GY005	Colpo	5	LGL
12	11	580000243	F	11-Feb-2022 11:46:00 AM	046Y	11-Jul-1975	ES	GY65020570-GY005	Colpo	3	Normal
14	13	640099808	F	10-Feb-2022 10:11:00 AM	067Y	17-Mar-1954	ES	GY65020492-GY005	Colpo	4	Normal
16	15	620237997	F	09-Feb-2022 4:51:00 PM	042Y	18-Mar-1979	ES	GY65020467-GY005	Colpo	5	LGL
17	16	640497113	F	09-Feb-2022 2:48:00 PM	025Y	18-Aug-1996	ES	GY65020459-GY005	Colpo	6	LGL


รูปที่ 3.2 ข้อมูลแสดงจำนวนภาพถ่ายที่มีในแต่ละครั้งของการวินิจฉัย

3.3 การใช้เทคนิคในการเพิ่มปริมาณภาพถ่าย

เทคนิคการเพิ่มปริมาณภาพถ่ายในการศึกษาครั้งนี้ มีจุดประสงค์เพื่อให้จำนวนของภาพถ่ายมีจำนวนที่ใกล้เคียงกัน โดยใช้เทคนิควิธีการพลิกรูปภาพ (Flip), การเพิ่มความเข้มของสี (Increase saturation), การขยายภาพ (Zoom) และการปรับรูปภาพสีเป็นรูปภาพสเกลสีเทา (Convert to grayscale) ซึ่งเป็นเทคนิคที่ใกล้เคียงกับการถ่ายภาพเยื่ออุ้งฉี่ภายในบริเวณปากมดลูกที่แพทย์ถ่ายเพื่อวินิจฉัยมากที่สุด

3.4 ขั้นตอนการจำแนกระดับความผิดปกติของเนื้อเยื่ออุ้งฉี่

การจำแนกระดับความผิดปกติของเนื้อเยื่ออุ้งฉี่ในการศึกษาครั้งนี้ ใช้วิธีการสร้างตัวแบบจาก ระบบโครงข่ายประสาทเทียมแบบสังวัตนาการ (CNN) ในการจำแนกภาพออกเป็นกลุ่มตามลักษณะความผิดปกติ โดยมีขั้นตอน แสดงดังรูปที่ 3.3



รูปที่ 3.3 ขั้นตอนการจำแนกระดับความผิดปกติของเนื้อเยื่อบุผิว

3.4.1 เตรียมภาพถ่ายเยื่อบุผิวภายในบริเวณปากมดลูก

ข้อมูลภาพถ่ายเยื่อบุผิวภายในบริเวณปากมดลูกหลังจากผ่านการคัดเลือกเฉพาะภาพถ่ายเนื้อเยื่อบุผิวแบบซิโลมปากมดลูกด้วยน้ำเกลือ (Normal Saline Solution) และภาพถ่ายที่ได้จากการคัดกรองในแต่ละครั้งจำนวน 1 รูปภาพด้วยมือ ทำให้ได้ภาพถ่ายของแต่ละกลุ่ม คือ Normal จำนวน 105 ภาพ, Low Grade Lesion (LGL) จำนวน 261 ภาพ, High Grade Lesion (HGL) จำนวน 48 ภาพ และ Cancer จำนวน 3 ภาพ เนื่องจากภาพถ่ายของกลุ่ม Cancer มีจำนวนน้อย และจากการสอบถามทางแพทย์พบว่า ลักษณะความผิดปกติในกลุ่มของ Cancer นั้นแพทย์สามารถวินิจฉัยลักษณะได้ถูกต้องแล้ว เพราะมีลักษณะความผิดปกติที่เด่นชัด ทำให้การศึกษารังนี้ จะนำรูปภาพในกลุ่มของ Cancer ออกจากตัวแบบในการจำแนก ทำให้ได้จำนวนภาพถ่ายที่ผ่านการคัดเลือกด้วยมือเพื่อสร้างตัวแบบ แสดงดังตารางที่ 3.2

ตารางที่ 3.2 จำนวนภาพถ่ายที่ผ่านการคัดเลือกด้วยมือเพื่อสร้างตัวแบบ แบ่งตามระดับความผิดปกติของเนื้อเยื่อผิวหนัง

ความผิดปกติของเนื้อเยื่อผิวหนัง	จำนวน (ภาพ)		
	เดือน มีนาคม - ธันวาคม	เดือน มกราคม - ธันวาคม	รวม
	2564	2565	
Normal	37	68	105
LGL	105	156	261
HGL	19	29	48
รวม	164	253	414

LGL = Low Grade Lesion, HGL = High Grade Lesion

โดยใช้เทคนิคในการเพิ่มปริมาณภาพถ่ายโดยใช้เทคนิค 4 รูปแบบ ดังนี้

3.4.1.1 เทคนิคการพลิกรูปภาพ (Flip)


นำภาพถ่ายต้นฉบับที่มีมาผ่านกระบวนการพลิกรูปภาพจากด้านซ้ายมาอยู่ที่ด้านขวา โดยมีจุดประสงค์เพื่อการเพิ่มจำนวนภาพถ่ายในชุดข้อมูลและให้ภาพถ่ายมีความแตกต่างกัน โดยยังมีองค์ประกอบที่สำคัญของภาพถ่ายอยู่อย่างครบถ้วน มีคำสั่งในการดำเนินการดังรูปที่ 3.4 และได้ผลการดำเนินการดังรูปที่ 3.5

```
# Define the input and output directories
input_dir = IMG_PATH
output_dir = "/content/drive/MyDrive/IS/Colpo_Zoom60_Flip_Satu/HGL"

# Create the output directory if it doesn't exist
if not os.path.exists(output_dir):
    os.makedirs(output_dir)

# Define a sequence of augmentations
seq = iaa.Sequential([
    iaa.Fliplr(1), # horizontally flip the images
])
```

รูปที่ 3.4 คำสั่งในการดำเนินการพลิกรูปภาพ



รูปที่ 3.5 ผลการดำเนินการพลิกรูปภาพ (ด้านซ้าย – ภาพถ่ายต้นฉบับ, ด้านขวา ภาพถ่ายหลังดำเนินการพลิกรูปภาพ)

3.4.1.2 เทคนิคการเพิ่มความเข้มของสี (Increase saturation)

นำภาพถ่ายต้นฉบับมาดำเนินการเพิ่มค่า Saturation ของภาพถ่ายให้เป็น 2 เท่า จากค่าเดิม เพื่อเพิ่มความเข้มของสีที่แสดงออกมาในภาพถ่าย ซึ่งทำให้ได้ภาพถ่ายที่มีสีที่ชัดเจนขึ้น มีคำสั่งในการดำเนินการดังรูปที่ 3.6 และได้ผลการดำเนินการดังรูปที่ 3.7

```
# Define the input and output directories
input_dir = IMG_PATH
output_dir = "/content/drive/MyDrive/IS/Colpo Satu_forModel/Normal"

# Create the output directory if it doesn't exist
if not os.path.exists(output_dir):
    os.makedirs(output_dir)

# Define the Max RGB filter as an augmentation
max_rgb = iaa.Sequential([
    iaa.MultiplySaturation(2),
])
```

รูปที่ 3.6 คำสั่งในการเพิ่มความเข้มของสี



รูปที่ 3.7 ผลการดำเนินการเพิ่มความเข้มของสี (ด้านซ้าย – ภาพถ่ายต้นฉบับ, ด้านขวา ภาพถ่ายหลังดำเนินการเพิ่มความเข้มของสี)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.4.1.3 เทคนิคการขยายภาพ (Zoom)


นำภาพถ่ายต้นฉบับมาดำเนินการขยายภาพเพื่อลดขอบภาพถ่ายให้ส่วนของกลางภาพถ่ายมีขนาดของที่ใหญ่ขึ้น โดยเป็นการเพิ่มคุณลักษณะที่สำคัญของภาพถ่าย มีคำสั่งในการดำเนินการดังรูปที่ 3.8 และได้ผลการดำเนินการดังรูปที่ 3.9

```
# Define the input and output directories
input_dir = IMG_PATH
output_dir = "/content/drive/MyDrive/IS/Colpo_Zoom60/HGL"

# Create the output directory if it doesn't exist
if not os.path.exists(output_dir):
    os.makedirs(output_dir)

# Define a sequence of augmentations
seq = iaa.Sequential([
    iaa.Affine(
        scale=(1.7, 1.7)
    )
])
```

รูปที่ 3.8 คำสั่งในการขยายภาพ (จากภาพเป็นการขยายรูปภาพที่ 70%)



รูปที่ 3.9 ผลการดำเนินการขยายภาพ (ด้านซ้าย - ภาพถ่ายต้นฉบับ, ด้านขวา ภาพถ่ายหลังการขยายภาพ 70%)

3.4.1.4 เทคนิคการปรับรูปภาพสีเป็นรูปภาพสเกลสีเทา (Convert to grayscale)

นำภาพถ่ายต้นฉบับมาดำเนินการลดค่าสีให้เหลือค่าสีที่เป็นสีขาวหรือสีดำเท่านั้น เพื่อลดคุณลักษณะที่สำคัญของสีที่แสดงออกมาในภาพถ่าย เพื่อเพิ่มความท้าทายในการเรียนรู้ภาพถ่ายของตัวแบบ มีคำสั่งในการดำเนินการดังรูปที่ 3.10 และได้ผลการดำเนินการดังรูปที่ 3.11

```

# Define the input and output directories
input_dir = IMG_PATH
output_dir = "/content/drive/MyDrive/IS/Colpo_Grayscale/LGL"

# Create the output directory if it doesn't exist
if not os.path.exists(output_dir):
    os.makedirs(output_dir)

# Define a sequence of augmentations
seq = iaa.Sequential([
    iaa.Grayscale(alpha=(1.0))
])

```

รูปที่ 3.10 คำสั่งในการปรับรูปภาพสีเป็นรูปภาพสเกลสีเทา



รูปที่ 3.11 ผลการดำเนินการปรับรูปภาพสีเป็นรูปภาพสเกลสีเทา (ด้านซ้าย – ภาพถ่ายต้นฉบับ, ด้านขวาภาพถ่ายหลังดำเนินการปรับรูปภาพสีเป็นรูปภาพสเกลสีเทา)

หลังจากใช้เทคนิคในการเพิ่มปริมาณภาพถ่ายจากเทคนิคต่างๆ จะได้ชุดข้อมูลจำนวน 4 ชุด ที่มีการเพิ่มปริมาณภาพถ่ายโดยเทคนิคต่างๆ ดังตารางที่ 3.3 - 3.6

ตารางที่ 3.3 รายละเอียดภาพถ่ายที่ผ่านการเพิ่มปริมาณโดยเทคนิคการเพิ่มปริมาณ ชุดที่ 1

ชุดภาพถ่ายที่ 1								
เขตของการเพิ่มภาพถ่าย	เทคนิคการขยายภาพ	เทคนิคการพลิกรูปภาพจากซ้าย-ขวา	เทคนิคการเพิ่มความเข้มของสี 2 เท่า	เทคนิคการปรับรูปภาพสีเป็นรูปภาพสเกลสีเทา	จำนวนรูปภาพ			
					Normal	LGL	HGL	รวม
ภาพถ่ายต้นฉบับ	-	-	-	-	105	261	48	414
การเพิ่มภาพถ่าย ชุดที่ 1.1	-	✓	-	-	105	239	48	392
การเพิ่มภาพถ่าย ชุดที่ 1.2	50%	-	-	-	105	-	48	153
การเพิ่มภาพถ่าย ชุดที่ 1.3	50%	✓	-	-	105	-	48	153
การเพิ่มภาพถ่าย ชุดที่ 1.4	30%	-	-	-	80	-	48	128
การเพิ่มภาพถ่าย ชุดที่ 1.5	30%	✓	-	-	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 1.6	40%	-	-	-	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 1.7	70%	-	-	-	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 1.8	70%	✓	-	-	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 1.9	10%	-	-	-	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 1.10	10%	✓	-	-	-	-	20	20
รวมชุดภาพถ่ายที่ 1					500	500	500	1500

LGL = Low Grade Lesion, HGL = High Grade Lesion

ตารางที่ 3.4 รายละเอียดภาพถ่ายที่ผ่านการเพิ่มปริมาณโดยเทคนิคการเพิ่มปริมาณ ชุดที่ 2

ชุดภาพถ่ายที่ 2								
เขตของการเพิ่มภาพถ่าย	เทคนิคการขยายภาพ	เทคนิคการพลิกรูปภาพจากซ้าย-ขวา	เทคนิคการเพิ่มความเข้มของสี 2 เท่า	เทคนิคการปรับรูปภาพสีเป็นรูปภาพสเกลสีเทา	จำนวนรูปภาพ			
					Normal	LGL	HGL	รวม
การเพิ่มภาพถ่าย ชุดที่ 2.1	-	-	✓	-	105	261	48	414
การเพิ่มภาพถ่าย ชุดที่ 2.2	-	✓	✓	-	105	239	48	392
การเพิ่มภาพถ่าย ชุดที่ 2.3	50%	-	✓	-	105	-	48	153
การเพิ่มภาพถ่าย ชุดที่ 2.4	50%	✓	✓	-	105	-	48	153
การเพิ่มภาพถ่าย ชุดที่ 2.5	30%	-	✓	-	80	-	48	128
การเพิ่มภาพถ่าย ชุดที่ 2.6	30%	✓	✓	-	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 2.7	40%	-	✓	-	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 2.8	70%	-	✓	-	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 2.9	70%	✓	✓	-	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 2.10	10%	-	✓	-	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 2.11	10%	✓	✓	-	-	-	20	20
รวมชุดภาพถ่ายที่ 2					500	500	500	1500

LGL = Low Grade Lesion, HGL = High Grade Lesion

ตารางที่ 3.5 รายละเอียดภาพถ่ายที่ผ่านการเพิ่มปริมาณโดยเทคนิคการเพิ่มปริมาณ ชุดที่ 3

ชุดภาพถ่ายที่ 3								
เขตของการเพิ่มภาพถ่าย	เทคนิคการขยายภาพ	เทคนิคการพลิกรูปภาพจากซ้าย-ขวา	เทคนิคการเพิ่มความเข้มของสี 2 เท่า	เทคนิคการปรับรูปภาพสีเป็นรูปภาพสเกลสีเทา	จำนวนรูปภาพ			
					Normal	LGL	HGL	รวม
การเพิ่มภาพถ่าย ชุดที่ 3.1	-	-	✓	-	105	261	48	414
การเพิ่มภาพถ่าย ชุดที่ 3.2	70%	-	✓	-	105	239	48	392
การเพิ่มภาพถ่าย ชุดที่ 3.3	70%	✓	✓	-	105	-	48	153
การเพิ่มภาพถ่าย ชุดที่ 3.4	80%	-	✓	-	105	-	48	153
การเพิ่มภาพถ่าย ชุดที่ 3.5	80%	✓	✓	-	80	-	48	128
การเพิ่มภาพถ่าย ชุดที่ 3.6	50%	-	✓	-	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 3.7	50%	✓	✓	-	-	-	20	20
การเพิ่มภาพถ่าย ชุดที่ 3.8	60%	-	✓	-	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 3.9	60%	✓	✓	-	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 3.10	90%	-	✓	-	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 3.11	90%	✓	✓	-	-	-	48	48
รวมชุดภาพถ่ายที่ 3					500	500	500	1500

LGL = Low Grade Lesion, HGL = High Grade Lesion

ตารางที่ 3.6 รายละเอียดภาพถ่ายที่ผ่านการเพิ่มปริมาณโดยเทคนิคการเพิ่มปริมาณ ชุดที่ 4

ชุดภาพถ่ายที่ 4								
เขตของการเพิ่มภาพถ่าย	เทคนิคการขยายภาพ	เทคนิคการพลิกรูปภาพจากซ้าย-ขวา	เทคนิคการเพิ่มความเข้มของสี 2 เท่า	เทคนิคการปรับรูปภาพสีเป็นรูปภาพสเกลสีเทา	จำนวนรูปภาพ			
					Normal	LGL	HGL	รวม
การเพิ่มภาพถ่าย ชุดที่ 4.1	-	-	-	✓	105	261	48	414
การเพิ่มภาพถ่าย ชุดที่ 4.2	-	✓	-	✓	105	239	48	392
การเพิ่มภาพถ่าย ชุดที่ 4.3	50%	-	-	✓	105	-	48	153
การเพิ่มภาพถ่าย ชุดที่ 4.4	50%	✓	-	✓	105	-	48	153
การเพิ่มภาพถ่าย ชุดที่ 4.5	30%	-	-	✓	80	-	48	128
การเพิ่มภาพถ่าย ชุดที่ 4.6	30%	✓	-	✓	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 4.7	40%	-	-	✓	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 4.8	70%	-	-	✓	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 4.9	70%	✓	-	✓	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 4.10	10%	-	-	✓	-	-	48	48
การเพิ่มภาพถ่าย ชุดที่ 4.11	10%	✓	-	✓	-	-	20	20
รวมชุดภาพถ่ายที่ 4					500	500	500	1500

LGL = Low Grade Lesion, HGL = High Grade Lesion


3.4.1.5 ปรับโครงสร้างการจัดเก็บภาพถ่าย

นำภาพถ่ายต้นฉบับและภาพถ่ายที่ผ่านเทคนิคการเพิ่มปริมาณมาจัดเก็บในโฟลเดอร์ของชุดหลัก ได้จำนวน 4 โฟลเดอร์ โดยแต่ละโฟลเดอร์หลักจะมีโฟลเดอร์ย่อยที่แบ่งออกเป็น 3 โฟลเดอร์ตามจำนวนระดับความผิดปกติของเนื้อเยื่อผิวหนังที่กำหนดไว้ โดยมีรายละเอียดดังนี้


