การจำแนกเนื้อวัวและเนื้อหมูโดยใช้เทคนิคการเรียนรู้เชิงลึก

CLASSIFICATION OF BEEF AND PORK USING DEEP LEARNING TECHNIQUES

ปียพักตร์ สมวิทูร

บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ

2565

การจำแนกเนื้อวัวและเนื้อหมูโดยใช้เทคนิคการเรียนรู้เชิงลึก

ปียพักตร์ สมวิทูร

สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล
คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ
ปีการศึกษา 2565
ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

CLASSIFICATION OF BEEF AND PORK USING DEEP LEARNING TECHNIQUES

PEEYAPAK SOMVITOON

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

for the Degree of MASTER OF SCIENCE

(Data Science)

Faculty of Science, Srinakharinwirot University

2022

Copyright of Srinakharinwirot University

สารนิพนธ์

เรื่อง

การจำแนกเนื้อวัวและเนื้อหมูโดยใช้เทคนิคการเรียนรู้เชิงลึก

ของ

ปียพักตร์ สมวิทูร

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล

ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์ฉัตรชัย เอกปัญญาสกุล)

คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

..... ที่ปรึกษาหลัก

(อาจารย์ ดร.เรืองศักดิ์ ตระกูลพุทธิรักษ์)

..... ประธาน

(ผู้ช่วยศาสตราจารย์ ดร.รัตน์ชัยนันท์ ธรรมสุจริต)

..... กรรมการ

(ผู้ช่วยศาสตราจารย์ ดร.ศิริสรรพ เหล่าหะเกียรติ)

ชื่อเรื่อง	การจำแนกเนื้อวัวและเนื้อหมูโดยใช้เทคนิคการเรียนรู้เชิงลึก
ผู้วิจัย	ปียพักตร์ สมวิทูร
ปริญญา	วิทยาศาสตรมหาบัณฑิต
ปีการศึกษา	2565
อาจารย์ที่ปรึกษา	อาจารย์ ดร. เรืองศักดิ์ ตระกูลพุทธิรักษ์

ด้วยความหลากหลายของวัฒนธรรมสังคมไทย บางคนกินเนื้อวัวแต่ไม่กินหมู บางคนกินหมูแต่ไม่กินเนื้อวัว ข้อห้ามเหล่านี้สร้างข้อกำหนดเพื่อให้แน่ใจว่าเนื้อสัตว์ที่กินได้นั้นเหมาะสมที่จะบริโภคได้ การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อสร้างแบบจำลองการเรียนรู้ของเครื่องเพื่อจำแนกเนื้อวัวและเนื้อหมูโดยใช้ภาพเนื้อวัวและเนื้อหมู โดยแบ่งข้อมูลออกเป็นชุดข้อมูลการสอนและชุดข้อมูลการทดสอบ การศึกษานี้ทดสอบความถูกต้องของการจำแนกโดยใช้ภาพต้นฉบับขนาด 3000x4000 พิกเซล และ 4000x3000 พิกเซล ทำการครอบตัดรูปภาพจากกึ่งกลางโดยใช้ขนาดครอบตัด 1000x1000 พิกเซล, 2000x2000 พิกเซล และ 3000x3000 พิกเซลตามลำดับ ผลลัพธ์ที่ได้คือขนาดภาพที่มีประสิทธิภาพสูงสุดคือ 3000x3000 พิกเซล เมื่อปรับขนาดภาพเป็น 224x224 พิกเซล อัตราส่วนภาพต้นฉบับจะเปลี่ยนไป แต่สำหรับภาพขนาด 3000x3000 พิกเซล อัตราส่วนภาพจะคงเดิม สำหรับการทดลองด้วยเทคนิคการเรียนรู้เชิงลึก โมเดล DenseNet201 เป็นโมเดลที่ใช้จำแนกได้ดีที่สุดโดยพิจารณาจากประสิทธิภาพและจำนวนรอบการเทรน พื้นที่ใต้กราฟ ROC คือ 0.997

คำสำคัญ : การเรียนรู้ของเครื่อง, เทคนิคการเรียนรู้เชิงลึก

Title	CLASSIFICATION OF BEEF AND PORK USING DEEP LEARNING TECHNIQUES
Author	PEEYAPAK SOMVITOON
Degree	MASTER OF SCIENCE
Academic Year	2022
Thesis Advisor	Dr. Ruangsak Trakunphutthirak

With the variety of Thai social culture, some people consume beef, but do not consume pork, while some people consume pork, but not consume beef. These prohibitions create the requirement to ensure that the edible meat they can consume is proper. The aim of this research is to create a machine-learning model to classify beef and pork by using beef and pork images. We divide data into training and testing datasets. This study tests the validity of the model by taking the original image size of 3000x4000 pixels and 4000x3000 pixels. The image is cropped from the center by using the cropping sizes, 1000x1000 pixels, 2000x2000 pixels and 3000x3000 pixels respectively. The results showed that the most effective image size is 3000x3000 pixels. When resizing an image to 224x224 pixels, the original aspect ratio will be changed. However, for the image of 3000x3000 pixels, the aspect ratio will remain the same. In an experiment using deep learning techniques, the DenseNet201 model reveals as the best classification model by considering the performance and the number of epochs. The area under the ROC graph is 0.997.

Keyword : Machine Learning, deep learning techniques

กิตติกรรมประกาศ

การวิจัยเรื่อง การจำแนกเนื้อวัวและเนื้อหมูโดยใช้เทคนิคการเรียนรู้เชิงลึก สามารถดำเนินการไปด้วยดี เนื่องจากได้รับความอนุเคราะห์จาก

อ. ดร. เรืองศักดิ์ ตระกูลพุทธิรักษ์ ที่กรุณาให้คำแนะนำ และปรับปรุงข้อบกพร่องต่างๆ จนกระทั่งการวิจัยสำเร็จด้วยดี

ขอขอบคุณ นส.เมธากาญจน์ ง้อตระกูล ที่ช่วยเหลืองานทางด้านเอกสาร

สุดท้ายนี้ทางผู้วิจัยหวังว่างานวิจัยนี้จะมีประโยชน์สำหรับผู้ที่ศึกษาต่อไป

ปิยพักตร์ สมวิทูร

สารบัญ

หน้า

บทคัดย่อภาษาไทย ..... ง

บทคัดย่อภาษาอังกฤษ ..... จ

กิตติกรรมประกาศ ..... ฉ

สารบัญ ..... ช

สารบัญตาราง ..... ฌ

สารบัญรูปภาพ ..... ญ

บทที่ 1 บทนำ 1

1.1 ความสำคัญและความเป็นมาของงานวิจัย 1

1.2 วัตถุประสงค์ 2

1.3 **ขอบเขตของงานวิจัย** 2

1.4 นิยามศัพท์เฉพาะ 4

1.5 กรอบแนวคิดในงานวิจัย 5

1.6 สมมติฐานในงานวิจัย 5

1.7 ประโยชน์ที่คาดว่าจะได้รับจากงานวิจัย 5

บทที่ 2 วรรณกรรมและงานวิจัยที่เกี่ยวข้อง 6

2.1 **ทฤษฎีเกี่ยวกับอัลกอริทึม** 6

2.2 งานวิจัยที่เกี่ยวข้อง 9

บทที่ 3 วิธีดำเนินการวิจัย 17

3.1 กระบวนการวิจัย 17

3.2 การสำรวจข้อมูล (Exploratory Data Analysis: EDA) 18

3.3 การเตรียมข้อมูล (Data Preprocessing) 18

3.4 การตัดส่วนของภาพ (Image Cropping) 19
3.5 การปรับขนาดภาพ (Image Resizing) 20
3.6 การสร้างแบบจำลอง (Model Creation) 21
3.7 การวัดประสิทธิภาพ และวิเคราะห์ผล 21
บทที่ 4 ผลการทดลอง 25
4.1 วิธีการทดลอง 25
4.2 ขั้นตอนในการวิจัย 25
เปรียบเทียบประสิทธิภาพแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันที่เกิดจากการเปลี่ยนไฮเปอร์พารามิเตอร์ 27
เปรียบเทียบประสิทธิภาพแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน และแบบจำลองจากเทคนิคการเรียนรู้เชิงลึก 46
เปรียบเทียบค่าพื้นที่ใต้กราฟ ROC ค่าความถูกต้อง (Accuracy) และจำนวนรอบที่สอนแบบจำลอง(Epochs) 58
บทที่ 5 สรุปผล อภิปรายผล และข้อเสนอแนะ 71
5.1 สรุปผลการวิจัย 71
5.2 อภิปรายผลการวิจัย 72
5.3 ข้อเสนอแนะ 73
บรรณานุกรม 74
ประวัติผู้เขียน 78

สารบัญตาราง

หน้า

ตาราง 1 ชุดข้อมูลที่นำมาใช้ในงานวิจัย 18

สารบัญรูปภาพ

หน้า

ภาพประกอบ 1 ตัวอย่างเนื้อวัวและเนื้อหมู 3

ภาพประกอบ 2 เซลล์ประสาท..... 6

ภาพประกอบ 3 โหนด..... 7

ภาพประกอบ 4 โครงข่ายประสาทเทียม..... 7

ภาพประกอบ 5 โครงข่ายประสาทเทียมแบบคอนโวลูชัน..... 8

ภาพประกอบ 6 การรับรู้ข้อมูลรูปภาพของ โครงข่ายประสาทเทียมแบบคอนโวลูชัน 8

ภาพประกอบ 7 กระบวนการวิจัย 17

ภาพประกอบ 8 วิธีการตัดสัดส่วนภาพ..... 19

ภาพประกอบ 9 การปรับขนาดภาพ 20

ภาพประกอบ 10 ตัวอย่างการปรับขนาดภาพโดยอัลกอลิทึม NEAREST..... 21

ภาพประกอบ 11 เครื่องมือวัดประสิทธิภาพ 22

ภาพประกอบ 12 เมทริกซ์ความสับสน 22

ภาพประกอบ 13 ผลลัพธ์กรณีภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3, และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50..... 28

ภาพประกอบ 14 ผลลัพธ์กรณีภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4, และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50..... 29

ภาพประกอบ 15 ผลลัพธ์กรณีภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50..... 30

ภาพประกอบ 16 ผลลัพธ์กรณีภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 40 และ 50 31

ภาพประกอบ 17 ผลลัพธ์กรณีภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 32

ภาพประกอบ 18 ผลลัพธ์กรณีภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 33

ภาพประกอบ 19 ผลลัพธ์กรณีภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 34

ภาพประกอบ 20 ผลลัพธ์กรณีภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 40 และ 50 35

ภาพประกอบ 21 ผลลัพธ์กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 36

ภาพประกอบ 22 ผลลัพธ์กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 37

ภาพประกอบ 23 ผลลัพธ์กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 38

ภาพประกอบ 24 ผลลัพธ์กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 39

ภาพประกอบ 25 ผลลัพธ์กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 40

ภาพประกอบ 26 ผลลัพธ์กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 41

ภาพประกอบ 27 ผลลัพธ์กรณีภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50..... 42

ภาพประกอบ 28 ผลลัพธ์กรณีภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50..... 43

ภาพประกอบ 29 กรณีภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50..... 44

ภาพประกอบ 30 กรณีภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 40 และ 50 45

ภาพประกอบ 31 ผลลัพธ์กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 7 แบบจำลอง 46

ภาพประกอบ 32 ผลลัพธ์กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 7 แบบจำลอง 47

ภาพประกอบ 33 ผลลัพธ์กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 40 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 7 แบบจำลอง 48

ภาพประกอบ 34 ผลลัพธ์กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 7 แบบจำลอง 49

ภาพประกอบ 35 ผลลัพธ์กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 40 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 50

ภาพประกอบ 36 ผลลัพธ์กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201 51

ภาพประกอบ 37 กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet20152

ภาพประกอบ 38 กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30 และ 50 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet20153

ภาพประกอบ 39 ผลลัพธ์กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 ทำการทดสอบระบบซึ่งใช้

เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201 54

ภาพประกอบ 40 ผลลัพธ์กรณีชุดข้อมูลจากภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 และ 40 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201 55

ภาพประกอบ 41 ผลลัพธ์กรณีชุดข้อมูลจากภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 และ 40 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201 56

ภาพประกอบ 42 กรณีชุดข้อมูลจากภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 และ 40 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201 57

ภาพประกอบ 43 เปรียบเทียบพื้นที่ใต้กราฟ ROC ในงานวิจัยนี้ 59

ภาพประกอบ 44 เปรียบเทียบค่าความถูกต้อง(accuracy)ในงานวิจัยนี้ 60

ภาพประกอบ 45 เปรียบเทียบจำนวนรอบที่มีการสอนแบบจำลอง(Epochs) 61

ภาพประกอบ 46 เปรียบเทียบพื้นที่ใต้กราฟ ROC หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณี อัตราการเรียนรู้ (Learning rate) ค่า 1e-3 62

ภาพประกอบ 47 เปรียบเทียบพื้นที่ใต้กราฟ ROC หลังจากใช้เทคนิคการเรียนรู้เชิงลึกกรณีอัตราการเรียนรู้ (Learning rate) ค่า 1e-4 63

ภาพประกอบ 48 เปรียบเทียบพื้นที่ใต้กราฟ ROC หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณี อัตราการเรียนรู้ (Learning rate) ค่า 1e-5 64

ภาพประกอบ 49 เปรียบเทียบค่าความถูกต้อง(Accuracy)หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณีอัตราการเรียนรู้ (Learning rate) ค่า 1e-3 65

ภาพประกอบ 50 เปรียบเทียบค่าความถูกต้อง(Accuracy) หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณี อัตราการเรียนรู้ (Learning rate) ค่า 1e-4 66

ภาพประกอบ 51 เปรียบเทียบค่าความถูกต้อง(Accuracy)หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณีอัตราการเรียนรู้ (Learning rate) ค่า 1e-5 67

ภาพประกอบ 52 เปรียบเทียบจำนวนรอบที่สอนแบบจำลอง(Epochs) หลังจากใช้เทคนิคการเรียนรู้เชิงลึกกรณีอัตราการเรียนรู้ (Learning rate) ค่า 1e-3..... 68

ภาพประกอบ 53 เปรียบเทียบจำนวนรอบที่สอนแบบจำลอง(Epochs) หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณี อัตราการเรียนรู้ (Learning rate) ค่า 1e-4..... 69

ภาพประกอบ 54 เปรียบเทียบจำนวนรอบที่สอนแบบจำลอง(Epochs) หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณีอัตราการเรียนรู้ (Learning rate) ค่า 1e-5..... 70

บทที่ 1
บทนำ

1.1 ความสำคัญและความเป็นมาของงานวิจัย

อาหาร ที่อยู่อาศัย เครื่องนุ่งห่ม และยารักษาโรค เป็น ปัจจัย 4 ซึ่งจำเป็นในการดำรงชีวิตของคน สำหรับอาหารนั้น เนื้อสัตว์ที่คนนิยมบริโภคในประเทศไทย มี เนื้อหมู, เนื้อไก่, เนื้อปลา, เนื้อวัว และเนื้อเป็ด โดยลักษณะของเนื้อสัตว์ที่คล้ายกันคือ เนื้อวัวและ เนื้อหมู ซึ่งหากคนไม่สังเกตุ อาจทานผิดได้ โดยเฉพาะตามร้านอาหารที่เป็นลักษณะให้บริการเนื้อหมูหรือ เนื้อวัวสไลด์ เช่นร้านชาบู, ร้านสุกี้ หรือร้านปิ้งย่าง ซึ่งมีเป็นจำนวนมากในปัจจุบัน ทั้งนี้จากวัฒนธรรมทางสังคมทำให้ปรากฏว่า คนไทยบางส่วนบริโภค เนื้อวัว ไม่บริโภคเนื้อหมู เช่นผู้นับถือศาสนาอิสลามมีบทบัญญัติทางศาสนาไม่ให้บริโภคเนื้อหมู และมองว่าหมูเป็นสัตว์สกปรก และมีวัฒนธรรมทางสังคมบางแห่งเช่นกันที่มีคนที่บริโภคเนื้อหมูไม่บริโภคเนื้อวัว เช่น คนที่นับถือศาสนาฮินดูไม่กินหรือฆ่าวัว เพราะถือเป็นสัตว์ศักดิ์สิทธิ์ตามความเชื่อศาสนา หรือคนไทยเชื้อสายจีนที่นับถือเจ้าแม่กวนอิม จะไม่ทานเนื้อวัว เพราะเชื่อว่าเจ้าแม่กวนอิมไม่ทานเนื้อวัว หรือแม้กระทั่ง คนที่บริจาคไถ่ชีวิต โค กระบือ บางคนจะไม่ทานเนื้อวัวอีกเลย เนื่องจากถือว่า ได้ช่วยชีวิตวัวแล้ว จึงไม่ทานเนื้อวัว ซึ่งความเชื่อ หรือข้อห้ามต่างๆเหล่านี้ ทำให้เกิดความต้องการที่จะมั่นใจว่า เนื้อที่บริโภคเป็นเนื้อสัตว์ที่คนนั้นๆบริโภคได้ ไม่ต้องการที่จะเผลอบริโภคเนื้อสัตว์ต้องห้ามของตัวเอง ความแตกต่างโดยทั่วไปของเนื้อวัว เนื้อหมู มีหลายคุณลักษณะ คือ สี โดยเนื้อวัวสีจะเข้มกว่าเนื้อหมู, ใยของเนื้อโดยเนื้อวัว ใยของเนื้อจะเป็นริ้วตามแนวยาว เนื้อหมู จะมีริ้วน้อย, ไขมัน โดยไขวันวัวจะแข็งกระด้างกว่า แยกออกง่ายจากเนื้อ ไขมันหมูจะซุ่มและแยกยากจากเนื้อ, เนื้อสัมผัส เนื้อวัวเหนียวกว่า, กลิ่น เนื้อวัวจะมีกลิ่นคาวของเนื้อ ซึ่งความแตกต่างเหล่านี้หากไม่คุ้นเคย สามารถทำให้เกิดการเข้าใจผิดคิดว่าเนื้อวัว เป็นเนื้อหมู หรือ เนื้อหมูเป็นเนื้อวัวได้ ซึ่งได้เคยมีข่าว การปลอมเนื้อวัวเป็นเนื้อหมูมาบ้างแล้ว เพราะ เนื้อหมูราคาถูกกว่าเนื้อวัว หากนำไปใส่สี สามารถหลอกว่าเป็นเนื้อวัวได้ ทั้งนี้เพราะเนื้อวัวมีราคาสูงกว่าเนื้อหมู หากผู้บริโภคไม่ชำนาญอาจถูกหลอกได้ หรือสำหรับในเมืองใหญ่ที่มีร้านชาบู เป็นที่นิยม ซึ่งจะมีการเสิร์ฟหมูสไลด์มาให้ บางครั้ง การสไลด์เนื้อของร้านเมื่อเปรียบเทียบระหว่างเนื้อวัวและเนื้อหมู ผู้บริโภคจะยากในการแยกว่าจานไหนเป็นเนื้อวัว หรือเนื้อหมู ซึ่งหากผู้ไม่ทานเนื้อวัว เข้าใจผิดและทานเนื้อวัวเข้าไป จะก่อให้เกิดความไม่สบายใจในการบริโภค และอาจไม่มาร้านค้านั้นๆอีกเลย ซึงอาจส่งผลในเชิงจิตวิทยาสำหรับผู้บริโภคได้

แนวคิดงานวิจัยชิ้นนี้เป็นการใช้ภาพเนื้อหมู เนื้อวัว สร้างวิธีการแยกประเภทเนื้อวัวและเนื้อหมูด้วยวิธีการเรียนรู้ของเครื่องจักร (Machine Learning) โดยใช้ โครงข่ายประสาทเทียมแบบ