3.4.1.5.1 โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 1

โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 1 ถูกจัดเก็บไว้ในโฟลเดอร์หลักที่มีโฟลเดอร์ย่อย 3 โฟลเดอร์คือ HGL, LGL และ Normal โดยที่ข้อมูลภาพถ่ายจะมาจากภาพถ่ายต้นฉบับและภาพถ่ายที่ใช้เทคนิคการเพิ่มปริมาณภาพถ่ายโดยเทคนิควิธีการพลิกรูปภาพ (Flip) และเทคนิคการขยายภาพ (Zoom) แบบ 10%, 30%, 40%, 50% และ 70% ดังรูปที่ 3.12 โดยโฟลเดอร์ HGL มีจำนวนภาพถ่าย 500 รูป, โฟลเดอร์ LGL มีจำนวนภาพถ่าย 500 รูป และโฟลเดอร์ Normal มีจำนวนภาพถ่าย 500 รูป โดยรูปทั้งหมดถูกบันทึกไว้ในรูปแบบ Bitmap (.bmp) ดังรูปที่


3.13



รูปที่ 3.12 โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 1 และเทคนิคที่ใช้ในการเพิ่มปริมาณภาพถ่าย




(a)



(b)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




(c)

รูปที่ 3.13 ภาพถ่ายเยื่อบุผิวภายในบริเวณปากมดลูก จากข้อมูลภาพถ่ายชุดที่ 1 หลังใช้เทคนิคการเพิ่มปริมาณภาพ


- (a) ภาพตัวอย่างของข้อมูลภาพถ่ายชุดที่ 1 หลังใช้เทคนิคการเพิ่มปริมาณภาพ ในโพลเดอรัยย่อย HGL
- (b) ภาพตัวอย่างของข้อมูลภาพถ่ายชุดที่ 1 หลังใช้เทคนิคการเพิ่มปริมาณภาพ ในโพลเดอรัยย่อย LGL
- (c) ภาพตัวอย่างของข้อมูลภาพถ่ายชุดที่ 1 หลังใช้เทคนิคการเพิ่มปริมาณภาพ ในโพลเดอรัยย่อย Normal

3.4.1.5.2 โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 2

โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 2 ถูกจัดเก็บไว้ในโพลเดอรัยหลัก ที่มีโพลเดอรัยย่อย 3 โพลเดอรัยคือ HGL, LGL และ Normal โดยที่ข้อมูลภาพถ่ายจะมาจากภาพถ่ายต้นฉบับและภาพถ่ายที่ใช้เทคนิคการเพิ่มปริมาณภาพถ่ายโดยเทคนิควิธีการพลิกรูปภาพ (Flip), เทคนิคการขยายภาพ (Zoom) แบบ 10%, 30%, 40%, 50% และ 70% และเทคนิคการเพิ่มความเข้มของสี (Increase saturation) ดังรูปที่ 3.14 โดยโพลเดอรัย HGL มีจำนวนภาพถ่าย 500 รูป, โพลเดอรัย LGL มีจำนวนภาพถ่าย 500 รูป และโพลเดอรัย Normal มีจำนวนภาพถ่าย 500 รูป โดยรูปทั้งหมดถูกบันทึกไว้ในรูปแบบ Bitmap (.bmp) ดังรูปที่ 3.15




รูปที่ 3.14 โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 2 และเทคนิคที่ใช้ในการเพิ่มปริมาณภาพถ่าย



(a)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



(b)



(c)

รูปที่ 3.15 ภาพถ่ายเยื่อบุผิวภายในบริเวณปากมดลูก จากข้อมูลภาพถ่ายชุดที่ 2 หลังใช้เทคนิคการเพิ่มปริมาณภาพ

(a) ภาพตัวอย่างของข้อมูลภาพถ่ายชุดที่ 2 หลังใช้เทคนิคการเพิ่มปริมาณภาพ ในโฟลเดอร์ย่อย HGL

(b) ภาพตัวอย่างของข้อมูลภาพถ่ายชุดที่ 2 หลังใช้เทคนิคการเพิ่มปริมาณภาพ ในโฟลเดอร์ย่อย LGL

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


(c) ภาพตัวอย่างของข้อมูลภาพถ่ายชุดที่ 2 หลังใช้เทคนิคการเพิ่มปริมาณภาพ ในโพลเดอรร้อยย Normal

3.4.1.5.3 โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 3


โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 3 ถูกจัดเก็บไว้ในโพลเดอร์หลัก ที่มีโพลเดอรร้อยย 3 โพลเดอร์คือ HGL, LGL และ Normal โดยที่ข้อมูลภาพถ่ายจะมาจากภาพถ่ายต้นฉบับและภาพถ่ายที่ใช้เทคนิคการเพิ่มปริมาณภาพถ่ายโดยเทคนิควิธีการพลิกรูปภาพ (Flip), เทคนิคการขยายภาพ (Zoom) แบบ 50%, 60%, 70%, 80% และ 90% และเทคนิคการเพิ่มความเข้มของสี (Increase saturation) ดังรูปที่ 3.16 โดยโพลเดอร์ HGL มีจำนวนภาพถ่าย 500 รูป, โพลเดอร์ LGL มีจำนวนภาพถ่าย 500 รูป และโพลเดอร์ Normal มีจำนวนภาพถ่าย 500 รูป โดยรูปทั้งหมดถูกบันทึกไว้ในรูปแบบ Bitmap (.bmp) ดังรูปที่ 3.17



รูปที่ 3.16 โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 3 และเทคนิคที่ใช้ในการเพิ่มปริมาณภาพถ่าย




(a)



(b)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



(c)


รูปที่ 3.17 ภาพถ่ายเยื่อบุผิวภายในบริเวณปากมดลูก จากข้อมูลภาพถ่ายชุดที่ 3 หลังใช้เทคนิคการเพิ่มปริมาณภาพ

- (a) ภาพตัวอย่างของข้อมูลภาพถ่ายชุดที่ 3 หลังใช้เทคนิคการเพิ่มปริมาณภาพ ในโพลเดอร้อยย HGL
- (b) ภาพตัวอย่างของข้อมูลภาพถ่ายชุดที่ 3 หลังใช้เทคนิคการเพิ่มปริมาณภาพ ในโพลเดอร้อยย LGL
- (c) ภาพตัวอย่างของข้อมูลภาพถ่ายชุดที่ 3 หลังใช้เทคนิคการเพิ่มปริมาณภาพ ในโพลเดอร้อยย Normal


3.4.1.5.4 โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 4

โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 4 ถูกจัดเก็บไว้ในโพลเดอร้อยยหลัก ที่มีโพลเดอร้อยย 3 โพลเดอร้อยยคือ HGL, LGL และ Normal โดยที่ข้อมูลภาพถ่ายจะมาจากภาพถ่ายต้นฉบับและภาพถ่ายที่ใช้เทคนิคการเพิ่มปริมาณภาพถ่ายโดยเทคนิควิธีการพลิกรูปภาพ (Flip), เทคนิคการขยายภาพ (Zoom) แบบ 10%, 30%, 40%, 50% และ 70% และเทคนิคการปรับรูปภาพสีเป็นรูปภาพสเกลสีเทา (Convert to grayscale) ดังรูปที่ 3.18 โดยโพลเดอร้อยย HGL มีจำนวนภาพถ่าย 500 รูป, โพลเดอร้อยย LGL มีจำนวนภาพถ่าย 500 รูป และโพลเดอร้อยย Normal มีจำนวน

ภาพถ่าย 500 รูป โดยรูปทั้งหมดถูกบันทึกไว้ในรูปแบบ Bitmap (.bmp) ดังรูปที่ 3.19



รูปที่ 3.18 โครงสร้างการจัดเก็บข้อมูลภาพถ่ายชุดที่ 4 และเทคนิคที่ใช้ในการเพิ่มปริมาณภาพถ่าย



(a)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.19 ภาพถ่ายเยื่อบุผิวภายในบริเวณปากมดลูก จากข้อมูลภาพถ่ายชุดที่ 4 หลังใช้เทคนิคการเพิ่มปริมาณภาพ

(d) ภาพตัวอย่างของข้อมูลภาพถ่ายชุดที่ 4 หลังใช้เทคนิคการเพิ่มปริมาณภาพ ในโฟลเดอร์ย่อย HGL

(e) ภาพตัวอย่างของข้อมูลภาพถ่ายชุดที่ 4 หลังใช้เทคนิคการเพิ่มปริมาณภาพ ในโฟลเดอร์ย่อย LGL

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- (f) ภาพตัวอย่างของข้อมูลภาพถ่ายชุดที่ 4 หลังใช้เทคนิคการเพิ่มปริมาณภาพ ในโพลเดอร์ย่อย Normal

3.4.1.6 แบ่งชุดข้อมูลเพื่อการสร้างตัวแบบในการทำนาย

ข้อมูลภาพถ่ายที่ผ่านเทคนิคเพิ่มปริมาณภาพถ่ายจะถูกแบ่งออกเป็น 2 ส่วนคือ ชุดข้อมูลเรียนรู้ (Training Set) และ ชุดข้อมูลทดสอบ (Testing Set) ซึ่งการศึกษารั้งนี้ จะแบ่งข้อมูลโดยใช้สัดส่วน 70:30 ระหว่างชุดข้อมูลเรียนรู้และชุดข้อมูลทดสอบ และทำการปรับภาพถ่ายให้มีขนาดกว้าง 224 Pixel และ ยาว 224 Pixel เนื่องจากเป็นข้อกำหนดของการใช้สถาปัตยกรรมในการสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อบุผิว โดยใช้คำสั่งดังรูปที่ 3.20

```
seed = 6256
img_height = 224
img_width = 224
batch_size = 32
validation_split=0.3
epochs = 20

train_datagen = ImageDataGenerator(
    validation_split=validation_split
)

train_generator=train_datagen.flow_from_directory(
    folder_path,
    target_size=(img_height,img_width),
    color_mode='rgb',
    class_mode='categorical',
    subset='training',
    shuffle=True,
    seed = seed
)

validation_generator=train_datagen.flow_from_directory(
    folder_path,
    target_size=(img_height,img_width),
    color_mode='rgb',
    class_mode='categorical',
    subset='validation',
    shuffle=True,
    seed = seed
)
```

รูปที่ 3.20 คำสั่งในการปรับขนาดภาพถ่ายและแบ่งชุดข้อมูลออกเป็นชุดข้อมูลเรียนรู้ (70%) และชุดข้อมูลทดสอบ (30%)

3.4.2 จัดเตรียมตัวแบบในการจำแนกความผิดปกติของเนื้อเยื่อปาก

เนื่องจากตัวแบบที่ใช้ในการจำแนกในการศึกษานี้ จะมีการใช้สถาปัตยกรรมในการจำแนกภาพ 3 ตัวแบบเพื่อเปรียบเทียบประสิทธิภาพ โดยผู้วิจัยได้เลือกใช้ตัวแบบที่มีความนิยมในการใช้งานจากงานวิจัยที่เกี่ยวข้องที่ได้กล่าวไปในบทที่ 2 โดยจากงานวิจัยชื่อ MobileNetV2 Ensemble for Cervical Precancerous Lesions Classification ได้ใช้สถาปัตยกรรม MobileNetV2 ซึ่งได้ค่าความถูกต้องที่ 83.33%, งานวิจัยชื่อ MDFI: Multi-CNN Decision Feature Integration for Diagnosis of Cervical Precancerous Lesions ได้ใช้สถาปัตยกรรม ResNet50 ทำให้ได้ค่าความถูกต้องที่ 0.604 และงานวิจัยชื่อ Deep learning based cervical screening by the cross-modal integration of colposcopy, cytology, and HPV test ได้ใช้สถาปัตยกรรม VGG16 ซึ่งได้ค่า AUC ที่ 0.921 ดังนั้นสถาปัตยกรรมที่จะนำมาเปรียบเทียบประสิทธิภาพในการศึกษานี้ ได้แก่ MobileNetV2, ResNet50 และ VGG16 โดยจะมีการกำหนดค่า Hyperparameter ที่ผ่านการทดลองปรับแต่งเปรียบเทียบ แสดงดังตารางที่ 3.7

ตารางที่ 3.7 ค่า Hyperparameter ที่ใช้ในสถาปัตยกรรม MobileNetV2, ResNet50 และ VGG16

Parameter	Value
Activation Function (Hidden Nodes)	Rectified Linear Unit (ReLU)
Activation Function (Output Nodes)	Softmax
Loss Function	Cross Entropy
Optimizer	Adam
Regularizer	L1
Origin Learning Rate	0.001
Adjust Learning Rate Factor	0.1
Min Learning Rate	0.00000001
Callbacks	ReduceLROnPlateau
Callbacks Patience	2
Layer Dropout	0.4 (except Layer 3 rd)
Epoch	20

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Parameter	Value
Batch Size	32
Validation Set	0.3
Evaluation Metric	Validation Accuracy, Validation Sensitivity, Validation Specificity, Validation Area Under Curve (Validation AUC) และ Confusion Matrix

โดยมีคำสั่งในสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนังของสถาปัตยกรรม MobileNetV2, ResNet50 และ VGG16 ดังรูปที่ 3.21 – 3.23



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

model_MNV2.compile(optimizer=optMNV2,
                   loss='categorical_crossentropy',
                   metrics=['accuracy', 'AUC', keras.metrics.Precision(), keras.metrics.Recall(), keras.metrics.SpecificityAtSensitivity(0.5), keras.metrics.SensitivityAtSpecificity(0.5)])

```

```

from keras.applications import MobileNetV2
tf.random.set_seed(8664)
model_MNV2 = tf.keras.models.Sequential([
    MobileNetV2(input_shape=(224,224,3), include_top=False),
])
for layer in model_MNV2.layers:
    layer.trainable = True

model_MNV2.add(Conv2D(64, (3,3), activation='relu', kernel_regularizer=regularizers.l1(0.01)))
model_MNV2.add(Dropout(0.4))
model_MNV2.add(Dense(128, activation='relu', kernel_regularizer=regularizers.l1(0.01)))
model_MNV2.add(Dropout(0.4))
model_MNV2.add(Dense(256, activation='relu', kernel_regularizer=regularizers.l1(0.01)))
model_MNV2.add(MaxPooling2D(2,2))
model_MNV2.add(Flatten())
model_MNV2.add(Dense(512, activation='relu', kernel_regularizer=regularizers.l1(0.01)))
model_MNV2.add(Dropout(0.4))
model_MNV2.add(Dense(3, activation='softmax'))

model_MNV2.summary()

```

รูปที่ 3.21 คำสั่งในการสร้างตัวแบบ MobileNetV2 เพื่อจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนัง

```

model_RN50.compile(optimizer=optRN50,
                  loss='categorical_crossentropy',
                  metrics=['accuracy', 'AUC', keras.metrics.Precision(), keras.metrics.Recall(), keras.metrics.SpecificityAtSensitivity(0.5), keras.metrics.SensitivityAtSpecificity(0.5)])

```

```

from keras.applications import ResNet50
tf.random.set_seed(8664)
model_RN50 = tf.keras.models.Sequential([
    ResNet50(input_shape=(224,224,3), include_top=False),
])
for layer in model_RN50.layers:
    layer.trainable = True

model_RN50.add(Conv2D(64, (3,3), activation='relu', kernel_regularizer=regularizers.l1(0.01)))
model_RN50.add(Dropout(0.4))
model_RN50.add(Dense(128, activation='relu', kernel_regularizer=regularizers.l1(0.01)))
model_RN50.add(Dropout(0.4))
model_RN50.add(Dense(256, activation='relu', kernel_regularizer=regularizers.l1(0.01)))
model_RN50.add(MaxPooling2D(2,2))
model_RN50.add(Flatten())
model_RN50.add(Dense(512, activation='relu', kernel_regularizer=regularizers.l1(0.01)))
model_RN50.add(Dropout(0.4))
model_RN50.add(Dense(3, activation='softmax'))

model_RN50.summary()

```

รูปที่ 3.22 คำสั่งในการสร้างตัวแบบ ResNet50 เพื่อจำแนกระดับความผิดปกติของเนื้อเยื่อปอด

```

model_VGG16.compile(optimizer=optVGG16,
                    loss='categorical_crossentropy',
                    metrics=['accuracy', 'AUC', keras.metrics.Precision(), keras.metrics.Recall(), keras.metrics.SpecificityAtSensitivity(0.5), keras.metrics.SensitivityAtSpecificity(0.5)])

from keras.applications import VGG16
tf.random.set_seed(9477)
model_VGG16 = tf.keras.models.Sequential([
    VGG16(input_shape=(224,224,3), include_top=False),
])
for layer in model_VGG16.layers:
    layer.trainable = True

model_VGG16.add(Conv2D(64, (3,3), activation='relu', kernel_regularizer=regularizers.l1(0.01)))
model_VGG16.add(Dropout(0.4))
model_VGG16.add(Dense(128, activation='relu', kernel_regularizer=regularizers.l1(0.01)))
model_VGG16.add(Dropout(0.4))
model_VGG16.add(Dense(256, activation='relu', kernel_regularizer=regularizers.l1(0.01)))
model_VGG16.add(MaxPooling2D(2,2))
model_VGG16.add(Flatten())
model_VGG16.add(Dense(512, activation='relu', kernel_regularizer=regularizers.l1(0.01)))
model_VGG16.add(Dropout(0.4))
model_VGG16.add(Dense(3, activation='softmax'))

model_VGG16.summary()

```

รูปที่ 3.23 คำสั่งในการสร้างตัวแบบ VGG16 เพื่อจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนัง

เนื่องจากการสร้างตัวแบบมีกำหนดค่า Learning Rate ไว้ที่ 0.001 ซึ่งการปรับปรุงค่าน้ำหนักในแต่ละครั้งอาจจะมีค่าที่แตกต่างกัน การศึกษาครั้งนี้จึงมีการกำหนด Callbacks ที่ใช้ ReduceLROnPlateau ในการปรับปรุงค่า Learning Rate ที่ได้ในแต่ละรอบ โดยใช้ค่าตัวคูณในการปรับปรุงที่ 0.1 ที่มี Callbacks Patience ของค่า Validation Accuracy เท่ากับ 2 และทำการบันทึกตัวแบบที่มีค่า Validation Accuracy สูงที่สุดระหว่างการทดลองสร้างตัวแบบ โดยใช้รูปแบบเดียวกันนี้ทั้ง 3 สถาปัตยกรรมซึ่งมีคำสั่งดังรูปที่ 3.24 – 3.26