คอนโวลูชัน (CNN) เป็นการนำวิธีการทางวิทยาศาสตร์ข้อมูลมาสร้างระบบการเรียนรู้เพื่อ สอนระบบให้สามารถตัดสินใจในการจำแนกเนื้อวัว เนื้อหมู ได้อย่างมีประสิทธิภาพ โดยใช้งานร่วมกับการปรับไฮเปอร์พารามิเตอร์ และการสกัดคุณลักษณะพิเศษ

โดยงานวิจัยชิ้นนี้เป็นลักษณะ การจำแนกแบบไบนารี คือการใช้วิธีการเรียนรู้ของเครื่องจักร เพื่อจำแนกประเภทของเนื้อสัตว์ 2 ประเภท คือ เนื้อวัว และ เนื้อหมู โดยนำข้อมูลรูปภาพมาใช้ในการสอนระบบ เพื่อสร้างแบบจำลอง และจำแนกผลออกมาเป็น 2 ประเภท จากนั้นทำการทดสอบโดยนำรูปภาพทดสอบกับแบบจำลองที่สร้างขึ้น เพื่อทดสอบค่าความถูกต้องของแบบจำลอง

1.2 **วัตถุประสงค์**

ในการวิจัยครั้งนี้ผู้วิจัยได้ตั้งความมุ่งหมายไว้ดังนี้

เพื่อศึกษาและเปรียบเทียบการสร้างแบบจำลองการจำแนกภาพเนื้อวัวและเนื้อหมู โดยใช้เทคนิคการเรียนรู้เชิงลึก ซึ่งใช้แบบจำลองที่ถูกสอนแล้ว เป็นส่วนหนึ่งของแบบจำลองที่พัฒนาขึ้น

เพื่อศึกษาการปรับเปลี่ยน ไฮเปอร์พารามิเตอร์ ต่างๆ กับชุดข้อมูลภาพ ในการสร้างแบบจำลองที่มีประสิทธิภาพ และเหมาะสมในการใช้งานกับข้อมูลชุดนี้

เพื่อศึกษาความแตกต่างของลักษณะรูปภาพที่ใช้ในการสร้างแบบจำลอง ภาพลักษณะใดที่เหมาะสมกับการใช้งานกับการสร้างแบบจำลองมากที่สุด โดยเปรียบเทียบจาก ประสิทธิภาพและเวลา

เพื่อเปรียบเทียบวัดประสิทธิภาพของแบบจำลองที่สร้างจากการใช้ข้อมูลรูปภาพเนื้อวัวกับรูปภาพเนื้อหมู เมทริกซ์ความสับสน(Confusion Matrix), ความถูกต้อง (Accuracy), คะแนน F1 (F1-Score) และพื้นที่ใต้กราฟ ROC

1.3 **ขอบเขตของงานวิจัย**

งานวิจัยนี้เป็นการแยกเนื้อหมู และเนื้อวัวที่มีลักษณะเดียวกับที่ขายในร้านอาหาร โดยมีการใช้งาน แบบจำลองพื้นฐาน คือ ใช้ โครงข่ายประสาทเทียมแบบคอนโวลูชัน ทำการทดลอง มีภาพที่ใช้คือภาพเนื้อวัว และเนื้อ ใช้ภาพที่ถ่ายจากโทรศัพท์เป็นชุดข้อมูล ขนาด 3000x4000 พิกเซล และ 4,000x3,000 พิกเซล นำมาตัดขอบเป็นภาพขนาด 1000x1000 พิกเซล, 2000x2000

พิกเซล และ 3000x3000 พิกเซล ทำการปรับขนาดภาพเป็นภาพขนาด 224x224 พิกเซล ทำการปรับ ไฮเปอร์พารามิเตอร์ และทดลองเปลี่ยนModel ทำการทดสอบประสิทธิภาพแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน ที่มีการปรับไฮเปอร์พารามิเตอร์ และทำการทดสอบเปรียบเทียบประสิทธิภาพกับแบบจำลองเทคนิคการเรียนรู้เชิงลึกอื่นโดยแบบจำลองที่เลือกใช้ จะเป็น แบบจำลองที่มีขนาดเล็ก ความถูกต้อง (Accuracy) สูง ใช้เวลาในการประมวลผลไม่มาก เช่น MobileNetV2, Resnet50V2 และ Densenet201 เพื่อเปรียบเทียบว่าแบบจำลองใดให้ประสิทธิภาพที่ดีที่สุด โดยผลลัพธ์สุดท้ายคือจะได้แบบจำลองที่เหมาะสมซึ่งจะทำให้ระบบมีเสถียรภาพ, ประสิทธิภาพสูงสุด ใช้เวลาน้อยในการจำแนกเนื้อวัว เนื้อหมูสำหรับงานวิจัยนี้ โดยพิจารณาจากความถูกต้อง เมทริกซ์ความสับสน และพื้นที่ใต้กราฟROC

ภาพประกอบ 1 ตัวอย่างเนื้อวัวและเนื้อหมู

ประชากรที่ใช้ในการวิจัย

1. ภาพเนื้อวัว จำนวน 3,519 ภาพ
2. ภาพเนื้อหมู จำนวน 3,519 ภาพ

แบบจำลองพื้นฐาน ที่ใช้ในการวิจัย

- โครงข่ายประสาทเทียมแบบคอนโวลูชัน

1.4 นิยามศัพท์เฉพาะ

ศัพท์ที่ 1 Deep Learning หมายถึง แบบจำลองทางคณิตศาสตร์ที่พยายามจำลองสมองของคน ออกแบบมาเพื่อวิเราะห์ข้อมูลแบบต่อเนื่องตามโครงสร้างเชิงตรรกะ อาศัยโครงสร้างลำดับชั้น ของ โครงข่ายประสาทเทียม สามารถเรียนรู้และตัดสินใจได้ด้วยตัวเอง โดยยิ่งข้อมูลเข้ามา Train มาก ประสิทธิภาพในการคิดของคอมพิวเตอร์จะยิ่งมาก

ศัพท์ที่ 2 Neural Network หมายถึง โครงข่ายประสาทเทียม คือแบบจำลองทางคณิตศาสตร์ ที่จำลองมาจากการศึกษาโครงข่ายไฟฟ้าในสมอง โดยข่ายงานประสาทเกิดจากการเชื่อมต่อระหว่างเซลล์ประสาท จนเป็นเครือข่ายที่ทำงานร่วมกัน

ศัพท์ที่ 3 Convolutional Neural Networks หรือเรียกว่า CNN หมายถึง โครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยจะจำลองการมองเห็นของมนุษย์ที่มองพื้นที่เป็นพื้นที่ย่อยๆ และนำมารวมกันเพื่อพิจารณาว่าเป็นอะไร

ศัพท์ที่ 4 Keras หรือเรียกว่าเคราส เป็น ไลบรารีภาษาไพทอน ใช้ในการทำงานกับโครงข่ายประสาทเทียม ใช้เลือกโมเดลที่ถูกสอนเพื่อนำโมเดลที่สร้างเองต่อท้ายในการประมวลผล

ศัพท์ที่ 5 TensorFlow หรือเรียกว่า เท็นโซโฟว์ หมายถึง ไลบรารีภาษาไพทอน ใช้ในการทำงานกับการเรียนรู้ด้วยเครื่อง ใช้เลือกโมเดลที่ถูกสอนเพื่อนำโมเดลที่สร้างเองต่อท้ายในการประมวลผล

ศัพท์ที่ 6 SHAP หรือแชฟ เป็นเครื่องมือในการช่วยวิเคราะห์โดยจะเป็นการอธิบายคุณลักษณะของสิ่งที่เราสนใจ โดยจะแสดงว่าสิ่งไหนมีส่วนในการจำแนกสิ่งที่เราสนใจ

ศัพท์ที่ 7 Densenet121 เป็นแบบจำลองที่ถูกฝึกมาแล้ว ใช้เพื่อเป็นส่วนช่วยในการสร้างแบบจำลองใหม่ต่อไป เป็นโมเดลที่เลือกมาจากเคราส

ศัพท์ที่ 8 Densenet201 เป็นแบบจำลองที่ถูกฝึกมาแล้ว ใช้เพื่อเป็นส่วนช่วยในการสร้างแบบจำลองใหม่ต่อไป เป็นโมเดลที่เลือกมาจากเคราส

ศัพท์ที่ 9 MobileNetV2 เป็นแบบจำลองที่ถูกฝึกมาแล้ว ใช้เพื่อเป็นส่วนช่วยในการสร้างแบบจำลองใหม่ต่อไป เป็นโมเดลที่เลือกมาจากเคราส

ศัพท์ที่ 10 NASNetMobile เป็นแบบจำลองที่ถูกฝึกมาแล้ว ใช้เพื่อเป็นส่วนช่วยในการสร้างแบบจำลองใหม่ต่อไป เป็นโมเดลที่เลือกมาจากเคราส

ศัพท์ที่ 11 Xception เป็นแบบจำลองที่ถูกฝึกมาแล้ว ใช้เพื่อเป็นส่วนช่วยในการสร้างแบบจำลองใหม่ต่อไป เป็นโมเดลที่เลือกมาจากเคราส

ศัพท์ที่ 12 Vgg16 เป็นแบบจำลองที่ถูกฝึกมาแล้ว ใช้เพื่อเป็นส่วนช่วยในการสร้างแบบจำลองใหม่ต่อไป เป็นโมเดลที่เลือกมาจากเคราส

ศัพท์ที่ 13 ResNet50V2 เป็นแบบจำลองที่ถูกฝึกมาแล้ว ใช้เพื่อเป็นส่วนช่วยในการสร้างแบบจำลองใหม่ต่อไป เป็นโมเดลที่เลือกมาจากเคราส

1.5 กรอบแนวคิดในงานวิจัย

งานวิจัยนี้เป็นการศึกษาและนำเสนอแนวคิดวิธีแก้ปัญหาของการแยกภาพสไลด์ของ เนื้อวัวและเนื้อหมู ซึ่งมีการให้บริการในร้านอาหาร โดยใช้เทคนิคโครงข่ายปราสาทเทียมแบบคอนโวลูชัน เพื่อสร้างแบบจำลองในการจำแนกภาพเนื้อวัว เนื้อหมู