```
filename_MNV2 = 'model_MobileNetV2.h5'
checkpoint_MNV2 = ModelCheckpoint(filename_MNV2, monitor='val_accuracy', verbose=1, save_best_only=True, mode='auto')

learning_rate_reduction_MNV2 = ReduceLRonPlateau(monitor='val_accuracy', patience = 2, verbose=1, factor=0.1, min_lr=0.00000001)
callbacks_list_MNV2 = [checkpoint_MNV2, learning_rate_reduction_MNV2]
```

รูปที่ 3.24 คำสั่งในการปรับค่า Learning Rate โดย ReduceLRonPlateau ของสถาปัตยกรรม MobileNetV2

```
filename_RN50 = 'model_ResNet50.h5'
checkpoint_RN50 = ModelCheckpoint(filename_RN50, monitor='val_accuracy', verbose=1, save_best_only=True, mode='auto')

learning_rate_reduction_RN50 = ReduceLRonPlateau(monitor='val_accuracy', patience = 2, verbose=1, factor=0.1, min_lr=0.00000001)
callbacks_list_RN50 = [checkpoint_RN50, learning_rate_reduction_RN50]
```

รูปที่ 3.25 คำสั่งในการปรับค่า Learning Rate โดย ReduceLRonPlateau ของสถาปัตยกรรม ResNet50

```
filename_VGG16 = 'model_VGG16.h5'
checkpoint_VGG16 = ModelCheckpoint(filename_VGG16, monitor='val_accuracy', verbose=1, save_best_only=True, mode='auto')

learning_rate_reduction_VGG16 = ReduceLRonPlateau(monitor='val_accuracy', patience = 2, verbose=1, factor=0.1, min_lr=0.00000001)
callbacks_list_VGG16 = [checkpoint_VGG16, learning_rate_reduction_VGG16]
```

รูปที่ 3.26 คำสั่งในการปรับค่า Learning Rate โดย ReduceLRonPlateau ของสถาปัตยกรรม VGG16

3.4.3 ทดสอบประสิทธิภาพของตัวแบบที่ได้

การทดสอบประสิทธิภาพของตัวแบบในการศึกษาครั้งนี้ จะใช้การทดสอบประสิทธิภาพจากมาตรวัด 4 แบบ ได้แก่ Validation Accuracy, Validation Sensitivity, Validation Specificity, Validation Area Under Curve (Validation AUC) และ Confusion Matrix โดยทำการบันทึกตัวแบบที่มีค่า Validation Accuracy ที่สูงที่สุดใน 20 Epoch มาเป็นตัวแทนของตัวแบบ

3.4.4 วิเคราะห์และสรุปผลการทดลอง

การวิเคราะห์ประสิทธิภาพของตัวแบบในการศึกษาครั้งนี้ จะมีการใช้ค่า Validation Accuracy ที่สูงที่สุดใน 20 Epoch และประกอบกับผลที่ได้จาก Confusion Matrix ในการสรุปผลประสิทธิภาพของตัวแบบ ซึ่งจะกล่าวถึงในบทถัดไป



บทที่ 4

ผลการดำเนินงานและการอภิปรายผล

ในบทนี้จะกล่าวถึงผลการดำเนินการทดลองสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อปมูผิว โดยใช้ชุดข้อมูลภาพถ่ายที่ผ่านการใช้เทคนิคการเพิ่มปริมาณภาพทั้ง 4 ชุดข้อมูล โดยการใช้สถาปัตยกรรมทั้ง 3 แบบ คือ MobileNetV2, ResNet50 และ VGG16 และอภิปรายผลการทดลองรวมถึงปัญหาที่พบในการสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อปมูผิว แสดงดังหัวข้อ 4.1 – 4.6

4.1 การทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรมทั้ง 3 แบบ

การทดลองสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อปมูผิวจากชุดข้อมูลภาพถ่ายชุดที่ 1 โดยใช้สถาปัตยกรรม MobileNetV2, ResNet50 และ VGG16 ซึ่งข้อมูลภาพถ่ายชุดที่ 1 จะเป็นภาพถ่ายต้นฉบับและภาพถ่ายที่ใช้เทคนิคการเพิ่มปริมาณภาพถ่ายโดยเทคนิควิธีการพลิกรูปภาพ (Flip) และเทคนิคการขยายภาพ (Zoom) แบบ 10%, 30%, 40%, 50% และ 70% เพื่อค้นหาองค์ประกอบสำคัญที่มีผลต่อประสิทธิภาพของตัวแบบในการจำแนกระดับความผิดปกติของเนื้อเยื่อปมูผิว โดยมีมาตรวัดประสิทธิภาพคือ Validation Accuracy, Validation Sensitivity, Validation Specificity, Validation Area Under Curve (AUC) และ Confusion Matrix ซึ่งมีรายละเอียดดังหัวข้อ 4.1.1 – 4.1.3

4.1.1 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม MobileNetV2


จากการทดลองสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อปมูผิวจากชุดข้อมูลภาพถ่ายชุดที่ 1 โดยใช้สถาปัตยกรรม MobileNetV2 ได้ผลการทดลองแสดงดังตารางที่ 4.1 และมีกราฟแสดงค่า Accuracy, Validation Accuracy, Loss, Validation Loss, AUC และ Confusion Matrix ดังรูปที่ 4.1 – 4.4

ตารางที่ 4.1 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม MobileNetV2

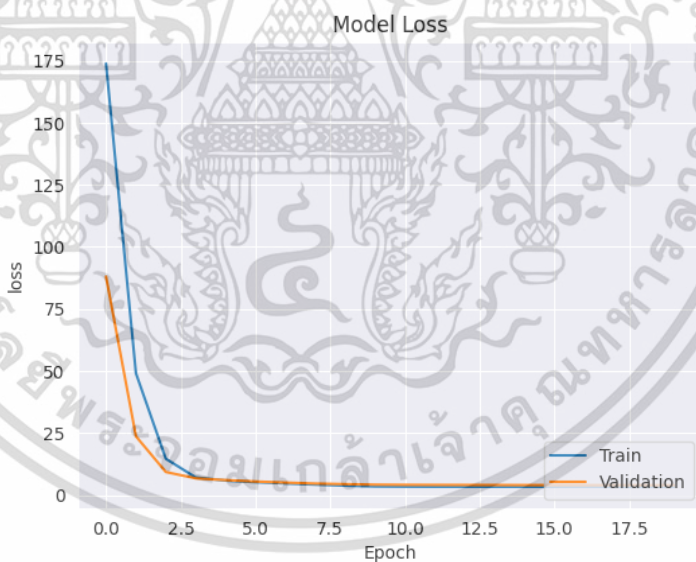
Model for Classification of Cervical Cancer Screening from Colposcopy Image

Dataset No.	1	Architecture	MobileNetV2			
Epoch	Validation Loss	Training Accuracy	Validation Accuracy	Validation Specificity	Validation Sensitivity	Validation AUC
1	88.0108	40.10%	33.33%	41.11%	36.00%	50.48%
2	23.6736	53.71%	33.33%	49.33%	45.11%	51.39%
3	9.2849	66.48%	33.33%	53.00%	54.67%	52.51%
4	6.7351	75.81%	34.22%	56.44%	58.00%	54.27%
5	6.023	80.48%	43.78%	64.22%	65.56%	59.14%
6	5.4556	84.29%	49.78%	73.00%	73.56%	65.89%
7	5.0253	85.62%	51.33%	75.67%	73.78%	67.01%
8	4.639	85.62%	50.67%	74.67%	74.89%	67.15%
9	4.3999	87.24%	44.67%	69.33%	70.00%	63.80%
10	4.1858	87.52%	46.00%	69.33%	72.00%	64.07%
11	4.1164	87.81%	45.11%	70.89%	72.00%	64.20%
12	4.084	87.43%	45.11%	68.56%	71.78%	64.49%
13	4.0613	87.14%	46.89%	69.56%	72.67%	65.37%
14	4.0345	88.10%	48.00%	72.33%	72.89%	66.61%
15	4.0129	87.14%	49.78%	73.33%	74.89%	67.68%
16	3.9997	87.52%	49.56%	74.44%	74.89%	68.36%
17	3.9846	87.05%	49.78%	75.67%	76.89%	69.19%
18	3.9721	87.90%	50.22%	77.00%	77.33%	70.15%
19	3.9644	88.10%	52.22%	76.67%	79.11%	70.56%
20	3.9611	87.24%	52.44%	78.11%	79.33%	70.93%
Average		81.12%	45.48%	68.13%	68.77%	63.66%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

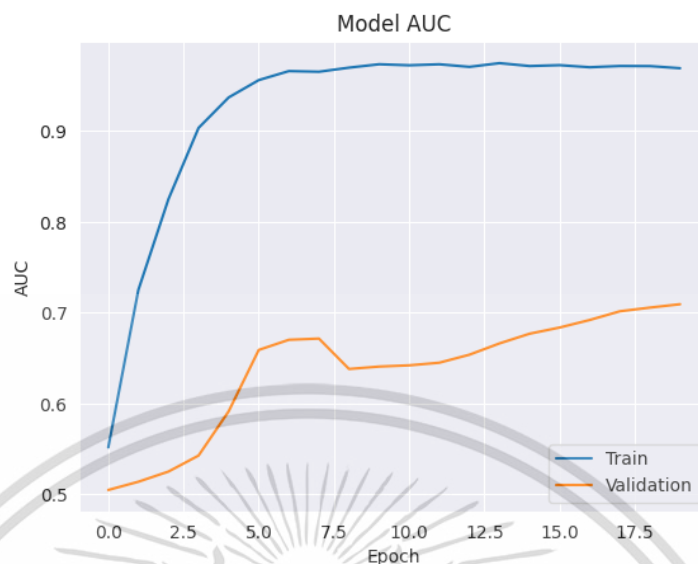


รูปที่ 4.1 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม MobileNetV2

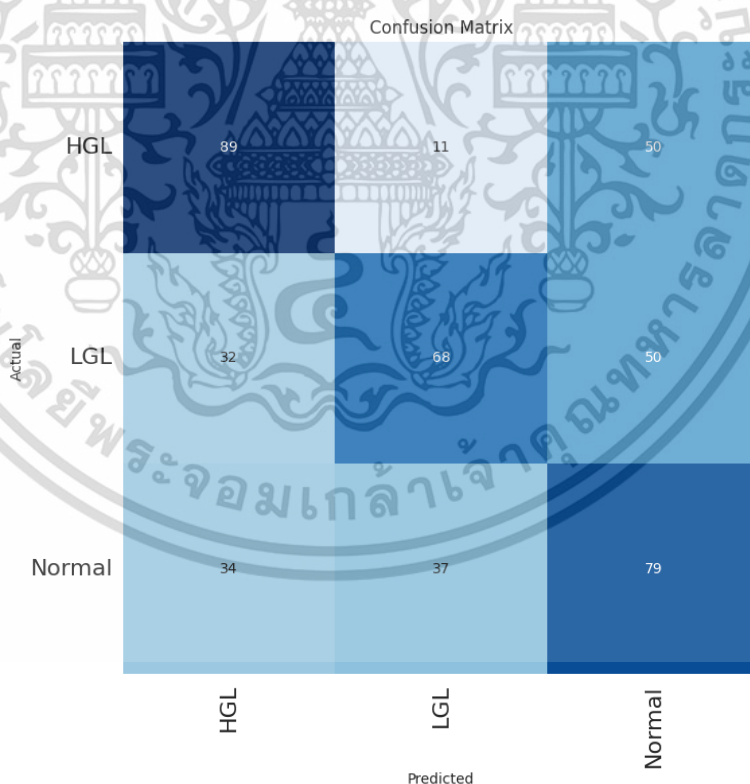


รูปที่ 4.2 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม MobileNetV2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.3 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม MobileNetV2



รูปที่ 4.4 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม MobileNetV2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.1.2 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม ResNet50

จากการทดลองสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนังจากชุดข้อมูลภาพถ่ายชุดที่ 1 โดยใช้สถาปัตยกรรม ResNet50 ได้ผลการทดลองแสดงดังตารางที่ 4.2 และมีกราฟแสดงค่า Accuracy, Validation Accuracy, Loss, Validation Loss, AUC และ Confusion Matrix ดังรูปที่ 4.5 – 4.8




ตารางที่ 4.2 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม ResNet50

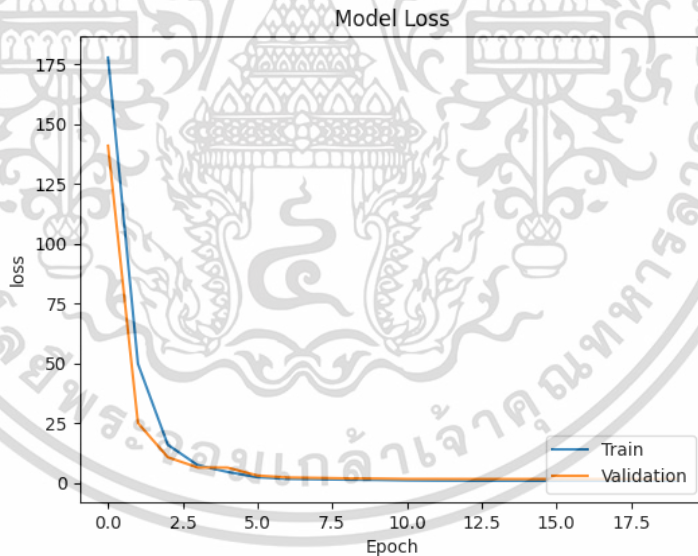
Model for Classification of Cervical Cancer Screening from Colposcopy Image

Dataset No.	1	Architecture	ResNet50			
Epoch	Validation Loss	Training Accuracy	Validation Accuracy	Validation Specificity	Validation Sensitivity	Validation AUC
1	140.9204	46.67%	33.33%	31.44%	33.33%	50.00%
2	25.0838	58.00%	42.67%	65.11%	62.22%	61.57%
3	10.7894	61.81%	53.56%	78.33%	67.56%	66.28%
4	6.5048	62.57%	45.33%	69.00%	64.89%	63.38%
5	6.4528	64.57%	45.11%	67.67%	56.67%	61.85%
6	3.1545	71.33%	54.44%	78.44%	70.00%	69.03%
7	2.3415	80.48%	61.11%	84.33%	81.11%	74.30%
8	2.1692	84.29%	62.44%	85.78%	83.33%	76.77%
9	1.9637	88.00%	56.89%	83.67%	87.78%	74.85%
10	1.8866	90.67%	55.78%	83.00%	84.00%	74.69%
11	1.7083	90.38%	57.56%	84.44%	83.78%	74.80%
12	1.7057	92.29%	56.00%	82.33%	82.22%	74.29%
13	1.677	93.90%	57.78%	84.44%	84.89%	75.68%
14	1.6758	94.29%	58.67%	85.00%	86.89%	76.19%
15	1.6797	93.43%	58.67%	86.78%	88.44%	76.66%
16	1.6861	93.71%	60.00%	87.00%	88.22%	76.86%
17	1.6932	94.38%	60.67%	87.33%	88.89%	76.90%
18	1.699	94.29%	60.22%	87.00%	88.67%	77.02%
19	1.7041	93.05%	60.67%	87.00%	88.44%	77.10%
20	1.7071	94.19%	60.89%	87.11%	88.22%	77.13%
Average		82.12%	55.09%	79.26%	77.98%	71.77%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.5 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม ResNet50




รูปที่ 4.6 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม ResNet50

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.7 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม ResNet50



รูปที่ 4.8 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม ResNet50

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.1.3 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม VGG16

จากการทดลองสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนังจากชุดข้อมูลภาพถ่ายชุดที่ 1 โดยใช้สถาปัตยกรรม VGG16 ได้ผลการทดลองแสดงดังตารางที่ 4.3 และมีกราฟแสดงค่า Accuracy, Validation Accuracy, Loss, Validation Loss, AUC และ Confusion Matrix ดังรูปที่ 4.9 – 4.12




ตารางที่ 4.3 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม VGG16


Model for Classification of Cervical Cancer Screening from Colposcopy Image

Dataset No.	1	Architecture	VGG16			
Epoch	Validation Loss	Training Accuracy	Validation Accuracy	Validation Specificity	Validation Sensitivity	Validation AUC
1	165.8281	35.33%	33.33%	33.33%	33.33%	50.00%
2	120.2615	33.33%	33.33%	34.78%	33.33%	51.99%
3	93.6851	37.24%	56.00%	77.78%	56.89%	67.70%
4	75.1129	55.05%	56.00%	78.56%	77.11%	71.10%
5	60.9841	55.62%	56.89%	80.56%	83.33%	72.89%
6	49.862	58.10%	56.22%	80.33%	79.78%	72.69%
7	41.0429	54.57%	58.00%	83.33%	86.89%	76.15%
8	33.864	55.33%	60.44%	80.78%	86.44%	74.55%
9	28.0662	54.86%	60.44%	81.11%	89.78%	76.87%
10	23.3572	57.90%	60.44%	82.00%	88.00%	76.96%
11	22.2575	59.90%	60.22%	82.44%	88.89%	77.50%
12	21.7866	59.62%	58.44%	82.78%	89.11%	77.49%
13	21.6702	59.33%	59.33%	82.56%	90.22%	77.72%
14	21.6114	58.19%	59.78%	82.56%	90.00%	77.93%
15	21.5992	59.52%	59.78%	82.56%	90.00%	77.94%
16	21.5932	58.86%	59.78%	82.56%	90.00%	77.93%
17	21.592	59.14%	59.78%	82.56%	90.00%	77.93%
18	21.5914	58.76%	59.78%	82.56%	90.00%	77.93%
19	21.5912	58.86%	59.78%	82.56%	90.00%	77.93%
20	21.5912	59.52%	59.78%	82.56%	90.00%	77.93%
Average		54.45%	56.38%	76.91%	80.66%	73.46%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.9 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม VGG16




รูปที่ 4.10 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม VGG16

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.11 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม VGG16



รูปที่ 4.12 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 1 จากสถาปัตยกรรม VGG16

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.1.4 การอภิปรายผลการทดลองตัวแบบที่ได้จากข้อมูลภาพถ่ายชุดที่ 1

ข้อมูลภาพถ่ายชุดที่ 1 มีการใช้เทคนิคการเพิ่มปริมาณภาพถ่ายโดยใช้เทคนิควิธีการพลิกรูปภาพ และเทคนิคการขยายภาพแบบระยะไกลที่ 10%, 30%, 40%, 50% และ 70% เท่านั้น ซึ่งภาพถ่ายที่ได้จะมีลักษณะที่ใกล้เคียงกับรูปภาพต้นฉบับมากที่สุดทั้งในด้านของสีและมุมของภาพถ่าย

พบว่าตัวแบบที่ดีที่สุดจากข้อมูลภาพถ่ายชุดที่ 1 โดยใช้สถาปัตยกรรม ResNet50 จะมีค่า Validation Accuracy เท่ากับ 62.44% ซึ่งมีค่าสูงกว่าสถาปัตยกรรมอื่น โดยสถาปัตยกรรม MobileNetV2 มีค่า Validation Accuracy เท่ากับ 52.44% และสถาปัตยกรรม VGG16 มีค่า Validation Accuracy เท่ากับ 60.44% โดย Confusion Matrix ของสถาปัตยกรรม ResNet50 สามารถจำแนกความผิดปกติระดับ LGL ถูกต้องสูงถึง 146 ภาพจากจำนวนทั้งหมด 150 ภาพ ซึ่งแตกต่างจากสถาปัตยกรรม MobileNetV2 ที่สามารถจำแนกความผิดปกติระดับ HGL และ Normal ได้ดีกว่า แต่สถาปัตยกรรม VGG16 ประสบปัญหาในการจำแนกระดับ Normal ซึ่งเกิดจากสถาปัตยกรรม VGG16 ไม่สามารถเรียนรู้คุณลักษณะสำคัญจากภาพถ่ายของระดับ Normal ได้

4.2 การทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรมทั้ง 3 แบบ

การทดลองสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อบุผิวจากชุดข้อมูลภาพถ่ายชุดที่ 2 โดยใช้สถาปัตยกรรม MobileNetV2, ResNet50 และ VGG16 ซึ่งข้อมูลภาพถ่ายชุดที่ 2 จะเป็นภาพถ่ายที่ใช้เทคนิคการเพิ่มความเข้มของสี (Increase saturation) ที่ดำเนินการกับข้อมูลภาพถ่ายชุดที่ 1 เพื่อทดสอบว่าความเข้มของสีส่งผลต่อประสิทธิภาพการจำแนกระดับความผิดปกติของเนื้อเยื่อบุผิวของตัวแบบหรือไม่ โดยมีมาตรวัดประสิทธิภาพคือ Validation Accuracy, Validation Sensitivity, Validation Specificity และ Validation Area Under Curve (AUC) ซึ่งมีรายละเอียดดังหัวข้อ 4.2.1 – 4.2.3

4.2.1 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม MobileNetV2


จากการทดลองสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อบุผิวจากชุดข้อมูลภาพถ่ายชุดที่ 2 โดยใช้สถาปัตยกรรม MobileNetV2 ได้ผลการทดลองแสดงดังตารางที่ 4.4 และมีกราฟแสดงค่า Accuracy, Validation Accuracy, Loss, Validation Loss, AUC และ Confusion Matrix ดังรูปที่ 4.13 – 4.16

ตารางที่ 4.4 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม MobileNetV2


Model for Classification of Cervical Cancer Screening from Colposcopy Image

Dataset No.	2	Architecture	MobileNetV2			
Epoch	Validation Loss	Training Accuracy	Validation Accuracy	Validation Specificity	Validation Sensitivity	Validation AUC
1	93.802	39.71%	37.78%	50.56%	54.89%	56.73%
2	28.0934	56.76%	34.22%	57.67%	57.78%	56.31%
3	11.2561	68.10%	35.56%	58.33%	58.22%	57.99%
4	8.599	70.10%	36.00%	59.44%	60.67%	59.89%
5	7.7576	72.10%	38.67%	62.44%	63.78%	61.35%
6	7.0678	71.71%	37.78%	63.33%	64.00%	61.74%
7	6.4527	72.29%	37.56%	65.33%	67.33%	62.72%
8	6.2699	71.24%	40.67%	67.00%	69.33%	63.33%
9	6.2197	71.43%	41.78%	66.78%	71.78%	63.08%
10	6.172	72.95%	42.67%	68.67%	71.11%	63.43%
11	6.1262	71.71%	43.56%	68.78%	71.56%	63.71%
12	6.0729	71.24%	44.89%	70.11%	71.11%	63.97%
13	6.0187	71.24%	44.00%	71.00%	72.00%	64.31%
14	5.9682	72.19%	44.00%	70.89%	72.00%	64.31%
15	5.9544	70.48%	46.22%	71.11%	72.22%	64.51%
16	5.9521	70.86%	45.56%	71.56%	74.00%	64.69%
17	5.9527	72.29%	45.56%	71.56%	73.78%	64.73%
18	5.9555	71.33%	45.33%	71.78%	73.56%	64.85%
19	5.9575	71.24%	45.78%	71.67%	74.00%	64.87%
20	5.9593	71.05%	44.44%	71.89%	74.89%	64.98%
Average		69.00%	41.60%	66.50%	68.40%	62.58%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

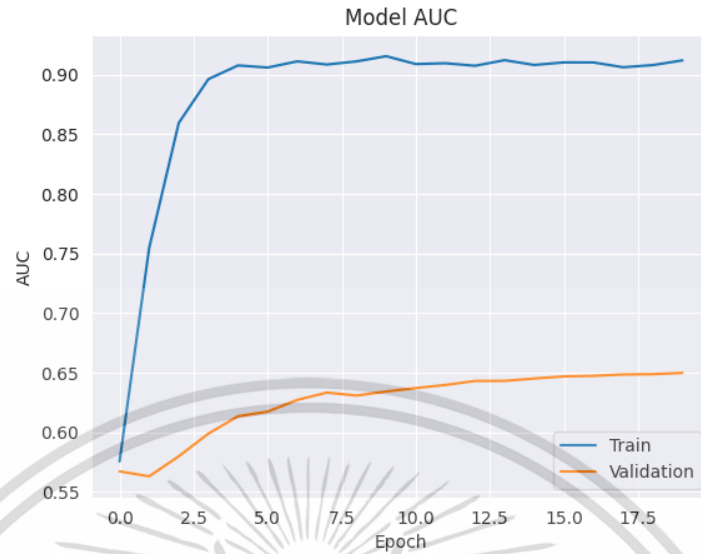


รูปที่ 4.13 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม MobileNetV2




รูปที่ 4.14 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม MobileNetV2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.15 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม MobileNetV2



รูปที่ 4.16 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม MobileNetV2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.2.2 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม ResNet50

จากการทดลองสร้างตัวแบบการจำแนกระดับความผิดพลาดของเนื้อเยื่อผิวหนังจากชุดข้อมูลภาพถ่ายชุดที่ 2 โดยใช้สถาปัตยกรรม ResNet50 ได้ผลการทดลองแสดงดังตารางที่ 4.5 และมีกราฟแสดงค่า Accuracy, Validation Accuracy, Loss, Validation Loss, AUC และ Confusion Matrix ดังรูปที่ 4.17 – 4.20




ตารางที่ 4.5 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม ResNet50


Model for Classification of Cervical Cancer Screening from Colposcopy Image

Dataset No.	2	Architecture	ResNet50			
Epoch	Validation Loss	Training Accuracy	Validation Accuracy	Validation Specificity	Validation Sensitivity	Validation AUC
1	93.4268	44.29%	35.78%	50.22%	50.22%	52.05%
2	26.8742	54.19%	37.56%	54.33%	53.78%	56.37%
3	11.2199	58.76%	48.67%	73.67%	74.22%	65.89%
4	6.093	59.81%	52.22%	76.00%	76.44%	69.26%
5	6.2784	61.81%	42.67%	66.67%	62.89%	59.44%
6	4.63	62.48%	41.56%	67.44%	64.44%	60.71%
7	1.9266	66.76%	45.33%	69.56%	75.33%	67.62%
8	1.8325	71.81%	45.78%	66.89%	71.56%	66.50%
9	1.6477	74.67%	46.22%	66.89%	72.44%	66.87%
10	1.6338	74.00%	46.89%	69.78%	73.33%	67.12%
11	1.6134	72.86%	47.56%	71.22%	73.56%	67.51%
12	1.6129	74.67%	47.78%	71.11%	74.89%	67.82%
13	1.6115	73.24%	48.44%	70.89%	74.89%	67.86%
14	1.6119	74.00%	48.44%	71.56%	74.22%	67.95%
15	1.6111	74.29%	48.44%	71.78%	73.78%	68.03%
16	1.6124	73.81%	48.67%	71.56%	74.44%	68.09%
17	1.6129	73.62%	48.89%	71.67%	74.22%	68.19%
18	1.6134	73.43%	48.89%	71.89%	74.44%	68.22%
19	1.6129	73.24%	48.89%	71.89%	74.44%	68.26%
20	1.6123	73.81%	48.67%	71.78%	74.67%	68.28%
Average		68.28%	46.37%	68.84%	70.91%	65.60%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.17 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม ResNet50




รูปที่ 4.18 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม ResNet50

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.19 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม ResNet50



รูปที่ 4.20 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม ResNet50

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.2.3 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม VGG16

จากการทดลองสร้างตัวแบบการจำแนกระดับความผิดพลาดของเนื้อเยื่อผิวหนังจากชุดข้อมูลภาพถ่ายชุดที่ 2 โดยใช้สถาปัตยกรรม VGG16 ได้ผลการทดลองแสดงดังตารางที่ 4.6 และมีกราฟแสดงค่า Accuracy, Validation Accuracy, Loss, Validation Loss, AUC และ Confusion Matrix ดังรูปที่ 4.21 – 4.24




ตารางที่ 4.6 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม VGG16