1.6 สมมติฐานในงานวิจัย

ปัจจัยในการจำแนกเนื้อวัวและเนื้อหมูจากชุดข้อมูลการจำแนกลักษณะ มีผลต่อความถูกต้องและแม่นยำในการจำแนกและคุณภาพการเรียนรู้ของเครื่องมือที่นำมาใช้ เพื่อตอบสนองในการลดเวลาการจำแนกเนื้อวัวและเนื้อหมู

1.7 ประโยชน์ที่คาดว่าจะได้รับจากงานวิจัย

1. ได้แบบจำลองเพื่อจำแนกเนื้อวัวและและเนื้อหมูโดยใช้แบบจำลองที่พัฒนาขึ้นโดยเทคนิคที่มีประสิทธิภาพ

2. ทำให้ทราบวิธีการเพิ่มประสิทธิภาพและประสิทธิผลการจำแนกเนื้อวัวและเนื้อหมู

3. แบบจำลองอาจนำมาซึ่งการลดต้นทุนค่าใช้จ่ายทรัพยากรคนเพื่อการแยกประเภทเนื้อสัตว์

4. สามารถนำแบบจำลองไปประยุกต์ใช้กับปัญหาอื่นๆในการแยกวัตถุที่มีรูปร่าง, สี หรือขนาดใกล้เคียงกันได้

5. เป็นพื้นฐานเพื่อใช้ในงานวิจัยอื่นที่มีลักษณะคล้ายกัน และสามารถนำผลงานเพื่อประยุกต์ต่อได้

ในบทนี้เป็นกล่าวถึงที่มา จุดประสงค์การวิจัย ขอบเขตงานวิจัย สมมติฐาน และประโยชน์ที่ได้รับจากงานวิจัย โดยจะกล่าวถึงงานวิจัยที่เกี่ยวข้องในบทที่ 2 ต่อไป

บทที่ 2
วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

งานวิจัยนี้ใช้แบบจำลองจำแนกข้อมูลแบบโครงข่ายประสาทเทียมแบบคอนโวลูชัน ในการแยกข้อมูล 2 ประเภท และได้นำเสนอหัวข้อ ดังนี้

2.1 ทฤษฎีเกี่ยวกับอัลกอริทึม

งานวิจัยนี้เป็นการจำแนกประเภทข้อมูลรูปภาพ 2 ประเภท โดยใช้ เทคนิคการเรียนรู้เชิงลึก

2.1.1 เทคนิคการเรียนรู้เชิงลึก(Deep learning)

เป็นส่วนหนึ่งของการเรียนรู้ด้วยเครื่อง(Machine Learning) ซึ่งเป็นอัลกอลิทึมที่มีจุดประสงค์เพื่อให้คอมพิวเตอร์สามารถเรียนรู้ด้วยตัวเองจากข้อมูลต่างๆที่ถูกสอน เพื่อนำไปสู่การตัดสินใจของเอาต์พุตที่ถูกต้อง

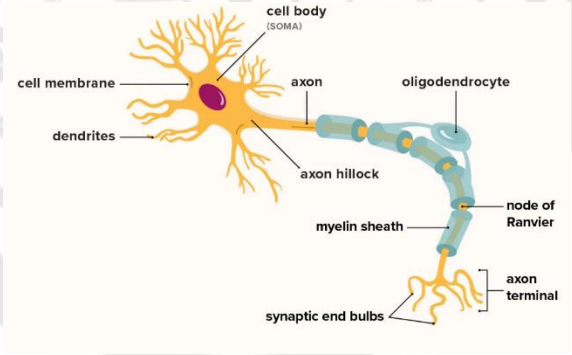

ภาพประกอบ 2 เซลล์ประสาท

ที่มา : Smith (2023)

โดยเทคนิคการเรียนรู้เชิงลึกมีพื้นฐานจาก โครงข่ายประสาทเทียม(Neuron Network) เป็นการเลียนแบบการทำงานของโครงข่ายประสาทของมนุษย์ โดยการจำลองการทำงานของเซลล์ประสาท ซึ่งเซลล์ประสาทแต่ละเซลล์จะทำงานเชื่อมโยงกัน และกระจายการวิเคราะห์ข้อมูลอย่างทั่วถึง

หน่วยย่อยของโครงข่ายประสาทเทียมที่ทำงานคล้ายเซลล์ประสาท เรียกว่า โหนด (Node) โหนดจำนวนหนึ่งเรียงตัวเป็นชั้น เรียกชั้นหรือเลเยอร์(Layer) ซึ่งโหนดในชั้นจะทำหน้าที่เดียวกันในชั้นนั้นๆ

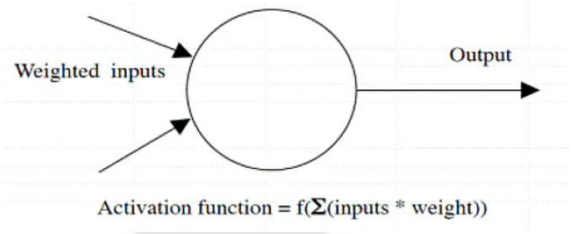

ภาพประกอบ 3 โหนด

ที่มา : (ProjectPro, 2023)

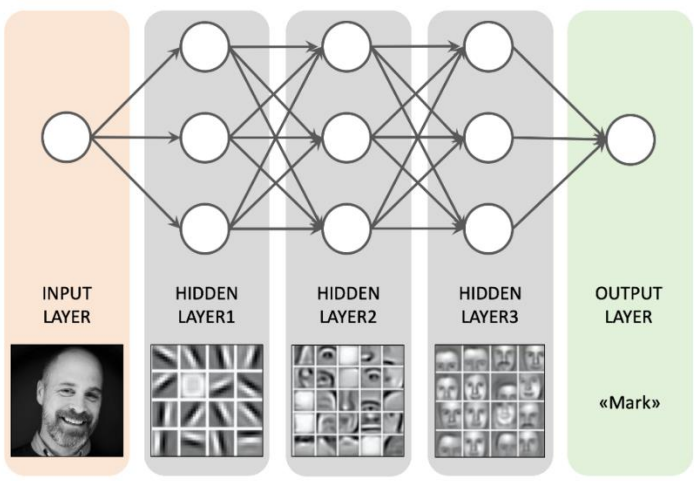

ภาพประกอบ 4 โครงข่ายประสาทเทียม

ที่มา : (West, 2023b)

โครงข่ายประสาทเทียมจะมี องค์ประกอบ 3 ส่วนคือชั้นข้อมูลเข้า(Input Layer), ชั้นซ่อน (Hidden Layer) และชั้นข้อมูลออก(Output Layer)

1. ชั้นข้อมูลเข้า (Input Layer)

ชั้นที่เป็นข้อมูลที่ใช้ในการสอนแบบจำลอง จำนวนโหนดขึ้นกับจำนวนประเภทข้อมูลที่ใช้สอน หรือที่เรียกว่าจำนวณคุณลักษณะของข้อมูล(Feature)

2. ชั้นซ่อน (Hidden Layer)

ชั้นที่เสมือนเป็นส่วนที่เรียนรู้ข้อมูลเชิงลึก มีผลต่อการเรียนรู้ และประสิทธิภาพของแบบจำลอง ในชั้นซ่อน จะมี Activation Function

3. ชั้นข้อมูลออก(Output Layer)

ชั้นที่เป็นส่วนผลลัพธ์ของการประมวลผลของโครงข่ายประสาทเทียม

2.1.2 การเรียนรู้ของเครื่องประเภทโครงข่ายประสาทเทียมแบบคอนโวลูชัน

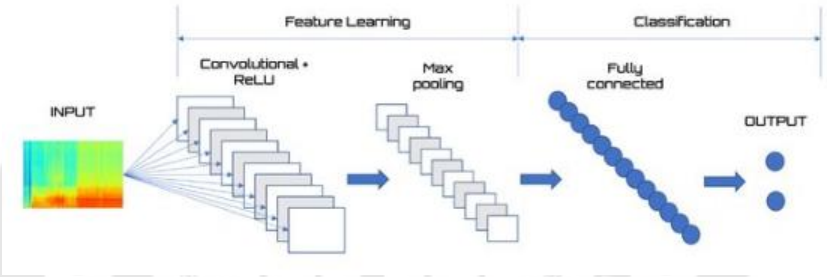

ภาพประกอบ 5 โครงข่ายประสาทเทียมแบบคอนโวลูชัน

ที่มา : (Ciaburro, 2020)

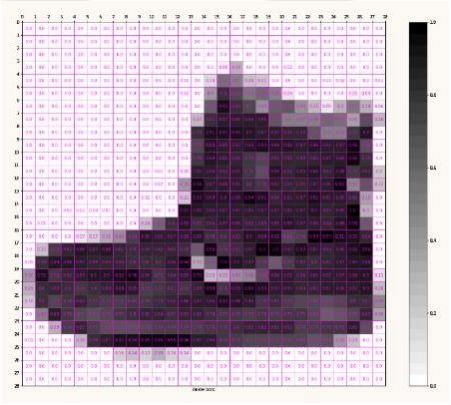

ภาพประกอบ 6 การรับรู้ข้อมูลรูปภาพของ โครงข่ายประสาทเทียมแบบคอนโวลูชัน

ที่มา : (West, 2023a)

โครงข่ายประสาทเทียมแบบคอนโวลูชัน ถูกออกแบบเพื่อเพิ่มความสามารถในการสกัดคุณลักษณะพิเศษ (Feature) จากข้อมูล ประกอบด้วย ส่วนสกัดคุณลักษณะพิเศษ (Feature Extraction) และส่วนจำแนกประเภท (Classification)

ส่วนสกัดคุณลักษณะพิเศษ (Feature Extraction) จะประกอบไปด้วย ชั้นคอนโวลูชัน (Convolution Layer) และ ชั้นพูลลิ่ง (Pooling Layer)

ส่วนจำแนกประเภท (Classification) จะประกอบด้วย ชั้นเชื่อมโยงแบบสมบูรณ์ (Fully – Connected Layer)

2.2 งานวิจัยที่เกี่ยวข้อง

การทบทวนวรรณกรรมของงานวิจัยนี้ได้ทำการศึกษาค้นคว้างานวิจัยที่เกี่ยวข้อง โดยมีรายละเอียดดังนี้

2.1 บทความวิจัย “Pork and Beef Features Extractions” (Chairunnisa **และคนอื่น ๆ**, 2018)

ในบทความนี้พิจารณาว่า สีและพื้นผิวของเนื้อสัตว์ เป็นลักษณะเฉพาะของเนื้อทุกประเภท จึงใช้การพิจารณาเนื้อสัตว์จากรูปภาพโดยการสกัดพื้นผิวตามฮิสโตแกรมและการสกัดคุณสมบัติสี (HIS) ผลของการสกัดคุณลักษณะเพื่อนำไปประมวลผลโดยใช้วิธีโครงข่ายประสาทเทียม(ANN), ซัปพอร์ตเวกเตอร์แมชชีน (SUPPORT VECTOR MACHINE : SVM) และ วิธีการคำนวณเพื่อนบ้านใกล้ที่สุด k ตำแหน่ง (k-Nearest Neighbors: KNN) เพื่อจัดกลุ่มเป็นเนื้อสัตว์ 2 ประเภทคือเนื้อวัวและเนื้อหมู พิจารณาความสำเร็จของการจำแนกนี้โดยใช้เมทริกซ์ความสับสนและความแม่นยำสูงสุด โดยชุดข้อมูลที่ใช้คือภาพ RGB ของเนื้อวัว 40 ภาพ และ เนื้อหมู 40 ภาพ 4032 x 4032 พิกเซล เปลี่ยนขนาดภาพเป็นภาพขนาด 400 x 400 พิกเซล จากนั้นสร้างภาพ HSI จากการแยกคุณสมบัติสีบนภาพ RGB ออกเป็นภาพ HSI เพื่อให้มี 12 คุณสมบัติสีของแต่ละภาพและแยกพื้นผิวฮิสโตแกรม สร้าง 6 คุณสมบัติพื้นผิวของภาพเนื้อวัวและหมู จากนั้น นำข้อมูลสอนเข้าสู่แบบจำลองที่ใช้ทดสอบ ซึ่งมี 3 วิธี คือ โครงข่ายประสาทเทียม(ANN), ซัปพอร์ตเวกเตอร์แมชชีน (SUPPORT VECTOR MACHINE : SVM) และ วิธีการคำนวณเพื่อนบ้านใกล้ที่สุด k ตำแหน่ง (k-Nearest Neighbors: KNN) ซึ่งวิธีที่ดีที่สุดให้ความแม่นยำ 93.75% โดยใช้ k-fold 20 ด้วยวิธีโครงข่ายประสาทเทียม

2.2 **บทความวิจัย** “Mobile Application to Differentiate Flesh Meat between Beef and Pork” (Muhammadiy **และ** Fahmi, 2016)

งานวิจัยนี้ใช้การประมวลผลภาพดิจิทัลในการวิเคราะห์พื้นผิวร่วมกับโครงข่ายประสาทเทียมเพื่อการตัดสินใจ โดยวิธีการนี้จะถูกนำไปใช้กับโทรศัพท์สมาร์ทโฟนเป็นการทำงานแบบเวลาจริง ความแม่นยำในการจำแนกเนื้อวัว เนื้อหมูอยู่ที่ 89% โดยภาพที่ถ่าย ถ่ายจากกล้องสมาร์ทโฟน มีขนาด 8 เมกะพิกเซล ทำการปรับขนาดภาพ ปรับสีเป็นภาพระดับสีเทา ใช้โครงข่ายประสาทเทียม(ANN) ในการสอน โดยซอฟต์แวร์ชื่อ ”Neuroph Studio” ซึ่งสร้างเครือข่ายที่มีนามสกุล.nnet และไฟล์นี้จะถูกฝังบนซอฟต์แวร์แอนดรอย ชุดข้อมูลที่ใช้คือภาพเนื้อวัวและเนื้อหมู รวม 50 ภาพ แบ่งเป็นชุดข้อมูลสอน 20ภาพ เป็นภาพเนื้อวัว และเนื้อหมูอย่างละ 10 ภาพ และชุดข้อมูลทดสอบ 30ภาพ เป็นภาพเนื้อวัว และเนื้อหมูอย่างละ 15 ภาพ มีการเปรียบเทียบประสิทธิภาพจากจำนวนชั้นซ่อน(Hidden Layer) โดยประสิทธิภาพสูงสุดมาจากแบบจำลองที่มีจำนวนชั้นซ่อน(Hidden Layer) 6ชั้น มีความแม่นยำที่ 89%สำหรับเนื้อวัว และ 89.674% สำหรับเนื้อหมู

2.3 **บทความวิจัย** “Image Classification Modelling of Beef and Pork Using Convolutional Neural Network” (Salsabila **และ** Sartono, 2021)

งานวิจัยนี้มีวัตถุประสงค์เพื่อการจำแนกภาพที่ดีที่สุดของภาพเนื้อวัวและเนื้อหมู โดยสร้างแบบจำลอง โครงข่ายประสาทเทียมแบบคอนโวลูชัน พื้นฐาน และเปรียบเทียบวิธีการทำให้เป็นมาตรฐานหลายวิธี เพื่อเอาชนะอาการโอเวอร์ฟิตติ้ง(Overfitting) ชุดข้อมูลที่ใช้คือรูปภาพเนื้อวัว และเนื้อหมู รวม 3,000 ภาพ แบ่งเป็น ข้อมูลสอน 2,550 ภาพ และ ข้อมูลทดสอบ 450 ภาพ วิธีการเป็นการนำรูปภาพเนื้อหมู ขนาด 1536x2048 พิกเซล และรูปภาพ เนื้อวัว ขนาด 3024x4032 พิกเซล เปลี่ยนขนาดภาพเป็นภาพขนาด 128x128 พิกเซล จากนั้นแปลงเป็นภาพขาวดำ และนำข้อมูลเข้าแบบจำลอง โครงข่ายประสาทเทียมแบบคอนโวลูชัน ซึ่งจะมีการเปรียบเทียบค่าต่างในการใช้ เทคนิค ดรอปเอาท์ (Dropout), L2 และ Max-Norm เพื่อหาวิธีที่เหมาะสมที่สุด ซึ่งผลการวิจัยของบทความนี้ คือความแม่นยำสูงสุด 97.56% จากแบบจำลอง โครงข่ายประสาทเทียมแบบคอนโวลูชัน ที่ใช้เทคนิคดรอปเอาท์ (Dropout) p=0.7

2.4 **บทความวิจัย** “Identifying Pork Raw-Meat Based on Color and Texture Extraction Using Support Vector Machine” (Aisah, Setyaningrum, Wardhani, **และ** Bahaweres, 2020)

งานวิจัยมีวัตถุประสงค์เพื่อพิจารณาประสิทธิภาพของ ซัปพอร์ตเวกเตอร์แมชชีน (SUPPORT VECTOR MACHINE : SVM) ในการระบุความแตกต่างระหว่างเนื้อวัวกับเนื้อหมูตามสีและลักษณะเนื้อสัมผัสด้วยการจำลองในโปรแกรม Matlab 2015A การแยกคุณสมบัติสีใช้การแปลง RGB เป็น HSV ซึ่งส่งผลให้เกิดสีสัน ความอิ่มตัว และค่าการแยกคุณลักษณะพื้นผิวโดยใช้การแปลง Local Binary Pattern (LBP) ผลลัพธ์ของ LBP นี้จะได้รับการประมวลผลโดยการดึงคุณลักษณะทางสถิติอันดับที่หนึ่ง ส่งผลให้เกิดค่าเฉลี่ย เอนโทรปี ความแปรปรวน ความโด่ง และความเบ้ และจาก8 พารามิเตอร์ของการแยกสีและพื้นผิวจะถูกนำเป็นข้อมูลเข้าสำหรับการจัดหมวดหมู่โดยใช้ ซัปพอร์ตเวกเตอร์แมชชีน (SUPPORT VECTOR MACHINE : SVM) ความแม่นยำสูงสุดที่ได้จากการวิจัยครั้งนี้คือ 90% โดยใช้ภาพข้อมูลเนื้อวัว เนื้อหมู และหมูป่าทั้งหมด 30 ภาพ ใช้กล้องจากโทรศัพท์สมาร์ทโฟนถ่ายรูปเนื้อสัตว์ ความละเอียด 8เมกะพิกเซล ปรับขนาดภาพเป็น 150 x 150 พิกเซล และเป็น 100 x 100 พิกเซล จากนั้นทำภาพเป็น ภาพHSV และภาพ LBP เพื่อใช้ในการแยกคุณลักษณะของคุณสมบัติการแยกสีและคุณสมบัติพื้นผิว การเปรียบเทียบประสิทธิภาพสำหรับงานวิจัยนี้มีการทดสอบภาพข้อมูลเข้า 4 แบบ คือ ภาพขนาด เป็น 150 x 150 พิกเซล ทำการแยกคุณสมบัติการแยกสีและคุณสมบัติพื้นผิว, ภาพขนาด เป็น 100 x 100 พิกเซล ทำการแยกคุณสมบัติการแยกสีและคุณสมบัติพื้นผิว, ภาพขนาด เป็น 150 x 150 พิกเซล ทำการแยกคุณสมบัติการแยกสี และภาพขนาด เป็น 150 x 150 พิกเซลทำการแยกคุณสมบัติพื้นผิว โดยผลลัพธ์ที่ได้นั้น หากเป็นภาพที่มีการสกัดคุณลักษณะทั้งจากคุณสมบัติการแยกสีและคุณสมบัติพื้นผิว เข้าแบบจำลองซัปพอร์ตเวกเตอร์แมชชีน (SUPPORT VECTOR MACHINE : SVM) จะได้ผลลัพธ์ที่ดีกว่าซึ่งอยู่ที่ 90%

2.5 บทความวิจัย “ The Identification of Red-Meat Types using The Fine-Tuned Vision Transformer and MobileNet Models” (Alhawas และ Tüfekci, 2022)