Model for Classification of Cervical Cancer Screening from Colposcopy Image

Dataset No.	2	Architecture	VGG16			
Epoch	Validation Loss	Training Accuracy	Validation Accuracy	Validation Specificity	Validation Sensitivity	Validation AUC
1	157.5506	33.90%	37.11%	34.11%	40.89%	52.33%
2	106.2349	37.81%	49.56%	44.22%	44.00%	66.63%
3	75.9922	50.29%	46.89%	67.33%	68.89%	66.53%
4	55.9237	52.00%	50.89%	66.22%	83.78%	73.41%
5	41.7606	54.86%	56.89%	82.22%	87.78%	76.01%
6	31.5892	54.29%	60.22%	83.00%	91.11%	78.55%
7	24.1675	56.48%	59.11%	83.67%	86.67%	76.56%
8	18.7274	56.67%	59.33%	82.33%	86.89%	76.56%
9	17.516	59.14%	58.89%	83.00%	88.00%	77.62%
10	16.9942	59.52%	58.89%	81.89%	88.00%	77.64%
11	16.8679	58.10%	58.00%	81.89%	87.56%	77.59%
12	16.8126	58.57%	58.00%	82.33%	87.78%	77.53%
13	16.7983	58.48%	58.00%	82.22%	87.78%	77.58%
14	16.792	58.95%	58.00%	82.11%	88.00%	77.57%
15	16.7906	58.86%	58.00%	82.11%	88.00%	77.57%
16	16.7898	59.33%	58.00%	82.11%	88.00%	77.57%
17	16.7897	59.33%	58.00%	82.11%	88.00%	77.57%
18	16.7896	58.48%	58.00%	82.11%	88.00%	77.57%
19	16.7895	59.71%	58.00%	82.11%	88.00%	77.57%
20	16.7895	58.57%	58.00%	82.11%	88.00%	77.57%
Average		55.17%	55.89%	76.46%	82.26%	74.88%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.21 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม VGG16




รูปที่ 4.22 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม VGG16

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.23 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม VGG16



รูปที่ 4.24 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 2 จากสถาปัตยกรรม VGG16

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.2.4 การอภิปรายผลการทดลองตัวแบบที่ได้จากข้อมูลภาพถ่ายชุดที่ 2

ข้อมูลภาพถ่ายชุดที่ 2 มีการใช้เทคนิคการเพิ่มปริมาณภาพถ่ายโดยใช้เทคนิคที่เพิ่มเติมจากข้อมูลภาพถ่ายชุดที่ 1 คือการใช้เทคนิคการเพิ่มความเข้มของสีเท่านั้น เพื่อทำการทดลองถึงปัจจัยที่อาจจะส่งผลต่อประสิทธิภาพของตัวแบบ ซึ่งภาพถ่ายที่ได้หลังจากใช้เทคนิคดังกล่าวจะได้ภาพถ่ายที่มีลักษณะสีโดดเด่นกว่าข้อมูลภาพถ่ายชุดที่ 1

พบว่าตัวแบบที่ดีที่สุดจากข้อมูลภาพถ่ายชุดที่ 2 โดยใช้สถาปัตยกรรม VGG16 จะมีค่า Validation Accuracy เท่ากับ 60.22% ซึ่งมีค่าสูงกว่าสถาปัตยกรรมอื่น โดยสถาปัตยกรรม MobileNetV2 มีค่า Validation Accuracy เท่ากับ 46.22% และสถาปัตยกรรม ResNet50 มีค่า Validation Accuracy เท่ากับ 52.22% โดย Confusion Matrix ของสถาปัตยกรรม VGG16 ประสบปัญหาในการจำแนกระดับ Normal เช่นเดียวกับการใช้ชุดข้อมูลที่ 1 ในการสร้างตัวแบบ ซึ่ง Confusion Matrix ของสถาปัตยกรรม MobileNetV2 ประสบปัญหาในการจำแนกความผิดปกติระดับ HGL เช่นเดียวกับสถาปัตยกรรม ResNet50 ที่ประสบปัญหาในการจำแนกในระดับ Normal แต่สามารถจำแนกความผิดปกติระดับ LGL และ HGL ได้ดี ทำให้มีค่า Validation Accuracy ที่สูงกว่า

ผู้วิจัยคาดว่าคุณลักษณะสำคัญที่ส่งผลต่อประสิทธิภาพของตัวแบบโดยใช้การเพิ่มความเข้มของสีกับข้อมูลภาพถ่ายในการศึกษาครั้งนี้อาจจะไม่ส่งผลต่อการจำแนกนัก เนื่องจากตัวแบบที่ได้จากชุดข้อมูลภาพถ่ายชุดที่ 1 โดยใช้สถาปัตยกรรม ResNet50 สามารถจำแนกความผิดปกติระดับ LGL และ Normal ได้ดีกว่า (146:122 และ 50:24 ตามลำดับ) และไม่มีความแตกต่างกันในความผิดปกติระดับ HGL (85:89 ตามลำดับ)

4.3 การทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรมทั้ง 3 แบบ

การทดลองสร้างตัวแบบการจำแนกความผิดปกติของเนื้อเยื่อผิวหนังจากชุดข้อมูลภาพถ่ายชุดที่ 3 โดยใช้สถาปัตยกรรม MobileNetV2, ResNet50 และ VGG16 ซึ่งข้อมูลภาพถ่ายชุดที่ 3 จะเป็นภาพถ่ายที่ใช้เทคนิควิธีการพลิกรูปภาพ (Flip), เทคนิคการขยายภาพ (Zoom) แบบ 50%, 60%, 70%, 80% และ 90% และเทคนิคการเพิ่มความเข้มของสี (Increase saturation) โดยเทคนิคการขยายภาพนั้นจะเป็นการตัดพื้นที่ขอบข้างของภาพถ่ายออกไป เพื่อทดสอบว่าพื้นที่ขอบข้างของภาพถ่ายส่งผลต่อประสิทธิภาพการจำแนกความผิดปกติของเนื้อเยื่อผิวหนังของตัวแบบหรือไม่ โดยมีมาตรวัดประสิทธิภาพคือ Validation

Accuracy, Validation Sensitivity, Validation Specificity และ Validation Area Under Curve (AUC) ซึ่งมีรายละเอียดดังหัวข้อ 4.3.1 – 4.3.3

4.3.1 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม MobileNetV2

จากการทดลองสร้างตัวแบบการจำแนกระดับความผิดพลาดของเนื้อเยื่อผิวหนังจากชุดข้อมูลภาพถ่ายชุดที่ 3 โดยใช้สถาปัตยกรรม MobileNetV2 ได้ผลการทดลองแสดงดังตารางที่ 4.7 และมีกราฟแสดงค่า Accuracy, Validation Accuracy, Loss, Validation Loss, AUC และ Confusion Matrix ดังรูปที่ 4.25 – 4.28




ตารางที่ 4.7 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม MobileNetV2


Model for Classification of Cervical Cancer Screening from Colposcopy Image

Dataset No.	3	Architecture	MobileNetV2			
Epoch	Validation Loss	Training Accuracy	Validation Accuracy	Validation Specificity	Validation Sensitivity	Validation AUC
1	91.3061	40.19%	36.44%	47.11%	30.44%	60.86%
2	26.1977	47.71%	34.00%	39.00%	31.56%	54.34%
3	10.5221	51.71%	33.78%	41.44%	32.44%	51.95%
4	7.9809	55.52%	33.56%	34.89%	32.67%	51.29%
5	7.2239	58.10%	31.33%	36.67%	44.00%	51.41%
6	7.0175	60.10%	32.89%	37.78%	30.89%	51.76%
7	6.9434	60.67%	33.11%	42.67%	31.11%	53.01%
8	6.9185	60.57%	32.67%	45.44%	31.33%	53.84%
9	6.9067	60.76%	34.89%	47.11%	31.33%	54.47%
10	6.8999	60.67%	35.33%	49.11%	32.89%	55.75%
11	6.8938	61.24%	36.44%	50.67%	57.78%	56.77%
12	6.8883	61.33%	37.11%	51.78%	57.56%	57.89%
13	6.883	60.76%	37.78%	52.56%	56.67%	58.42%
14	6.8786	60.86%	38.22%	54.11%	57.11%	59.44%
15	6.8744	61.05%	39.56%	55.67%	62.22%	60.24%
16	6.8704	60.29%	41.11%	56.56%	62.00%	60.93%
17	6.8672	60.76%	40.44%	57.00%	62.44%	61.34%
18	6.8648	60.29%	41.78%	57.78%	62.00%	61.63%
19	6.8624	60.86%	43.56%	58.00%	64.89%	61.99%
20	6.8601	60.38%	43.56%	58.89%	66.22%	62.31%
Average		58.19%	36.88%	48.71%	46.88%	56.98%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.25 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม MobileNetV2




รูปที่ 4.26 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม MobileNetV2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.27 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม MobileNetV2



รูปที่ 4.28 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม MobileNetV2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3.2 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม ResNet50

จากการทดลองสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนังจากชุดข้อมูลภาพถ่ายชุดที่ 3 โดยใช้สถาปัตยกรรม ResNet50 ได้ผลการทดลองแสดงดังตารางที่ 4.8 และมีกราฟแสดงค่า Accuracy, Validation Accuracy, Loss, Validation Loss, AUC และ Confusion Matrix ดังรูปที่ 4.29 – 4.32




ตารางที่ 4.8 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม ResNet50


Model for Classification of Cervical Cancer Screening from Colposcopy Image

Dataset No.	3	Architecture	ResNet50			
Epoch	Validation Loss	Training Accuracy	Validation Accuracy	Validation Specificity	Validation Sensitivity	Validation AUC
1	91.9537	39.14%	33.56%	60.44%	64.67%	59.58%
2	26.7965	46.19%	42.22%	62.67%	68.00%	63.76%
3	11.2678	53.81%	47.78%	70.56%	63.56%	60.44%
4	8.2359	61.24%	52.00%	76.67%	70.44%	64.44%
5	5.0001	62.86%	45.56%	65.22%	62.44%	58.37%
6	3.7106	65.14%	49.78%	73.89%	67.33%	63.99%
7	1.9656	69.14%	47.56%	69.44%	65.11%	62.53%
8	1.768	72.76%	44.44%	66.33%	56.67%	61.32%
9	1.5667	76.67%	46.67%	69.44%	57.56%	62.76%
10	1.552	77.14%	46.89%	68.89%	64.00%	63.33%
11	1.5296	77.71%	47.11%	71.00%	65.56%	63.93%
12	1.527	76.76%	47.11%	71.33%	66.22%	64.29%
13	1.5238	78.00%	46.89%	71.00%	68.00%	64.44%
14	1.5233	77.43%	47.56%	71.67%	67.56%	64.50%
15	1.5227	76.19%	48.44%	72.56%	67.33%	64.47%
16	1.5226	77.33%	49.11%	72.89%	67.33%	64.53%
17	1.5221	77.33%	49.33%	73.33%	66.67%	64.62%
18	1.5219	76.29%	49.56%	73.33%	66.44%	64.65%
19	1.5218	77.05%	49.56%	73.56%	67.56%	64.64%
20	1.5217	76.67%	49.33%	73.56%	67.33%	64.67%
Average		69.74%	47.02%	70.39%	65.49%	63.26%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.29 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม ResNet50




รูปที่ 4.30 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม ResNet50

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.31 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม ResNet50



รูปที่ 4.32 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม ResNet50

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3.3 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม VGG16

จากการทดลองสร้างตัวแบบการจำแนกระดับความผิดพลาดของเนื้อเยื่อผิวหนังจากชุดข้อมูลภาพถ่ายชุดที่ 3 โดยใช้สถาปัตยกรรม VGG16 ได้ผลการทดลองแสดงดังตารางที่ 4.9 และมีกราฟแสดงค่า Accuracy, Validation Accuracy, Loss, Validation Loss, AUC และ Confusion Matrix ดังรูปที่ 4.33 – 4.36




ตารางที่ 4.9 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม VGG16


Model for Classification of Cervical Cancer Screening from Colposcopy Image

Dataset No.	3	Architecture	VGG16			
Epoch	Validation Loss	Training Accuracy	Validation Accuracy	Validation Specificity	Validation Sensitivity	Validation AUC
1	145.2997	32.76%	33.33%	33.33%	33.33%	50.00%
2	88.3859	32.76%	43.11%	36.89%	44.89%	57.30%
3	59.0418	40.67%	43.56%	44.22%	46.22%	60.23%
4	41.3093	44.00%	47.56%	52.22%	73.56%	65.46%
5	29.6556	45.24%	45.11%	56.11%	65.11%	63.82%
6	21.6941	46.76%	46.44%	51.56%	72.44%	65.94%
7	20.2524	47.33%	46.00%	52.44%	73.11%	64.38%
8	19.5289	47.52%	45.78%	52.00%	73.11%	65.47%
9	19.3857	47.62%	46.00%	52.11%	73.33%	65.49%
10	19.3078	48.10%	46.00%	52.11%	73.33%	65.45%
11	19.2927	47.71%	46.00%	52.11%	73.56%	65.46%
12	19.2842	47.52%	46.00%	52.11%	73.33%	65.43%
13	19.2826	47.24%	46.00%	52.11%	73.33%	65.43%
14	19.2817	47.33%	46.00%	52.11%	73.33%	65.43%
15	19.2816	48.19%	46.00%	52.11%	73.33%	65.43%
16	19.2815	47.52%	46.00%	52.11%	73.33%	65.43%
17	19.2814	47.62%	46.00%	52.11%	73.33%	65.43%
18	19.2813	47.81%	46.00%	52.11%	73.33%	65.43%
19	19.2812	48.57%	46.00%	52.11%	73.33%	65.43%
20	19.281	47.71%	46.00%	52.11%	73.33%	65.43%
Average		45.50%	45.14%	50.20%	68.10%	63.89%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.33 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม VGG16




รูปที่ 4.34 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม VGG16

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.35 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม VGG16



รูปที่ 4.36 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม VGG16

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3.4 การอภิปรายผลการทดลองตัวแบบที่ได้จากข้อมูลภาพถ่ายชุดที่ 3

ข้อมูลภาพถ่ายชุดที่ 3 มีการใช้เทคนิคการเพิ่มปริมาณภาพถ่ายที่แตกต่างจากข้อมูลภาพถ่ายชุดที่ 1 คือวิธีการพลิกรูปภาพ, เทคนิคการขยายภาพแบบระยะใกล้ที่ 50%, 60%, 70%, 80% และ 90% เพื่อตัดพื้นที่ขอบข้างของภาพถ่ายเพื่อเพิ่มลักษณะของรูปภาพให้ใกล้กึ่งกลางของภาพถ่าย และใช้เทคนิคการเพิ่มความเข้มของสีร่วมด้วย เพื่อทำการทดลองถึงปัจจัยของสีที่อาจจะส่งผลต่อประสิทธิภาพของตัวแบบ

พบว่าตัวแบบที่ดีที่สุดจากข้อมูลภาพถ่ายชุดที่ 3 โดยใช้สถาปัตยกรรม ResNet50 จะมีค่า Validation Accuracy เท่ากับ 52.00% ซึ่งมีค่าสูงกว่าสถาปัตยกรรมอื่น โดยสถาปัตยกรรม MobileNetV2 มีค่า Validation Accuracy เท่ากับ 43.56% และสถาปัตยกรรม VGG16 มีค่า Validation Accuracy เท่ากับ 47.56% โดย Confusion Matrix ของสถาปัตยกรรม ResNet50 สามารถจำแนกระดับความผิดปกติได้ในทุกระดับ แต่สถาปัตยกรรม MobileNetV2 และสถาปัตยกรรม VGG16 ประสบปัญหาในการจำแนกระดับ Normal ซึ่งสถาปัตยกรรม MobileNetV2 สามารถจำแนกได้ 10 รูป จาก 150 รูป และสถาปัตยกรรม VGG16 สามารถจำแนกได้ 2 รูป จาก 150 รูป

หากเทียบกับตัวแบบที่ดีที่สุดจากข้อมูลภาพถ่ายชุดที่ 1 และ 2 จากสถาปัตยกรรม ResNet50 ที่ผ่านมา พบว่าตัวแบบที่ดีที่สุดจากข้อมูลภาพถ่ายชุดที่ 3 จากสถาปัตยกรรม ResNet50 มีค่า Validation Accuracy ต่ำที่สุด โดยเมื่อเปรียบเทียบกับ Confusion Matrix พบว่าสถาปัตยกรรม ResNet50 ที่สร้างจากข้อมูลภาพถ่ายชุดที่ 1 และ 2 จะสามารถการจำแนกความผิดปกติระดับ LGL ได้ดี ซึ่งแตกต่างจากสถาปัตยกรรม ResNet50 ที่สร้างจากข้อมูลภาพถ่ายชุดที่ 3 ซึ่งสามารถการจำแนกความผิดปกติระดับ HGL ได้ดีกว่า

เมื่อเปรียบเทียบค่า Validation Accuracy และการจำแนกความผิดปกติทั้ง 3 แบบ พบว่าสถาปัตยกรรม ResNet50 ที่สร้างจากข้อมูลภาพถ่ายชุดที่ 1 สามารถจำแนกความผิดปกติได้สูงกว่าสถาปัตยกรรม ResNet50 ที่สร้างจากข้อมูลภาพถ่ายชุดที่ 3 ซึ่งทางผู้วิจัยคาดว่า พื้นที่ขอบข้างของภาพถ่ายที่ตัดออกยังคงมีปัจจัยที่ส่งผลต่อค่า Validation Accuracy ทำให้คุณลักษณะสำคัญที่ส่งผลต่อประสิทธิภาพของตัวแบบนี้ถูกตัดออกไปด้วย

4.4 การทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรมทั้ง 3 แบบ

การทดลองสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนังจากชุดข้อมูลภาพถ่ายชุดที่ 4 โดยใช้สถาปัตยกรรม MobileNetV2, ResNet50 และ VGG16 ซึ่งข้อมูลภาพถ่ายชุดที่ 4 จะเป็นภาพถ่ายที่ใช้เทคนิควิธีการพลิกรูปภาพ (Flip), เทคนิคการขยายภาพ (Zoom) แบบ 10%, 30%, 40%, 50% และ 70% และเทคนิคการปรับรูปภาพสีเป็นรูปภาพสเกลสีเทา (Convert to grayscale) เพื่อทดสอบว่าสีและโครงสร้างของภาพถ่ายส่งผลต่อประสิทธิภาพการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนังของตัวแบบหรือไม่ โดยมีมาตรวัดประสิทธิภาพคือ Validation Accuracy, Validation Sensitivity, Validation Specificity และ Validation Area Under Curve (AUC) ซึ่งมีรายละเอียดดังหัวข้อ 4.4.1 – 4.4.3

4.4.1 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม MobileNetV2


จากการทดลองสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนังจากชุดข้อมูลภาพถ่ายชุดที่ 3 โดยใช้สถาปัตยกรรม MobileNetV2 ได้ผลการทดลองแสดงดังตารางที่ 4.10 และมีภาพแสดงค่า Accuracy, Validation Accuracy, Loss, Validation Loss, AUC และ Confusion Matrix ดังรูปที่ 4.37 – 4.40

ตารางที่ 4.10 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม MobileNetV2


Model for Classification of Cervical Cancer Screening from Colposcopy Image

Dataset No.	4	Architecture	MobileNetV2			
Epoch	Validation Loss	Training Accuracy	Validation Accuracy	Validation Specificity	Validation Sensitivity	Validation AUC
1	84.8665	42.00%	33.33%	48.56%	38.22%	53.86%
2	21.8641	60.57%	32.89%	47.33%	48.44%	51.73%
3	8.5397	65.62%	36.67%	55.44%	53.56%	54.68%
4	4.751	69.62%	35.56%	49.89%	49.56%	53.25%
5	3.4503	65.81%	32.22%	48.78%	48.22%	50.09%
6	2.2912	68.10%	30.22%	49.00%	48.00%	47.88%
7	2.1177	68.00%	29.11%	46.11%	48.67%	47.06%
8	1.9361	66.95%	25.78%	42.00%	42.22%	46.21%
9	1.9043	68.00%	26.44%	43.89%	42.67%	46.93%
10	1.8797	70.48%	30.44%	48.11%	48.22%	48.50%
11	1.8779	67.90%	34.22%	51.78%	52.67%	50.38%
12	1.9001	68.19%	37.78%	50.33%	50.22%	50.18%
13	1.9231	67.81%	38.22%	50.33%	50.89%	49.79%
14	1.9343	66.19%	39.11%	51.44%	52.00%	49.76%
15	1.9369	68.76%	39.11%	51.00%	52.00%	51.23%
16	1.9351	68.67%	40.44%	52.44%	52.44%	52.11%
17	1.9302	67.05%	40.22%	53.33%	54.00%	53.14%
18	1.9249	67.24%	42.00%	54.22%	55.78%	54.22%
19	1.9186	67.62%	43.33%	55.78%	55.56%	55.25%
20	1.9114	69.33%	44.22%	57.33%	57.11%	56.08%
Average		66.20%	35.57%	50.35%	50.02%	51.12%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.37 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม MobileNetV2




รูปที่ 4.38 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม MobileNetV2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.39 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม MobileNetV2