จุดประสงค์เพื่อใช้เทคนิคปัญญาประดิษฐ์ซับซ้อนล่าสุดช่วยในการจำแนกเนื้อสัตว์3 ประเภท จาก3,000 ภาพ โดยเปรียบเทียบประสิทธิภาพของแบบจำลอง Vision Transformer ViT และ แบบจำลอง Mobile Net ในการจำแนกภาพ บนชุดข้อมูลขนาดเล็ก โดยเป็นภาพสีRGB ของเนื้อม้า เนื้อวัว และเนื้อหมู จำนวนทั้งหมด 365 ภาพ แบ่งเป็น ข้อมูลสอน 335 ภาพ และข้อมูลทดสอบ 30 ภาพ ทำการเปรียบเทียบแบบจำลอง Vision Transformer ViTและ แบบจำลอง MobileNet ด้วยการปรับแบบจำลอง และไม่ปรับแบบจำลอง ผลการวิจัยคือ ทั้งแบบจำลอง Vision Transformer ViTและ แบบจำลอง MobileNet ที่ไม่มีการปรับแบบจำลอง มีการโอเวอร์ฟิตติ้ง

(Overfitting) และไม่ดีในการใช้งานกับข้อมูลทดสอบ เพราะจำนวนข้อมูลมีจำกัด สำหรับแบบจำลองที่มีการปรับจูนนั้น แบบจำลอง Vision Transformer ViT มีประสิทธิภาพดีกว่า คือ ความแม่นยำ 97% แต่ใช้เวลานานกว่า เนื่องจากมีจำนวนพารามิเตอร์ในการสอนมากกว่า

2.6 บทความวิจัย "Deep Learning Approach for Sign Language Recognition Using DenseNet201 with Transfer Learning" (Altaf, Wahid, **และ** Kirmani, 2023)

งานวิจัยนี้เสนอแบบจำลองการเรียนรู้แบบการถ่ายโอน ซึ่งใช้สถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน ชื่อ DenseNet201 สำหรับการรู้จำท่าทางภาษามืออินเดีย (ISL) ใช้การเรียนรู้การถ่ายโอนกับ DenseNet201 โดยแช่แข็งบางชั้นเพื่อรักษาความรู้และปรับแต่งชั้นที่เหลือสำหรับชุดข้อมูลภาษามืออินเดีย ซึ่งDenseNet201 ที่ถูกสอนแล้ว จะใช้แยกคุณลักษณะของภาพ เพื่อจัดประเภทรูปแบบการสัมผัสภาษามืออินเดีย(ISL)

ที่สร้างเองจะถูกเพิ่มเข้าไปในแบบจำลอง DenseNet201 ที่ถูกสอนแล้ว แบบจำลองที่นำเสนอช่วยให้ได้รับความแม่นยำสูงขึ้นถึง 100% การทดลองนี้ใช้ชุดข้อมูลภาพท่าทางมือภาษามืออินเดีย ที่มีอยู่ใน Kaggle ประกอบด้วยภาพ RGB 42,000 ภาพ ของสัญญาณมือ 35 รายการ รวมทั้งตัวเลข 9 ตัว และตัวอักษรภาษาอังกฤษ 26 ตัว แต่ละภาพมีขนาด 128×128×3 และปรับขนาดภาพให้มีความละเอียดสูงขึ้นเป็น 224×224×3 เพื่อเพิ่มประสิทธิภาพให้กับแบบจำลอง ในการตรวจสอบแบบจำลอง แบ่งชุดข้อมูลออกเป็นสามชุด การสอนอบรม การตรวจสอบ และการทดสอบในอัตราส่วน 80:15:05 (3,360 ภาพใช้สำหรับการสอน 6,300 สำหรับการตรวจสอบ และ 2,100 สำหรับการทดสอบ) เทคนิคการเสริมข้อมูลได้นำไปใช้กับชุดการสอน รวมถึงระยะเฉือน 0.2 ซูมสูงสุด 0.2 หมุนสูงสุด 20° และการเติมแนวนอน ภาพทั้งหมดถูกทำให้เป็นมาตรฐานเพื่อปรับขนาดค่าพิกเซลใหม่จากช่วง 0–255 เป็นช่วง 0–1 และสำหรับการแยกคุณสมบัติใช้วิธีแปลงเป็นอาร์เรย์ตัวเลข

2.7 **บทความวิจัย** "Multi-Class Classification of Intracranial Hemorrhages in a 3-Channel CT image by using a Transfer Learning based DenseNet121 model" (Kothala **และ** Guntur, 2022)

งานวิจัยนี้เป็นการประเมินแบบจำลอง DenseNet121 โดยใช้แนวคิดการเรียนรู้การถ่ายโอน โดยชุดข้อมูลประกอบด้วยภาพ 26,383 ภาพ ผลการปฏิบัติงานของข้อมูลการตรวจสอบมีความถูกต้อง (accuracy) 94.8% ความแม่นยำ(precision) 94.9% การเรียกคืน(recall) 81.4% คะแนน F1 87.2% และ ROC ภายใต้ AUC 99.1% ตามลำดับ ผลลัพธ์ทำให้มั่นใจได้ว่า

แบบจำลองที่นำเสนอมีความแม่นยำสูงกว่าเมื่อเทียบกับแบบจำลองอื่นๆ ชุดข้อมูลถูกดาวน์โหลดจากเว็บไซต์แคกเกิล (Kaggle) ชุดข้อมูลแบ่งออกเป็น 80:20 สำหรับการสอนและการทดสอบ ภาพเป็นไฟล์ PNG ผลลัพธ์ ซึ่งรวมภาพคนเข้ารับการอบรม 20,410 คน และ 5,973 คน สำหรับการตรวจสอบแสดงว่าแบบจำลองปรับปรุง ประสิทธิภาพของงานจำแนกประเภทหลายชั้น ภาพสามประเภทที่แตกต่างกันถูกรวมเข้าด้วยกัน เป็นภาพ 3 ช่อง และนำเข้าแบบจำลองจากนั้น ใช้เทคนิคการเสริมข้อมูล เช่น การปรับขนาด การหมุน และพลิกระหว่างขั้นตอนก่อนการประมวลผล เพื่อขยายขนาดของชุดข้อมูลและปรับปรุงความถูกต้องของแบบจำลอง

2.8 **บทความวิจัย** “Optimized MobileNetV2 Based on Model Pruning for Image Classification ” (Xiao, Pang, Feng, **และ** Hao, 2022)

บทความนี้เสนอสถาปัตยกรรมมือถือแบบใหม่ที่รวม MobileNetV2 และการตัดแต่งกิ่ง ซึ่งลดความล้มเหลวและลดจำนวนพารามิเตอร์ ประสิทธิภาพของMobileNetV2 ถูกพิสูจน์ในวงกว้าง และการดำเนินการตัดแต่งกิ่งทำให้สามารถจัดแบบจำลองเพิ่มเติม และป้องกันการโอเวอร์ฟิตติ้ง(Over fitting) งานวิจัยนี้ทำการทดลองกับข้อมูลยางของศูนย์ประมวลภาพและสารสนเทศ (CIIP) ประเทศจีน เป็นภาพยาง11,040 ภาพ แบ่งเป็น 69 กลุ่ม กับการตัดแต่งกิ่งแบบต่างๆ นอกจากนี้งานวิจัยได้เปิดตัวไฮเปอร์พารามิเตอร์ทั่วไปเพื่อถ่วงน้ำหนักอย่างมีประสิทธิภาพสำหรับความแม่นยำและความถูกต้อง การทดลองแสดงให้เห็นว่าความแม่นยำ 98.3% สำหรับแบบจำลองขนด 804.5 KB เท่านั้น ซึ่งแสดงประสิทธิภาพที่ดีกว่าวิธีพื้นฐาน

2.9 **บทความวิจัย** “Lightweight CNN-based Models for Masked Face Recognition” (Alawi **และ** Qasem, 2021; Xiao **และคนอื่น ๆ**, 2022)

บทความนี้เสนอแบบจำลองนี้ตรวจจับใบหน้าที่ถูกใส่หน้ากากอัตโนมัติโดยเทคนิคการเรียนรู้เชิงลึก เท็นโซโฟว์ (TensorFlow) และเคราส(Keras) วิธีนี้แยกใบหน้าที่ใส่หน้ากากและใบหน้าที่ไม่ใส่หน้ากากได้อย่างมีประสิทธิภาพ การนำแบบจำลองไปใช้จริงขึ้นกับ 3 แบบจำลองที่ผ่านการสอน คือ MobileNetV2, DenseNet และ NASNetMobile ในด้านความแม่นยำ MobilenetV2 มีค่า 0.9859, DenseNets และ NASNetMobile มีค่า 0.9852 และ 0.9758 ตามลำดับ งานวิจัยแสดงความเป็นไปได้ของการใช้แบบจำลองที่เบา (เช่น NasNetMobile) ซึ่งนำไปใช้ได้แม้ในอุปกรณ์ที่มีทรัพยากรต่ำเพื่อจดจำใบหน้าที่สวมหน้ากากได้อย่างมีประสิทธิภาพ

2.10 **บทความวิจัย** “Deep Convolutional Neural Network for Microscopic Bacteria Image Classification”(Wahid, Hasan, **และ** Alom, 2019)

งานวิจัยนี้เสนอระบบอัตโนมัติเพื่อจำแนกแบคทีเรียในเวลาเดียวกันจากภาพจุลทรรศน์ ใช้โครงข่ายประสาทเทียมแบบลึก ชื่อ สถาปัตยกรรม Xception มีพื้นฐานจากการเรียนรู้แบบถ่ายโอน เลือกแบคทีเรีย 7 สายพันธุ์สำหรับการจดจำและเตรียมชุดข้อมูลภาพแบคทีเรีย 1,150 ภาพ แต่ละพันธุ์มีภาพอย่างน้อย 160 ภาพ ชุดข้อมูลสอน 920 ภาพ 7 สายพันธุ์ ชุดข้อมูลทดสอบ 230 ภาพ 7 สายพันธุ์ ได้ความแม่นยำในการทำนายประมาณ 97.5%

2.11 **บทความวิจัย** “Fake Beef Detection with Machine Learning Technique” (Chanasupaprakit **และคนอื่น ๆ**, 2022)

งานวิจัยนี้เพื่อพัฒนาการตรวจสอบเนื้อสัตว์ หลังจากเตรียมรูปภาพที่เกี่ยวข้องล่วงหน้า ด้วยการลบภาพพื้นหลังออก และแปลงภาพเป็นภาพไบนารี่ จากนั้นสอนแบบจำลองด้วยซัปพอร์ตเวกเตอร์แมชชีน (SUPPORT VECTOR MACHINE : SVM) และโครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยใช้การประเมินแบบจำลองด้วยคะแนน F1 และความแม่นยำ ใช้ข้อมูลการทดสอบ 20% ผลลัพธ์ของแบบจำลองที่ใช้ทดสอบ 5 แบบจำลอง จะเห็นว่า VGG16 มีความถูกต้อง(Accuracy) สูงสุดที่ 95.20% จากภาพ 1,200 ภาพ ด้วย คะแนน F1, ความแม่นยำ สำหรับเนื้อหมู 98.00% และ 98.00% และสำหรับเนื้อวัว 98.00% และ 98.00%

2.12 **บทความวิจัย** “Comparison of image enhancement techniques and CNN models for COVID-19 classification using chest x-rays images”(Kanjanasurat, Domepananakorn, Archevapanich, **และ** Purahong, 2022)

งานวิจัยนี้เปรียบเทียบ เทคนิคการปรับปรุงภาพ 2 แบบ ด้วย 5 แบบจำลองโครงข่ายประสาทเทียมเพื่อจำแนกภาพเอกซเรย์ทรวงอกของ Covid-19 เทคนิคการปรับปรุงภาพ แบ่งเป็นฮิสโทแกรมแบบปรับได้ซึ่งถูกจำกัดความต่าง(CLAHE) และการแก้ไขแกมมา ซึ่งการปรับปรุงภาพจะถูกเปรียบเทียบกับภาพเอ็กซเรย์ทรวงอกเดิม ใช้แบบจำลอง โครงข่ายประสาทเทียมแบบคอนโวลูชัน ที่ถูกสอนแล้ว 5 แบบจำลอง : MobileNet, MobileNetV2, DenseNet169, DenseNet201 และ ResNet50V2 งานวิจัยนี้ใช้ฐานข้อมูลถ่ายภาพรังสี COVID-19 ซึ่งเข้าถึงได้ไม่เสียค่าใช้จ่าย ผลที่ได้นั้น MoblileNet ที่มีการแก้ไขแกมมาเหมาะสมสำหรับการจำแนกประเภท COVID-19 มีความถูกต้อง(Accuracy)แม่นยำ 87.53% ในรอบการคำนวณแรก และ 95.46% หลังจากการสอน 100 รอบด้วยเวลาการคำนวณที่สั้นที่สุด

2.13 บทความวิจัย “Exploring and Classifying Beef Retail Cuts Using Transfer Learning”(Abuzaid **และ** Atia, 2022)

งานวิจัยนี้เพื่อจำแนกประเภทของเนื้อวัวในการขายปลีกในแต่ละส่วน คือ ตับ, เนื้อย่าง, เนื้อสันใน, เนื้อกลม, เนื้อลายสิงโต, เนื้อกลม ,เนื้อปีก โดยใช้ชุดข้อมูลประเภทเนื้อวัวและสร้างอัลกอริทึมเพื่อจำแนกประเภท ซึ่งชุดข้อมูลประเภทเนื้อวัว 7 แบบซึ่งเปิดเผยต่อสาธารณะประกอบด้วยภาพสีของผู้วิจัย 1,638 ภาพ ทดลองกับแบบจำลองโครงข่ายประสาทเทียมการเรียนรู้เชิงลึก 5 แบบเพื่อให้ได้ความแม่นยำสูงสุดสำหรับการจำแนกชุดข้อมูล ประกอบด้วยแบบจำลอง MobileNet, ResNet50, InceptionV3, EfficientNetB0 และแบบจำลองที่สร้างเอง ซึ่ง แบบจำลองที่ถูกสอนแล้ว EffecientNetB0 มีความถูกต้อง (Accuracy) สูงสุดคือ 99.81% หลังการเพิ่มข้อมูล (Data Augmentation)

2.14 บทความวิจัย “Using SHAP Analysis to Detect Areas Contributing to Diabetic Retinopathy Detection”(Shakeri, Crump, Weis, Souza, **และ** Far, 2022)

งานวิจัยนี้ใช้วิธีการวิเคราะห์แชฟ(SHAP) เพื่อตรวจหาพื้นที่ของภาพในดวงตาเพื่อทำนายเบาหวาน โดยใช้การเรียนรู้แบบถ่ายโอน แบบจำลองมีความแม่นยำ 97% และ 81% สำหรับการจำแนกประเภทไบนารีและหลายคลาสของเบาหวาน ผลการวิเคราะห์ แชฟ (SHAP)แสดงให้เห็นว่า หากไม่คำนึงถึงประสิทธิภาพของแบบจำลอง วิธีนี้เป็นเครื่องมือในการตีความผลการทำนายที่ไว และทำให้เข้าใจเหตุผลของผลการจำแนกประเภทมากขึ้น แชฟ(SHAP) เป็นวิธีที่ใช้วัดการมีส่วนร่วมของผู้เล่นในเกมที่ร่วมมือกัน จะคำนวณความสำคัญของคุณลักษณะสำหรับภาพชองชุดข้อมูลแต่ละชุด และกำหนดคุณลักษณะแต่ละค่าด้วยค่าความสำคัญ งานวิจัยนี้ทำตำแหน่งของภาพที่แสดงการมีอยู่ของเบาหวาน หรือระยะความรุนแรงของโรค

2.15 บทความวิจัย “Deep Spectral-spatial Features of Snapshot Hyperspectral Images for Red-meat Classification”(Al-Sarayreh, Reis, Yan, **และ** Klette, 2018)

งานวิจัยนี้เป็นการตรวจสอบศักยภาพและความถูกต้องของการถ่ายภาพไฮเปอร์สเปกตรัม สแน็ปช็อต สำหรับรับรองความถูกต้องและการจำแนกเนื้อแดง ภาพมาจากตัวอย่างเนื้อแกะ เนื้อวัว และเนื้อหมู งานวิจัยพิจารณากล้ามเนื้อ 13 ประเภทของเนื้อซี่โครงและขา นำเสนอสถาปัตยกรรมโครงข่ายประสาทเทียม 3 มิติเชิงลึก สำหรับจำแนกคุณลักษณะด้านสเปกตรัมของเนื้อแดง เปรียบเทียบกับแบบจำลองที่ทันสมัย ที่มีการวิเคราะห์การจำแนกกำลังสองน้อยที่สุดบางส่วน กับวิธีซัปฟอร์ตเวคเตอร์แมชชีน ผลลัพธ์แสดงว่าโครงข่ายประสาทเทียม 3 มิติเชิงลึก มี

ประสิทธิภาพดีกว่าแบบจำลองที่ทันสมัย จากความถูกต้องรวมและคะแนน F1 เฉลี่ย ที่ 95.81% และ 96.01% ตามลำดับ ผลการวิจัยแสดงว่าแบบจำลอง โครงข่ายประสาทเทียม 3 มิติ สามารถแปลงภาพไฮเปอร์สเปกตรัมสแน็ปช็อตให้เป็นข้อมูลอัจฉริยะด้วยการแยกประเภทของเนื้อแดงได้ถูกต้อง เป็นการวิจัยระบบการถ่ายภาพไฮเปอร์สเปกตรัมแบบเรียลไทม์และแบบพกพา จากความสามารถของกล้องไฮเปอร์สเปกตรัมสแน็ปช็อตในการทำงานด้านวิดีโอ

ในบทนี้เป็นการกล่าวถึงงานวิจัยที่เกี่ยวข้องกับการจำแนกเนื้อวัวและเนื้อหมู และการทำงานทางด้านการเรียนรู้ด้วยเครื่องจากภาพถ่าย สำหรับวิธีดำเนินการวิจัย จะกล่าวถึงในบทที่ 3 ต่อไป