รูปที่ 4.40 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม MobileNetV2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.4.2 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม ResNet50

จากการทดลองสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนังจากชุดข้อมูลภาพถ่ายชุดที่ 3 โดยใช้สถาปัตยกรรม ResNet50 ได้ผลการทดลองแสดงดังตารางที่ 4.11 และมีกราฟแสดงค่า Accuracy, Validation Accuracy, Loss, Validation Loss, AUC และ Confusion Matrix ดังรูปที่ 4.41 – 4.44




ตารางที่ 4.11 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม ResNet50


Model for Classification of Cervical Cancer Screening from Colposcopy Image

Dataset No.	4	Architecture	ResNet50			
Epoch	Validation Loss	Training Accuracy	Validation Accuracy	Validation Specificity	Validation Sensitivity	Validation AUC
1	467.9693	40.95%	33.33%	0.00%	33.33%	50.00%
2	24.9125	50.00%	39.78%	62.11%	63.56%	59.63%
3	10.5379	52.10%	41.33%	64.00%	60.67%	60.21%
4	5.9866	55.71%	42.22%	57.56%	62.00%	60.53%
5	6.6356	53.62%	39.56%	53.44%	55.78%	56.01%
6	3.4668	55.24%	44.67%	71.78%	67.56%	67.42%
7	3.4114	54.00%	34.22%	57.56%	57.33%	53.89%
8	3.1071	54.95%	45.56%	73.78%	70.22%	68.85%
9	3.0645	56.00%	49.33%	75.89%	77.56%	71.20%
10	2.9981	59.43%	53.33%	79.33%	74.89%	72.21%
11	3.2341	60.19%	33.56%	50.89%	51.33%	50.26%
12	2.9888	60.57%	50.44%	76.67%	79.78%	71.97%
13	1.3187	64.29%	50.00%	77.33%	80.89%	72.72%
14	1.2418	64.48%	49.11%	77.11%	80.67%	72.81%
15	1.0577	66.95%	50.22%	78.56%	80.89%	73.18%
16	1.0485	66.67%	50.67%	78.11%	81.56%	73.31%
17	1.0252	68.29%	50.44%	77.56%	81.56%	73.44%
18	1.0205	66.38%	49.78%	76.78%	81.11%	73.49%
19	1.0161	66.48%	50.00%	76.56%	81.33%	73.56%
20	1.0146	68.10%	50.44%	76.00%	81.56%	73.61%
Average		59.22%	45.40%	67.05%	70.18%	66.42%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.41 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม ResNet50




รูปที่ 4.42 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม ResNet50

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.43 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม ResNet50



รูปที่ 4.44 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม ResNet50

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.4.3 ผลการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม VGG16

จากการทดลองสร้างตัวแบบการจำแนกระดับความผิดพลาดของเนื้อเยื่อผิวหนังจากชุดข้อมูลภาพถ่ายชุดที่ 3 โดยใช้สถาปัตยกรรม VGG16 ได้ผลการทดลองแสดงดังตารางที่ 4.12 และมีกราฟแสดงค่า Accuracy, Validation Accuracy, Loss, Validation Loss, AUC และ Confusion Matrix ดังรูปที่ 4.45 – 4.48




ตารางที่ 4.12 ค่าผลการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม VGG16


Model for Classification of Cervical Cancer Screening from Colposcopy Image

Dataset No.	4	Architecture	VGG16			
Epoch	Validation Loss	Training Accuracy	Validation Accuracy	Validation Specificity	Validation Sensitivity	Validation AUC
1	140.9333	34.86%	33.33%	33.33%	33.33%	50.00%
2	82.3639	32.95%	33.33%	33.33%	33.33%	50.00%
3	52.4555	33.33%	33.33%	33.33%	33.33%	50.00%
4	48.9729	33.33%	33.33%	33.33%	33.33%	50.00%
5	46.5578	33.33%	33.33%	33.33%	33.33%	50.00%
6	46.2433	33.33%	33.33%	33.33%	33.33%	50.00%
7	45.9821	33.33%	33.33%	33.33%	33.33%	50.00%
8	45.9485	33.33%	33.33%	33.33%	33.33%	50.00%
9	45.9198	33.33%	33.33%	33.33%	33.33%	50.00%
10	45.9162	33.33%	33.33%	33.33%	33.33%	50.00%
11	45.9131	33.33%	33.33%	33.33%	33.33%	50.00%
12	45.9127	33.33%	33.33%	33.33%	33.33%	50.00%
13	45.9124	33.33%	33.33%	33.33%	33.33%	50.00%
14	45.912	33.33%	33.33%	33.33%	33.33%	50.00%
15	45.9117	33.33%	33.33%	33.33%	33.33%	50.00%
16	45.9113	33.33%	33.33%	33.33%	33.33%	50.00%
17	45.911	33.33%	33.33%	33.33%	33.33%	50.00%
18	45.9106	33.33%	33.33%	33.33%	33.33%	50.00%
19	45.9102	33.33%	33.33%	33.33%	33.33%	50.00%
20	45.9098	33.33%	33.33%	33.33%	33.33%	50.00%
Average		33.39%	33.33%	33.33%	33.33%	50.00%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.45 กราฟแสดงค่า Accuracy และ Validation Accuracy จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม VGG16




รูปที่ 4.46 กราฟแสดงค่า Accuracy และ Validation Loss จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม VGG16

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.47 กราฟแสดงค่า AUC และ Validation AUC จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม VGG16



รูปที่ 4.48 Confusion Matrix จากการทดลองข้อมูลภาพถ่ายชุดที่ 4 จากสถาปัตยกรรม VGG16

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.4.4 การอภิปรายผลการทดลองตัวแบบที่ได้จากข้อมูลภาพถ่ายชุดที่ 4

ข้อมูลภาพถ่ายชุดที่ 4 มีการใช้เทคนิคการเพิ่มปริมาณภาพถ่ายที่แตกต่างจากข้อมูลภาพถ่ายชุดที่ 1 คือวิธีการพลิกรูปภาพ, เทคนิคการขยายภาพแบบระยะไกลที่ 10%, 30%, 40%, 50% และ 70% และการใช้เทคนิคการปรับรูปภาพสีเป็นรูปภาพสเกลสีเทาเพื่อทำการตัดสีภายในภาพถ่ายออก เพื่อทดสอบปัจจัยที่อาจจะส่งผลต่อประสิทธิภาพของตัวแบบ

พบว่าตัวแบบที่ดีที่สุดจากข้อมูลภาพถ่ายชุดที่ 4 โดยใช้สถาปัตยกรรม ResNet50 จะมีค่า Validation Accuracy เท่ากับ 53.33% ซึ่งมีค่าสูงกว่าสถาปัตยกรรมอื่น โดยสถาปัตยกรรม MobileNetV2 มีค่า Validation Accuracy เท่ากับ 44.22% แต่สถาปัตยกรรม VGG16 ไม่เกิดการเรียนรู้คุณลักษณะที่สำคัญจากภาพถ่ายจึงมีค่า Validation Accuracy เท่ากับ 33.33% ซึ่งมีค่าเท่ากับค่าเริ่มต้น ซึ่งพบว่า Confusion Matrix ของสถาปัตยกรรม VGG16 จะจำแนกความผิดพลาดระดับ HGL เพียงระดับเดียว ซึ่งเป็นปัญหาจากการไม่สามารถเรียนรู้คุณลักษณะสำคัญจากภาพถ่ายได้ และจาก Confusion Matrix ของสถาปัตยกรรม MobileNetV2 นั้นสามารถจำแนกความผิดพลาดระดับ LGL และ Normal ได้ดี แต่ยังไม่สามารถเอาชนะสถาปัตยกรรม ResNet50 ทำสร้างจากข้อมูลภาพถ่ายชุดที่ 4 ได้ เนื่องจากสถาปัตยกรรม ResNet50 สามารถจำแนกความผิดพลาดระดับ LGL และ HGL ถูกต้องได้มากกว่า

เมื่อเปรียบเทียบสถาปัตยกรรม ResNet50 จากตัวแบบที่จากข้อมูลภาพถ่ายชุดที่ 1 กับสถาปัตยกรรม ResNet50 จากตัวแบบที่จากข้อมูลภาพถ่ายชุดที่ 4 พบว่าจาก Confusion Matrix ของตัวแบบที่จากข้อมูลภาพถ่ายชุดที่ 4 ประสบปัญหาในการจำแนกระดับ Normal ซึ่งสถาปัตยกรรม ResNet50 จากตัวแบบที่จากข้อมูลภาพถ่ายชุดที่ 1 สามารถทำได้ดีกว่าในส่วนนี้จึงทำให้มีค่า Validation Accuracy ที่สูงกว่า (62.44% และ 53.33% ตามลำดับ)

ผู้วิจัยคาดว่าตัวแบบจากสถาปัตยกรรม ResNet50 จากตัวแบบที่จากข้อมูลภาพถ่ายชุดที่ 4 อาจจะมีปัญหาความซับซ้อนของตัวแบบที่สูงเกินจำเป็น เนื่องจากรายละเอียดของข้อมูลภาพถ่ายชุดที่ 4 จะเป็นรูปภาพสเกลสีเทา เนื่องจากตัวแบบใช้คุณลักษณะสำคัญที่ส่งผลต่อประสิทธิภาพของตัวแบบเพื่อทดแทนการใช้สีในการจำแนกระดับความผิดพลาดของเนื้อเยื่อผิว โดยคุณลักษณะสำคัญนั้นอาจไม่จำเป็นต้องใช้โครงสร้างของตัวแบบที่ซับซ้อนมากนัก

4.5 การอภิปรายผลการทดลอง


ผลการทดลองตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อบุผิวจากชุดข้อมูลภาพถ่ายชุดที่ 1 – 4 โดยใช้สถาปัตยกรรม MobileNetV2, ResNet50 และ VGG16 โดยใช้ Validation Accuracy เป็นเกณฑ์ในการวัดประสิทธิภาพของตัวแบบ หาก Validation Accuracy มีค่าเท่ากัน จะเลือกใช้ตัวแบบที่มีค่า Testing AUC สูงกว่ามานำเสนอ ดังตารางที่ 4.13 และกราฟแสดงผลการทดลองตัวแบบที่ดีที่สุดการจำแนกระดับความผิดปกติของเนื้อเยื่อบุผิวจากชุดข้อมูลภาพถ่ายชุดที่ 1 – 4 แสดงดังรูปที่ 4.49

ตารางที่ 4.13 สรุปผลการทดลองการจำแนกระดับความผิดปกติของเนื้อเยื่อบุผิวจากชุดข้อมูลภาพถ่าย

Dataset No.	Architecture	Epoch	Training Accuracy	Val. Accuracy	Val. Specificity	Val. Sensitivity	Val. AUC	Rank
1	MobileNetV2	20	87.24%	52.44%	78.11%	79.33%	70.93%	3
1	ResNet50	8	84.29%	62.44%	85.78%	83.33%	76.77%	1
1	VGG16	10	57.90%	60.44%	82.00%	88.00%	76.96%	2
2	MobileNetV2	15	70.48%	46.22%	71.11%	72.22%	64.51%	2
2	ResNet50	4	59.81%	52.22%	76.00%	76.44%	69.26%	1
2	VGG16	6	54.29%	**60.22%	83.00%	91.11%	78.55%	3
3	MobileNetV2	20	60.38%	43.56%	58.89%	66.22%	62.31%	3
3	ResNet50	4	61.24%	52.00%	76.67%	70.44%	64.44%	1
3	VGG16	4	44.00%	47.56%	52.22%	73.56%	65.46%	2
4	MobileNetV2	20	69.33%	44.22%	57.33%	57.11%	56.08%	2
4	ResNet50	10	59.43%	53.33%	79.33%	74.89%	72.21%	1
4	VGG16	20	33.33%	33.33%	33.33%	33.33%	50.00%	3

* ตัวแบบที่ Validation Accuracy มีค่าเท่ากัน จะเลือกใช้ตัวแบบที่มีค่า Testing AUC สูงกว่ามานำเสนอ

** พบปัญหาในการจำแนกความผิดปกติ จึงไม่นำมาเป็นตัวแทนของตัวแบบที่ดีที่สุด



** พบปัญหาในการทำนายความผิดปกติ จึงไม่นับมาเป็นตัวแทนของตัวแบบที่ดีที่สุด

รูปที่ 4.49 กราฟแสดงผลการทดลองตัวแบบที่ดีที่สุดการจำแนกระดับความผิดปกติของเนื้อเยื่อหูผิว จากชุดข้อมูลภาพถ่ายชุดที่ 1 – 4

4.6 ปัญหาที่พบในการสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อหูผิว

4.6.1 ปัญหาด้านจำนวนของภาพถ่าย

ข้อมูลภาพถ่ายเยื่อหูผิวภายในบริเวณปากมดลูกที่มีในระบบนั้นมาจากการตรวจคัดกรองเพื่อค้นหาโรคร้ายของผู้ป่วย ซึ่งในบางครั้งแพทย์ผู้รักษาสามารถพิจารณากระดับความผิดปกติที่รุนแรงได้ด้วยตา เช่น ในลักษณะความผิดปกติในกลุ่ม High Grade Lesion และ Cancer นั้นแพทย์สามารถวินิจฉัยลักษณะได้เนื่องจากมีลักษณะความผิดปกติที่ค่อนข้างชัดเจนในบางราย ทำให้ภาพถ่ายมีจำนวนน้อยกว่ากลุ่ม Normal และ Low Grade Lesion

4.6.2 ปัญหาด้านเทคนิคและมุมมองของภาพถ่าย

การถ่ายภาพเยื่อหูผิวภายในบริเวณปากมดลูก มีเทคนิคการเตรียมบริเวณเยื่อหูผิวภายในบริเวณปากมดลูก จำนวน 4 เทคนิคคือ การโซลปากมดลูกด้วยน้ำเกลือ (Normal Saline Solution), การย้อมตัวอย่างด้วยกรดอะซิติก (Acetic Acid), การย้อมตัวอย่างด้วยไอโอดีนบริสุทธิ์ (Iodine Solution) และการถ่ายผ่านฟิลเตอร์สีเขียว (Green Filter) ซึ่งแต่ละเทคนิคจะช่วยให้แพทย์สามารถให้ค้นพบความผิดปกติได้ง่าย ทำให้ภาพถ่ายในระบบมีการถ่ายภาพโดยใช้เทคนิค

เหล่านี้ตามความเชี่ยวชาญของแพทย์ผู้วินิจฉัย ทำให้จำนวนภาพถ่ายของแต่ละเทคนิคไม่เท่ากัน รวมไปถึงมุมมองของการถ่ายภาพที่อาจจะไม่ใช่เพียงมุมตรงเท่านั้น เนื่องจากเครื่องมือที่ใช้ถ่ายจะไม่มีมุมคงที่จึงทำให้ภาพถ่ายอาจจะมีลักษณะที่แตกต่างกันออกไป

4.6.3 ปัญหาด้านการคัดเลือกภาพถ่ายที่เหมาะสม

จากปัญหาด้านเทคนิคและมุมมองของภาพถ่ายที่กล่าวไปก่อนหน้านี้ ทำให้การถ่ายภาพแต่ละครั้งอาจมีรูปภาพที่ได้มากกว่า 1 รูปภาพต่อผู้ป่วย 1 ราย ดังนั้นจะต้องมีการคัดเลือกรูปภาพที่มีองค์ประกอบครบถ้วนที่สุดเพื่อเป็นตัวแทนของภาพถ่ายที่ใช้ในการสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนัง

4.6.4 ปัญหาด้านทรัพยากรในการสร้างตัวแบบ

ชุดข้อมูลภาพถ่ายที่ใช้ในการสร้างตัวแบบมีจำนวนมาก ประกอบกับวัตถุประสงค์ในการศึกษานี้เพื่อเปรียบเทียบประสิทธิภาพของ 3 สถาปัตยกรรม ดังนั้นการจัดทำข้อมูลจำเป็นต้องดำเนินการพร้อมกัน เพื่อให้ทรัพยากรที่ใช้สร้างตัวแบบมาจากสภาพแวดล้อมเดียวกัน โดยต้องมีการปรับแต่งค่า Hyperparameter ของตัวแบบ การทดลองจึงเกิดการวนซ้ำในการคำนวณหลายครั้งทำให้ทรัพยากรด้าน GPU ไม่เพียงพอ ซึ่งส่งผลกระทบต่อระยะเวลาการประมวลผลของตัวแบบ โดยการใช้ Google Colab แบบ Free Version ไม่เพียงพอต่อการศึกษารุ่นนี้เนื่องจากมีข้อจำกัดด้านเวลาการใช้งานของระบบที่ถูกจำกัด

บทที่ 5

สรุปผลการดำเนินงานและข้อเสนอแนะ

ในบทนี้จะกล่าวถึงการสรุปผลการดำเนินงานและข้อเสนอแนะที่ได้จากการศึกษาในครั้งนี้ เพื่อให้การนำไปประยุกต์ใช้สามารถพัฒนาประสิทธิภาพได้ดีขึ้น

5.1 สรุปผลการดำเนินงาน

การศึกษาในครั้งนี้ได้สร้างตัวแบบในการจำแนกระดับความผิดปกติของเนื้อเยื่อผิวหนัง จากภาพถ่ายคอลโปลาโคปที่เป็นภาพถ่ายเนื้อเยื่อผิวหนังภายในบริเวณปากมดลูก จากกรณีศึกษา โรงพยาบาลจุฬารัตน์ เขตหลักสี่ กรุงเทพมหานคร โดยมีการแบ่งระดับของภาพถ่ายออกเป็น 3 กลุ่ม คือ Low Grade Lesion (LGL), High Grade Lesion (HGL) และ Cancer โดยภาพถ่ายแต่ละชุดจะผ่านเทคนิคเพิ่มปริมาณที่แตกต่างกันไป เช่น วิธีการพลิกรูปภาพ (Flip), การเพิ่มความเข้มของสี (Increase saturation), การขยายภาพ (Zoom) และการปรับรูปภาพสีเป็นรูปภาพสเกลสีเทา (Convert to grayscale) ทำให้มีภาพถ่ายที่ใช้ในการสร้างตัวแบบที่เท่ากันและทำการสร้างตัวแบบจากสถาปัตยกรรม MobileNetV2, ResNet50 และ VGG16

การสร้างตัวแบบได้ดำเนินการโดยใช้ข้อมูลภาพถ่ายที่แตกต่างกันจำนวน 4 ชุด เพื่อทดสอบประสิทธิภาพของแต่ละสถาปัตยกรรม และเพื่อค้นหาถึงองค์ประกอบสำคัญที่ได้จากชุดข้อมูลภาพถ่ายได้ผลลัพธ์ดังนี้

ตัวแบบที่จากข้อมูลภาพถ่ายชุดที่ 1 ที่ประกอบด้วยรูปภาพที่มีสีเหมือนรูปภาพต้นฉบับ และใช้เทคนิคการพลิกรูปภาพและการขยายภาพ ตัวแบบจากสถาปัตยกรรม ResNet50 เป็นตัวแบบที่ดีที่สุด มีค่า Validation Accuracy เท่ากับ 62.44% โดยสามารถจำแนกความผิดปกติระดับ LGL ได้ถูกต้อง 146 รูปจาก 150 รูป จำแนกความผิดปกติระดับ HGL ได้ถูกต้อง 85 รูปจาก 150 รูป และจำแนกระดับ Normal ได้ถูกต้อง 50 รูปจาก 150 รูป

ตัวแบบที่จากข้อมูลภาพถ่ายชุดที่ 2 ที่ประกอบด้วยรูปภาพที่ใช้เทคนิควิธีการเพิ่มความเข้มของสี, การพลิกรูปภาพและการขยายภาพ ตัวแบบจากสถาปัตยกรรม ResNet50 เป็นตัวแบบที่ดีที่สุด มีค่า Validation Accuracy เท่ากับ 52.22% โดยสามารถจำแนกความผิดปกติระดับ LGL ได้ถูกต้อง 122 รูปจาก 150 รูป จำแนกความผิดปกติระดับ HGL ได้ถูกต้อง 89 รูปจาก 150 รูป และ

จำแนกระดับ Normal ได้ถูกต้อง 24 รูปจาก 150 รูป ผู้วิจัยคาดว่าคุณลักษณะสำคัญที่ส่งผลต่อประสิทธิภาพของตัวแบบโดยใช้การเพิ่มความเข้มของสีกับข้อมูลภาพถ่ายในการศึกษาครั้งนี้อาจจะไม่ส่งผลต่อการจำแนกนัก

ตัวแบบที่จากข้อมูลภาพถ่ายชุดที่ 3 ที่ประกอบด้วยรูปภาพที่ใช้เทคนิคการเพิ่มความเข้มของสี, การพลิกรูปภาพและการขยายภาพระดับสูง สถาปัตยกรรม ResNet50 มีค่า Validation Accuracy เท่ากับ 52.00% โดยสามารถจำแนกความผิดปกติระดับ HGL ได้ถูกต้อง 122 รูปจาก 150 รูป จำแนกความผิดปกติระดับ LGL ได้ถูกต้อง 63 รูปจาก 150 รูป และจำแนกระดับ Normal ได้ถูกต้อง 49 รูปจาก 150 รูป ผู้วิจัยคาดว่าคุณลักษณะสำคัญที่ส่งผลต่อประสิทธิภาพของตัวแบบจากการใช้เทคนิคการเพิ่มความเข้มของสีประกอบกับเทคนิคการขยายภาพระดับสูงสามารถเพิ่มคุณลักษณะสำคัญในการจำแนกความผิดปกติระดับ HGL ได้

ตัวแบบที่จากข้อมูลภาพถ่ายชุดที่ 4 ที่ประกอบด้วยรูปภาพที่ใช้เทคนิคการปรับสีเป็นขาวดำ, การพลิกรูปภาพและการขยายภาพ สถาปัตยกรรม ResNet50 มีค่า Validation Accuracy เท่ากับ 53.33% โดยสามารถจำแนกความผิดปกติระดับ LGL ได้ถูกต้อง 147 รูปจาก 150 รูป จำแนกความผิดปกติระดับ HGL ได้ถูกต้อง 86 รูปจาก 150 รูป และจำแนกระดับ Normal ได้ถูกต้อง 7 รูปจาก 150 รูป ผู้วิจัยคาดว่าคุณลักษณะสำคัญที่ส่งผลต่อประสิทธิภาพของตัวแบบจากการใช้เทคนิคการปรับสีเป็นขาวดำจะถูกลดลงเนื่องจากประสิทธิภาพในการจำแนกประเภทของความผิดปกติของสถาปัตยกรรมทั้ง 3 มีค่าเฉลี่ยที่ลดลง

ซึ่งได้ผลการทดลองคือ สถาปัตยกรรม ResNet50 มีประสิทธิภาพดีที่สุดจากทุกข้อมูลภาพถ่าย ซึ่งมีค่า Validation Accuracy ของแต่ละชุดข้อมูลภาพถ่ายเท่ากับ 62.44%, 52.22%, 52.00% และ 53.33% ตามลำดับ

ซึ่งตัวแบบจากสถาปัตยกรรม ResNet50 จากข้อมูลภาพถ่ายชุดที่ 1 มีค่า Validation Accuracy เท่ากับ 62.44% ซึ่งสูงกว่าตัวแบบอื่นๆที่ทำการทดลอง ผู้วิจัยจึงเห็นว่าตัวแบบนี้เหมาะสมที่จะนำไปใช้งานเนื่องจากสามารถจำแนกความผิดปกติได้ในทุกระดับและมีความถูกต้องสูงกว่าตัวแบบอื่น

5.2 ข้อเสนอแนะ

การศึกษาในครั้งนี้ ได้พบปัญหาระหว่างการสร้างตัวแบบการจำแนกระดับความผิดปกติของเนื้อเยื่อบุผิว ดังที่ได้กล่าวไปในบทที่ 4 ซึ่งทางผู้วิจัยเห็นว่า หากมีการนำข้อเสนอแนะไปปรับปรุงจะทำให้ตัวแบบที่ได้มีประสิทธิภาพสูงขึ้นและสามารถนำไปพัฒนาต่อได้ โดย

5.2.1 เพิ่มจำนวนภาพถ่ายของความผิดปกติแต่ละประเภท

ปัญหาที่พบได้บ่อยของการสร้างตัวแบบทุกประเภทคือ การมีชุดข้อมูลเรียนรู้ที่ไม่มากพอ ซึ่งเป็นข้อจำกัดที่ส่งผลต่อประสิทธิภาพของตัวแบบและหากตัวแบบมีความซับซ้อนสูง ปัญหาที่ตัวแบบจะต้องเผชิญคือเกิดการเรียนรู้ที่เกินพอดี หากสามารถเพิ่มจำนวนภาพถ่ายที่ใช้ได้มากขึ้น จะส่งผลให้ตัวแบบสามารถทำงานได้มีประสิทธิภาพสูงขึ้นไปด้วย

5.2.2 เพิ่มการกำหนดจุดบ่งชี้ความผิดปกติของภาพถ่าย

เนื่องจากภาพถ่ายในการศึกษาครั้งนี้ มีมุมมองของภาพถ่ายที่แตกต่างกันออก ทำให้ลักษณะมุมมองของภาพถ่ายแตกต่างกันดังปัญหาที่ได้กล่าวในหัวข้อที่ 4.6.2 หากสามารถกำหนดจุดที่สามารถบ่งชี้ความผิดปกติภายในภาพถ่ายได้จะสามารถช่วยเพิ่มประสิทธิภาพของตัวแบบได้

5.2.3 เพิ่มการระบุตำแหน่งความผิดปกติที่ได้จากผลการจำแนก

การศึกษาในครั้งนี้ ตัวแบบสามารถจำแนกภาพถ่ายออกมาโดยระบุถึงระดับความผิดปกติโดยรวมของภาพถ่าย หากมีการใช้ Mask R-CNN ในการจัดทำตัวแบบ จะส่งผลให้ตัวแบบสามารถระบุถึงความผิดปกติตามตำแหน่งที่ปรากฏในภาพถ่ายได้ ซึ่งทำให้ได้ผลลัพธ์ที่ละเอียดมากขึ้นและสามารถนำไปพัฒนาต่อเพื่อใช้กับชุดข้อมูลอื่นๆที่ภาพถ่ายมีองค์ประกอบหลายส่วน

บรรณานุกรม

- CHRISTOPHER M. BISHOP. (1995). *Neural Networks for Pattern Recognition*. New York: CLARENDON PRESS • OXFORD.
- Eric J. Humphrey, และ Juan P. Bello. (2012). Rethinking Automatic Chord Recognition with Convolutional Neural Networks. *11th International Conference on Machine Learning and Applications*, 357-362.
- Google Machine Learning Education. (19 Jul 2022). เข้าถึงได้จาก developers.google.com: <https://developers.google.com/machine-learning/crash-course/multi-class-neural-networks/softmax>
- Imsamran et al. (2015). *Cancer in Thailand Vol.VIII*. Bangkok: New Thammada Press (Thailand) Co., Ltd.
- Imsamran et al. (2018). *Cancer in Thailand Vol.IX*. Bangkok: New Thammada Press (Thailand) Co., Ltd.
- June-Goo Lee, Sanghoon Jun, Young-Won Cho, Hyunna Lee, Guk Bae Kim, Joon Beom Seo, และ Namkug Kim. (2017). Deep Learning in Medical Imaging: General Overview. *Korean J Radiol*, 570-584.
- Khuhaprema et al. (2012). *Cancer in Thailand*. Bangkok: Bangkok Medical Publisher.
- Khuhaprema et al. (2013). *Cancer in Thailand Vol. VII*. Bangkok: Bangkok Medical Publisher.
- Kunal Banerjee, Vishak C Prasad, Rishi Raj Gupta, Karthik Vyas, Anushree H, และ Biswajit Mishra. (23 Nov 2020). *Exploring Alternatives to Softmax Function*. เข้าถึงได้จาก Cornell University: <https://arxiv.org/abs/2011.11538>
- N.S. Johnson, P. S. Vulimiri, A. C., X. Zhang, C.A. Brice, Branden Kappes, และ Aaron Stebner. (1 May 2020). *Machine Learning for Materials Developments in Metals Additive Manufacturing*. เข้าถึงได้จาก [researchgate.net: https://www.researchgate.net/publication/341310767_Machine_Learning_for_Materials_Developments_in_Metals_Additive_Manufacturing](https://www.researchgate.net/publication/341310767_Machine_Learning_for_Materials_Developments_in_Metals_Additive_Manufacturing)

บรรณานุกรม (ต่อ)

- Nopparut Pattansarn. (2020). Image Processing for Classifying the Quality of the Chok-Anan Mango by Simulating the Human Vision using Deep Learning. *Journal of Information Science and Technology*, 24-29.
- Pierce JG Jr, Bright S. (2013). Performance of a Colposcopic. *Obstetrics and Gynecology Clinics of North America, Volume 40, Issue 4*, 731-757.
- Pimpa Cheewaparakobkit. (2019). Improving the Performance of an Image Classification with Convolutional Neural Network Model by Using Image Augmentations Technique. *TNI Journal of Engineering and Technology*, 59-64.
- Rojanamatin et al. (2021). *Cancer in Thailand Vol.X*. Bangkok: Medical Record and Database Cancer Unit.
- SAGAR SHARMA. (6 Sep 2017). *Activation Functions in Neural Networks*. เข้าถึงได้จาก towardsdatascience.com: <https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6>
- Smith JS, Plummer M, et al. Clifford GM. (2003). Human papillomavirus types in invasive cervical cancer worldwide:. *British Journal of Cancer*, 88, 63-73.
- Thitiphong Raksarikorn. (2020). *Real-time Face Expression Classification on Embedded Devices using Compact Deep Learning Model*. Bangkok: Dhurakij Pundit University.
- Thomas W. Miller, Richard S. Sutton, และ Paul J. Werbos. (1990). *Neural Networks for Control*. Cambridge: MIT Press.
- World Health Organization. (2020). *Global strategy to accelerate the elimination of cervical cancer as a public health problem*.
- World Health Organization. (10 September 2022). *Comprehensive cervical cancer control: a guide to essential practice, 2nd ed.* เข้าถึงได้จาก <https://apps.who.int/iris/handle/10665/144785>

บรรณานุกรม (ต่อ)

- Yang Han, และ Xing Ming Zhao. (2016). A hybrid sequential feature selection approach for the diagnosis of Alzheimer's Disease. *International Joint Conference on Neural Networks (IJCNN)*, 1216-1220.
- Yongmei Ren, Jie Yang, Qingnian Zhang, และ Zhiqiang Guo. (2019). Multi-Feature Fusion with Convolutional Neural Network for Ship Classification in Optical Images. *Appl. Sci., Volume 9, Issue 20 (October-2 2019)*, 4209.
- Yu Dong g Zhang, Pan Chichun, Sun Junding, และ Tang Chaosheng. (2018). Multiple sclerosis identification by convolutional neural network with dropout and parametric ReLU. *Journal of Computational Science*, 1-10.
- ชิตพงษ์ กิตตินราทร. (1 Jan 2020). *Convolutional Neural Network*. เข้าถึงได้จาก github.io: <https://guopai.github.io/ml-blog19.html>
- พวงทอง ไกรพิบูลย์. (19 Dec 2021). *ซีไอเอ็น: ระยะก่อนมะเร็งปากมดลูก (CIN: Cervical of intraepithelial neoplasia)*. เข้าถึงได้จาก หาหมอ.com: <https://haamor.com/โรคซีไอเอ็น>
- รัสรินทร์ เมธาเฉลิมพัฒน์. (11 Nov 2022). www.nectec.or.th. เข้าถึงได้จาก NECTEC: <https://www.nectec.or.th/news/news-public-document/machine-learning-manufact-1.html>
- ศุภย์สุดิ-นริเวช. (10 September 2022). *โรงพยาบาลธนบุรี*. เข้าถึงได้จาก www.thonburihospital.com: www.thonburihospital.com/การตรวจด้วยกล้องขยายทางช่องคลอด_.html
- สุณาโชค ศรีใจพระเจริญ. (2015). โรคมะเร็งปากมดลูกและการป้องกัน. *เวชระเวชสาร*, 85-93.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ก

ตัวอย่างการเตรียมข้อมูล



รูปที่ ก.1 หน้าตาโปรแกรม EV Insite: DICOM Viewer Software version 3.13.3.0

	Interpreted	Patient ID	Patient sex	Study date and time	Patient age	Patient birthdate	Modality	Accession No.	Proc. Description	Number of images	AE title	Institution	Copy CD/...
1		610133272	F	07 Jul. 2022 07:32:00.031Y	31 Oct. 1990	08 Apr. 1957	ES	GY65970338-GY005	Colpo	4	ThaColpoAe		
2		650311002	F	07 Jul. 2022 02:32:00.065Y			ES	GY65970316-GY005	Colpo	5	ThaColpoAe		

รูปที่ ก.2 ข้อมูลภายในโปรแกรม EV Insite: DICOM Viewer Software version 3.13.3.0

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

No.	Patient no.	Study date and time	Patient age	Patient birthdate	Modality	Accession No.	Proc. Description	Number of images	Grades	Result
1	F	25-Feb-2022 10:58:00 AM	039Y	24-Dec-1982	ES	GV65021271-GY005	Colpo	4	Normal	Colposcopy notesPerformant: DR Nuttavut Kantataharn, MD/Indic
2	F	23-Feb-2022 12:25:00 PM	029Y	30-Nov-1992	ES	GV65021113-GY005	Colpo	6	LGL	Colposcopy notesSelf HPV project CH 35Self sampling --> LBC/HP
3	F	23-Feb-2022 11:30:00 AM	052Y	21-Jun-1969	ES	GV65021104-GY005	Colpo	3	LGL	colpo [2/2/65]: adequate, TZ1, faint AWE at 12 o'clock, no abnor
4	F	22-Feb-2022 11:05:00 AM	033Y	25-Jan-1988	ES	GV65021050-GY005	Colpo	1	Normal	colpo [2/2/65]: adequate, TZ1, no AWE, no atypical vessel
6	F	19-Feb-2022 2:59:00 PM	045Y	30-Oct-1976	ES	GV65020954-GY005	Colpo	7	LGL	Colposcopy notesSelf HPV project CH 48Self sampling --> LBC/HP
8	F	18-Feb-2022 5:55:00 PM	061Y	15-Mar-1960	ES	GV65020918-GY005	Colpo	3	HGL	Colposcopy notesPerformant: DR Nuttavut Kantataharn, MD/Indic
9	F	15-Feb-2022 12:20:00 PM	028Y	21-Nov-1993	ES	GV65020758-GY005	Colpo	7	LGL	colposat. TZ type 2thin AWE at 4-8 o'clock no atypical vessel (MP
10	F	14-Feb-2022 2:44:00 PM	046Y	21-Oct-1975	ES	GV65020717-GY005	Colpo	5	LGL	Indication: Persistent HPV infection (HR non 16/18) x 3 y Colposc
11	F	11-Feb-2022 11:46:00 AM	046Y	11-Jul-1975	ES	GV65020570-GY005	Colpo	3	Normal	Colposcopy; Preacetic: no lesion, transformation zone type 2Posti
13	F	10-Feb-2022 10:11:00 AM	067Y	17-Mar-1954	ES	GV65020492-GY005	Colpo	4	Normal	Colposcopy notes (S/P hysterectomy) Performant: DR Nuttavut Kan
15	F	09-Feb-2022 4:51:00 PM	042Y	18-Mar-1979	ES	GV65020367-GY005	Colpo	5	LGL	colposat. TZ type 2thin AWE at 2-4 o'clock, no atypical vessel(MP
16	F	09-Feb-2022 2:48:00 PM	025Y	18-Aug-1996	ES	GV65020459-GY005	Colpo	6	LGL	Colposcopy notesSelf HPV project CH 47Self sampling --> LBC/HP
17	F	08-Feb-2022 12:15:00 PM	028Y	21-Aug-1993	ES	GV65020387-GY005	Colpo	7	HGL	Colposcopy: satisfactory, TZ type 3: pre-acetic acid: mild eversion
19	F	08-Feb-2022 11:26:00 AM	025Y	22-Jan-1997	ES	GV65020373-GY005	Colpo	3	LGL	colpo [8/2/65]: adequate, TZ1, dense AWE @ 6 o'clock with fine p
20	F	08-Feb-2022 10:33:00 AM	042Y	14-Jul-1979	ES	GV65020366-GY005	Colpo	3	LGL	colpo [8/2/65]: adequate, TZ1, faint AWE at 10-11 o'clock, no abno
21	F	05-Feb-2022 3:28:00 PM	031Y	11-Dec-1990	ES	GV65020275-GY005	Colpo	5	LGL	Colposcopy notesSelf HPV project CH 45Self sampling --> LBC/HP
22	F	05-Feb-2022 3:11:00 PM	036Y	21-Feb-1985	ES	GV65020272-GY005	Colpo	8	LGL	5/2/65pap NILM HPV + no and non 16/18Colposcopy notesSelf HP
23	F	05-Feb-2022 3:00:00 PM	054Y	12-May-1967	ES	GV65020273-GY005	Colpo	12	LGL	HPV HR non 16/18 positive x 2 years Colposcopy- Satisfactory, TZ
24	F	05-Feb-2022 1:42:00 PM	046Y	21-Apr-1975	ES	GV65020262-GY005	Colpo	8	LGL	Colpo pre acetic: small nodule at 12 o'clock, 0.5 cmpost acetic thin
25	F	03-Feb-2022 11:04:00 AM	045Y	26-Apr-1976	ES	GV65020156-GY005	Colpo	2	Normal	3/2/65 LBC; Neg. HPV+ HR non16,18 Colposcopy: preacetic; no le
26	F	02-Feb-2022 6:51:00 PM	037Y	28-Jan-1985	ES	GV65020135-GY005	Colpo	6	LGL	Colposcopy notesSelf HPV project CH 43Self sampling --> LBC/HP
27	F	02-Feb-2022 11:30:00 AM	033Y	2-May-1988	ES	GV65020092-GY005	Colpo	6	LGL	Colposcopy notesSelf HPV project CH 42Self sampling --> LBC/HP
28	F	02-Feb-2022 10:41:00 AM	046Y	6-Nov-1975	ES	GV65020083-GY005	Colpo	2	LGL	adequate, TZ1, generalized reverse punctuation, no abnormal vesse
29	F	01-Feb-2022 11:42:00 AM	029Y	16-Mar-1993	ES	GV65020033-GY005	Colpo	6	LGL	Colposcopy notesSelf HPV project CH 41Self sampling --> LBC/HP
30	F	01-Feb-2022 11:18:00 AM	053Y	13-Feb-1966	ES	GV65020029-GY005	Colpo	5	LGL	colposat. TZ type 2small endocervical polyp 2 mm thin AWE at 6 o
31	F	01-Feb-2022 10:07:00 AM	043Y	28-Sep-1978	ES	GV65020018-GY005	Colpo	4	LGL	colpo[1/2/65]: adequate, TZ1, no abnormal vessel, thin AWE @ 8
32	F	01-Feb-2022 9:16:00 AM	036Y	20-Aug-1985	ES	GV65020006-GY005	Colpo	5	HGL	colpo [1/2/65]: Adequate, TZ1, erosive lesion @ 4-8 o'clock 0.5/0
34	F	29-Jan-2022 11:19:00 AM	041Y	19-Aug-1980	ES	GV65011192-GY005	Colpo	22	LGL	ColpoT-zone type 1Faint AWE lesion at 7 o'clock HPV infection at lo
35	F	25-Jan-2022 11:26:00 AM	027Y	23-Jul-1994	ES	GV65010986-GY005	Colpo	7	HGL	pap HSIL, CIN IIIColposcopy- Satisfactory, TZ type 3- Pre-acetic acid
36	F	25-Jan-2022 11:00:00 AM	045Y	21-May-1976	ES	GV65010982-GY005	Colpo	7	LGL	Colpo sat, TZ type 2thin AWE at 6 o'clock, no atypical vessels(MP L
37	F	24-Jan-2022 10:40:00 AM	036Y	1-Oct-1985	ES	GV65010962-GY005	Colpo	5	LGL	LSIL, IU HPV positivepregnancy GA 8-4 wk Colposcopy- Satisfac
38	F	20-Jan-2022 7:54:00 PM	046Y	9-Dec-1975	ES	GV65010822-GY005	Colpo	3	Normal	Colposcopy notesPerformant: DR Nuttavut Kantataharn, MD/Indic
39	F	20-Jan-2022 10:02:00 PM	048Y	20-Sep-1973	ES	GV65010798-GY005	Colpo	3	Normal	mobile firm nodular surface, ad; no massColposcopy: transformati
40	F	20-Jan-2022 12:25:00 PM	054Y	14-Dec-1967	ES	GV65010791-GY005	Colpo	3	Normal	Colposcopy; transformation zone type 1, Preacetic; no lesion
41	F	19-Jan-2022 7:33:00 PM	041Y	18-Mar-1980	ES	GV65010769-GY005	Colpo	9	LGL	colposat, TZ type 2thin AWE at 12 o'clock atypical vessels(MP;L
42	F	19-Jan-2022 1:31:00 PM	053Y	2-Oct-1968	ES	GV65010739-GY005	Colpo	7	LGL	Colpousmat, TZ type 3thin AWE at 6 o'clockIMP- LGL CDB 6 o'clock
43	F	17-Jan-2022 12:00 PM	050Y	3-Sep-1971	ES	GV65010668-GY005	Colpo	12	Normal	Colposcopy- Satisfactory, TZ type 1: Pre-acetic acid no lesion, no a
44	F	16-Jan-2022 12:27:00 AM	033Y	14-Oct-1988	ES	GV65010597-GY005	Colpo	9	LGL	Colposat, TZ type 2thin AWE at 12 and 6-7 o'clock no atypical vess
45	F	15-Jan-2022 2:09:00 PM	059Y	8-Mar-1962	ES	GV65010543-GY005	Colpo	8	Normal	Colposcopy- unsat, surgical stump no gross mass; pre-acetic acid
46	F	15-Jan-2022 12:47:00 PM	058Y	26-May-1963	ES	GV65010579-GY005	Colpo	6	HGL	Colposcopy- Satisfactory, TZ type 3- Pre-acetic acid no gross lesio
47	F	14-Jan-2022 11:56:00 AM	049Y	25-Feb-1972	ES	GV65010518-GY005	Colpo	2	Normal	LBC; N eg. HPV HR non16,18 Colposcopy: preacetic; no lesion
48	F	12-Jan-2022 7:44:00 PM	037Y	7-Mar-1984	ES	GV65010449-GY005	Colpo	4	Normal	Colposcopy findings - TZ type 2- no abnormal vessel- thin AWE at
49	F	12-Jan-2022 6:42:00 PM	059Y	19-Nov-1962	ES	GV65010443-GY005	Colpo	14	LGL	Colpo sat, TZ type 2thin AWE 12 o'clock no atypical vessels (M
51	F	07-Jan-2022 1:08:00 PM	043Y	9-Nov-1978	ES	GV65010166-GY005	Colpo	4	LGL	Colposcopy notesSelf HPV project CH 38Self sampling --> LBC/HP
52	F	07-Jan-2022 12:20:00 PM	043Y	21-Mar-1978	ES	GV65010165-GY005	Colpo	3	Normal	Colposcopy notesPerformant: DR Nuttavut Kantataharn, MD/Indic
53	F	07-Jan-2022 12:06:00 PM	030Y	23-Oct-1991	ES	GV65010166-GY005	Colpo	8	LGL	Colposcopy notesPerformant: DR Nuttavut Kantataharn, MD/Indic
54	F	06-Jan-2022 8:10:00 PM	031Y	29-Jun-1990	ES	GV65010137-GY005	Colpo	4	LGL	Colposcopy notesPerformant: DR Nuttavut Kantataharn, MD/Indic
56	F	06-Jan-2022 11:55:00 AM	049Y	6-Nov-1972	ES	GV65010112-GY005	Colpo	12	LGL	Colposcopy notesSelf HPV project CH 36Self sampling --> LBC/HP
58	F	05-Jan-2022 3:14:00 PM	031Y	12-Jul-1990	ES	GV65010060-GY005	Colpo	8	LGL	Colposcopy notesSelf HPV project CH 33Self sampling --> LBC/HP

รูปที่ ก.3 รายละเอียดของภาพถ่ายคอลโปสโคปที่เป็นกลุ่มตัวอย่างในการศึกษา

รูปที่ ก.4 การจัดเก็บภาพถ่ายคอลโปสโคปก่อนนำมาใช้งาน


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64031092-GY005-0003.bmp
robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64040231-GY005-0001.bmp
robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64050336-GY005-0003.bmp
robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64070155-GY005-0001.bmp
robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64070540-GY005-0001.bmp
robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64080101-GY005-0002.bmp
robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64080890-GY005-0002.bmp
robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64090214-GY005-0001.bmp
robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64090473-GY005-0004.bmp
robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64090921-GY005-0001.bmp
robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64100087-GY005-0004.bmp
robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64110617-GY005-0002.bmp
robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64110904-GY005-0002.bmp
robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64120241-GY005-0001.bmp
robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64120246-GY005-0002.bmp
robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64120290-GY005-0002.bmp
robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64120502-GY005-0002.bmp
robocopy D:\MS_Kmit\IS\ColpoDataset\ D:\MS_Kmit\IS\ColpoDataset\HGL\ GY64121259-GY005-0001.bmp

```

รูปที่ ก.5 คำสั่งที่ใช้ในการจัดการแบ่งภาพถ่ายเพื่อจัดกลุ่มตามความรุนแรง



รูปที่ ก.6 การจัดเก็บภาพถ่ายคอลโปสโคปหลังการแต่งเติมข้อมูล

ภาคผนวก ข

ตัวอย่างโปรแกรมที่ใช้

```

▼ Horizon flip

[ ] # Define the input and output directories
input_dir = IMG_PATH
output_dir = "/content/drive/MyDrive/IS/Colpo_Zoom60_Flip_Satu/HGL"

# Create the output directory if it doesn't exist
if not os.path.exists(output_dir):
    os.makedirs(output_dir)

# Define a sequence of augmentations
seq = iaa.Sequential([
    iaa.Fliplr(1), # horizontally flip the images
])

# Loop over the input images
for file_name in os.listdir(input_dir):
    # Load the image using OpenCV
    img = cv2.imread(os.path.join(input_dir, file_name))

    # Generate a batch of augmented images
    images_aug = seq(images=[img])

    # Convert the augmented images to NumPy arrays
    images_aug = np.array(images_aug)

    # Save the augmented images to disk
    for i, image_aug in enumerate(images_aug):
        output_file_name = os.path.splitext(file_name)[0] + f"_HGL_Zoom60_Flip_Satu{i}.bmp"
        output_file_path = os.path.join(output_dir, output_file_name)
        cv2.imwrite(output_file_path, image_aug)

```

รูปที่ ข.1 ตัวอย่างคำสั่งที่ใช้ในแต่งเติมข้อมูลภาพถ่าย

```

✓
0s [5] print('Total Class_Normal images:', len(os.listdir(folder_path + 'Normal')))
    print('Total Class_LGL images:', len(os.listdir(folder_path + 'LGL')))
    print('Total Class_HGL images:', len(os.listdir(folder_path + 'HGL')))

Total Class_Normal images: 500
Total Class_LGL images: 500
Total Class_HGL images: 500

```

รูปที่ ข.2 แสดงจำนวนข้อมูลภาพถ่ายคอลโปสโคปหลังการแต่งเติมข้อมูล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

from keras.applications import ResNet50
tf.random.set_seed(8664)
model_RN50 = tf.keras.models.Sequential([
    ResNet50(input_shape=(224,224,3), include_top=False),
])
for layer in model_RN50.layers:
    layer.trainable = True

model_RN50.add(Conv2D(64, (3,3), activation='relu', kernel_regularizer=regularizers.l1(0.01)))
model_RN50.add(Dropout(0.4))
model_RN50.add(Dense(128, activation='relu', kernel_regularizer=regularizers.l1(0.01)))
model_RN50.add(Dropout(0.4))
model_RN50.add(Dense(256, activation='relu', kernel_regularizer=regularizers.l1(0.01)))
model_RN50.add(MaxPooling2D(2,2))
model_RN50.add(Flatten())
model_RN50.add(Dense(512, activation='relu', kernel_regularizer=regularizers.l1(0.01)))
model_RN50.add(Dropout(0.4))
model_RN50.add(Dense(3, activation='softmax'))

model_RN50.summary()

```

Downloading data from https://storage.googleapis.com/tensorflow/keras-applications/resnet/resnet50_weights_tf_dim_ordering_tf_kernels_notop_h5_94765736/94765736 [-----] - 4s 0us/step
Model: "sequential"

Layer (type)	Output Shape	Param #
resnet50 (Functional)	(None, 7, 7, 2048)	23587712
conv2d (Conv2D)	(None, 5, 5, 64)	1179712
dropout (Dropout)	(None, 5, 5, 64)	0
dense (Dense)	(None, 5, 5, 128)	8320
dropout_1 (Dropout)	(None, 5, 5, 128)	0
dense_1 (Dense)	(None, 5, 5, 256)	33024
max_pooling2d (MaxPooling2D)	(None, 2, 2, 256)	0
flatten (Flatten)	(None, 1024)	0
dense_2 (Dense)	(None, 512)	524800
dropout_2 (Dropout)	(None, 512)	0
dense_3 (Dense)	(None, 3)	1539

Total params: 25,335,107
Trainable params: 25,281,987
Non-trainable params: 53,120

รูปที่ ข.3 ตัวอย่างโปรแกรมที่ใช้ในการสร้างตัวแบบ

```

[ ] learning_rate_reduction_VGG16 = ReduceLRonPlateau(monitor='val_accuracy', patience = 2, verbose=1, factor=0.1, min_lr=0.0000001)
callbacks_list_VGG16 = [checkpoint_VGG16, learning_rate_reduction_VGG16]

```

รูปที่ ข.4 โปรแกรม ReduceLRonPlateau ที่ใช้ในปรับปรุงค่า Learning Rate


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ค

ตัวอย่างผลลัพธ์ที่ได้


```
Epoch 19/20
33/33 [=====] - ETA: 0s - loss: 1.0671 - accuracy: 0.6762 - auc: 0.8901 - precision_1: 0.8483 - recall_1: 0.4048 - specificity_at_sensitivity_1: 0.9062 - se
Epoch 19: val_accuracy improved from 0.42800 to 0.43333, saving model to model_MobileNetV2.h5
33/33 [=====] - 78s 2s/step - loss: 1.0671 - accuracy: 0.6762 - auc: 0.8901 - precision_1: 0.8483 - recall_1: 0.4048 - specificity_at_sensitivity_1: 0.9062
Epoch 20/20
33/33 [=====] - ETA: 0s - loss: 1.0637 - accuracy: 0.6933 - auc: 0.8993 - precision_1: 0.8605 - recall_1: 0.4171 - specificity_at_sensitivity_1: 0.9067 - se
Epoch 20: val_accuracy improved from 0.43333 to 0.44222, saving model to model_MobileNetV2.h5
33/33 [=====] - 79s 2s/step - loss: 1.0637 - accuracy: 0.6933 - auc: 0.8993 - precision_1: 0.8605 - recall_1: 0.4171 - specificity_at_sensitivity_1: 0.9067
```

รูปที่ ค.1 ผลการทดสอบประสิทธิภาพของตัวแบบในแต่ละ Epoch




รูปที่ ค.2 แผนภาพแสดงค่า Accuracy ของตัวแบบในแต่ละ Epoch

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ ค.3 แผนภาพแสดงค่า Loss ของตัวแบบในแต่ละ Epoch



รูปที่ ค.4 แผนภาพแสดงค่า Loss ของตัวแบบในแต่ละ Epoch

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ ค.5 Confusion Matrix ของตัวแบบที่ผ่านการทดลองใช้จากชุดข้อมูลทดสอบ

```
print('Model ResNet50\n'
      'Validate Accuracy:', max(history_RN50.history['val_accuracy']), '\n'
      'Validate Loss:', min(history_RN50.history['val_loss']), '\n'
      '\nModel MobileNetV2\n'
      'Validate Accuracy:', max(history_MNV2.history['val_accuracy']), '\n'
      'Validate Loss:', min(history_MNV2.history['val_loss']), '\n'
      '\nModel VGG16\n'
      'Validate Accuracy:', max(history_VGG16.history['val_accuracy']), '\n'
      'Validate Loss:', min(history_VGG16.history['val_loss'])
      )
```

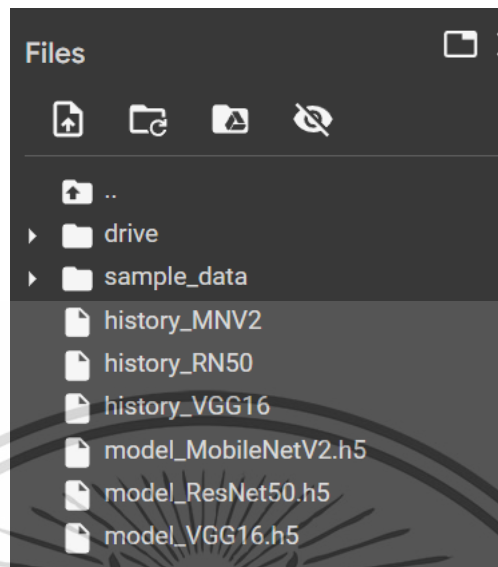
Model ResNet50
Validate Accuracy: 0.5933333039283752
Validate Loss: 1.1929327249526978

Model MobileNetV2
Validate Accuracy: 0.4422222077846527
Validate Loss: 1.8779363632202148

Model VGG16
Validate Accuracy: 0.3333333432674408
Validate Loss: 45.909847259521484

รูปที่ ค.6 การแสดงค่าประสิทธิภาพของตัวแบบแต่ละสถาปัตยกรรม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ ค.7 ไฟล์ตัวแบบที่ดีที่สุด และไฟล์ข้อมูลค่าที่ใช้ในการวัดประสิทธิภาพย้อนหลังแต่ละ Epoch

ประวัติผู้เขียน

ชื่อ	นาย ณัฐศิษฏ์ ลัดหลวง
วัน เดือน ปีเกิด	7 มกราคม 2535
ที่อยู่ปัจจุบัน	56/195 ซ.พระยาสุเรนทร์ 45 แขวงสามวาตะวันตก เขตคลองสามวา กรุงเทพฯ 10510
ประวัติการศึกษา	2557 วิทยาศาสตรบัณฑิต สาขาสถิติประยุกต์ (เกียรตินิยมอันดับ 1) เกรดเฉลี่ย 3.57 สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้