บทที่ 3
วิธีดำเนินการวิจัย

ในการวิจัยครั้งนี้ ผู้วิจัยได้ดำเนินการตามขั้นตอนดังนี้

3.1 กระบวนการวิจัย

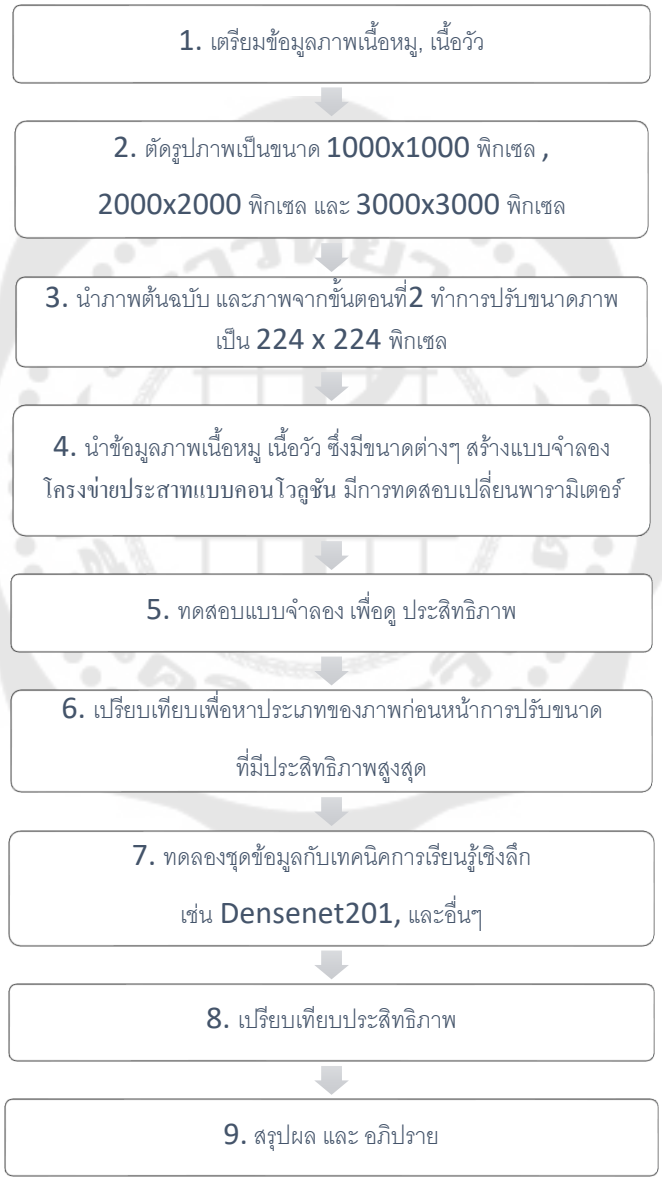

ภาพประกอบ 7 กระบวนการวิจัย

กระบวนการวิจัยประกอบไปด้วยการเตรียมข้อมูลภาพที่เข้ามา ปรับขนาดภาพ และสร้างภาพระดับสีเทา ซึ่งอธิบายในหัวข้อ 3.3 จากนั้นทำการเปรียบเทียบประสิทธิภาพ เพื่อหาชุดข้อมูลที่ทำให้ระบบมีประสิทธิภาพสูงสุด นำข้อมูลชุดนี้ทดสอบกับแบบจำลอง โครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยการปรับไฮเปอร์พารามิเตอร์ และทดสอบข้อมูลชุดข้อมูลกับโครงข่ายประสาทเทียมแบบคอนโวลูชันเทคนิคอื่น ทำการเปรียบเทียบประสิทธิภาพ และสรุปผลการวิจัย สาเหตุที่ออกแบบการวิจัยลักษณะนี้ เนื่องจากต้องการทราบว่าภาพลักษณะใด และขนาดของภาพเท่าไรจะเป็นชุดข้อมูลภาพที่ทำให้แบบจำลองมีประสิทธิภาพสูงสุดหากใช้แบบจำลองเหมือนกัน และหากเราทดลองโดยใช้เทคนิคการเรียนรู้เชิงลึกแบบอื่นๆ ต้องมีการทำขนาดภาพตามข้อกำหนดของแต่ละแบบจำลอง ต่อไป

3.2 **การสำรวจข้อมูล** (Exploratory Data Analysis: EDA)

ตาราง 1 ชุดข้อมูลที่นำมาใช้ในงานวิจัย

ชุดข้อมูล	จำนวนภาพที่ใช้สอน	จำนวนภาพที่ใช้ทดสอบ
เนื้อวัว	3,219	300
เนื้อหมู	3,219	300

3.3 **การเตรียมข้อมูล** (Data Preprocessing)

ชุดข้อมูลที่ใช้ในการวิจัยนี้เก็บข้อมูลจากมาจากการถ่ายภาพเนื้อวัว และเนื้อหมูสไลด์ ซึ่งจะได้ภาพ ขนาด 3000x4000 พิกเซล และ 4000X3000 พิกเซล คละกันโดยเป็นภาพเนื้อวัว และเนื้อหมู ชนิดละ 3,519 ภาพ เรียกภาพชุดนี้ว่าภาพต้นแบบ จากนั้นนำภาพชุดต้นแบบทำการตัดขอบให้ได้ภาพขนาด 1000x1000 พิกเซล, 2000x2000 พิกเซล และ 3000x3000 พิกเซล ต่อมาภาพที่ได้ทั้ง 4 ชุดทำการปรับขนาดภาพเป็นภาพขนาด 224 x 224 พิกเซล และเมื่อนำภาพทั้ง4 ประเภท ทำการสอนในแบบจำลองพื้นฐานและเปรียบเทียบประสิทธิภาพที่เกิดขึ้นเพื่อหาว่าชุดข้อมูลใดมีความเหมาะสมในการนำไปใช้ทดสอบแบบจำลองโดยเทคนิคการเรียนรู้เชิงลึก

3.4 **การตัดส่วนของภาพ** (Image Cropping)

งานวิจัยนี้จะนำภาพต้นฉบับที่ถ่ายจากกล้องโทรศัพท์มือถือ ซึ่งมีขนาด 3000x4000 พิกเซล หรือ 4000x3000 พิกเซล มาทำการตัดสัดส่วนภาพ ดังภาพประกอบ 8

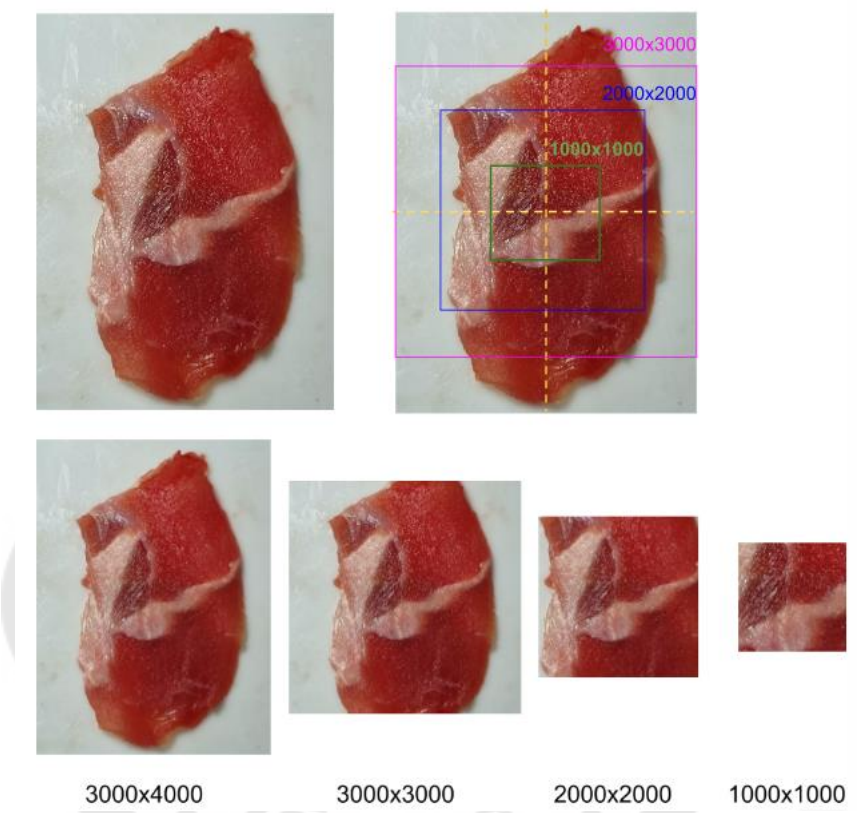

ภาพประกอบ 8 วิธีการตัดสัดส่วนภาพ

จุดประสงค์คือ ต้องการทราบว่าภาพชุดข้อมูลแบบใดเหมาะกับการใช้งาน โดยมีตัวเลือกคือ

1. ภาพต้นฉบับ ที่ถ่ายมาจากโทรศัพท์สมาร์ทโฟน โดยไม่ตัดส่วนภาพ
2. ภาพต้นฉบับแต่ทำเป็นรูปสี่เหลี่ยมจตุรัส ขนาด 3000x3000 พิกเซล ซึ่งจะมีขอบของภาพ และรายละเอียดของเนื้อสัตว์อยู่มาก
3. ภาพต้นฉบับแต่ทำเป็นรูปสี่เหลี่ยมจตุรัส ขนาด 2000x2000 พิกเซล ซึ่งจะมีขอบของภาพ และรายละเอียดของเนื้อสัตว์อยู่ไม่มากนัก หรือบางภาพจะไม่เห็นขอบของภาพ

4. ภาพต้นฉบับแต่ทำเป็นรูปสี่เหลี่ยมจตุรัส ขนาด 1000x1000 พิกเซล ซึ่งภาพส่วนใหญ่ไม่มีขอบของภาพ และองค์ประกอบโดยรวมของภาพ จะเห็นแต่ลักษณะผิว และสี

3.5 **การปรับขนาดภาพ** (Image Resizing)

เมื่อทำการตัดสัดส่วนภาพแล้ว ถัดมาจะเป็นการปรับขนาดภาพชุดข้อมูล เพื่อเตรียมนำชุดข้อมูลนี้เข้ายังแบบจำลอง

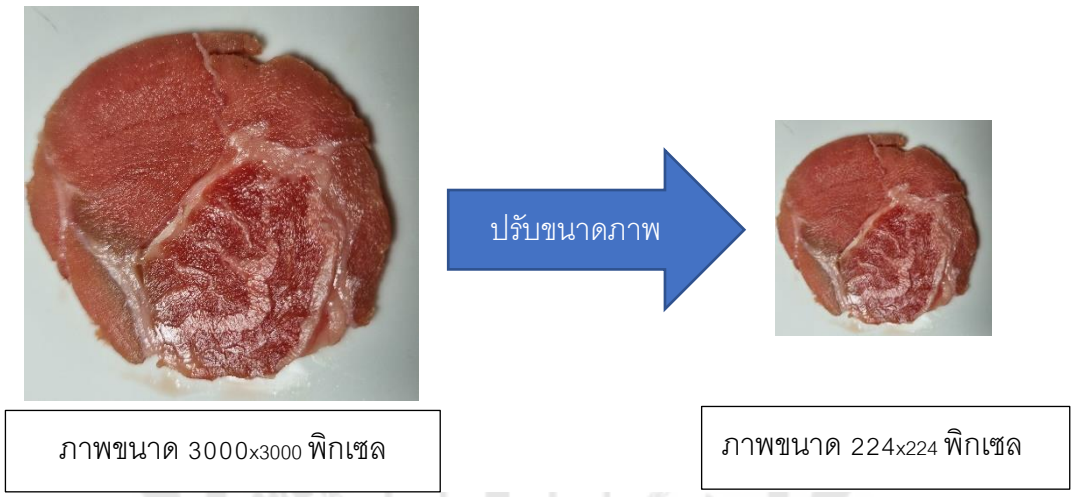

ภาพประกอบ 9 การปรับขนาดภาพ

สำหรับงานวิจัยนี้ใช้อัลกอริทึม NEAREST ในการปรับขนาดภาพ

โดยหลักการคือ ภาพผลลัพธ์เกิดจากการนำสีจากพิกเซลที่แบ่งตามสัดส่วนของภาพมาใช้

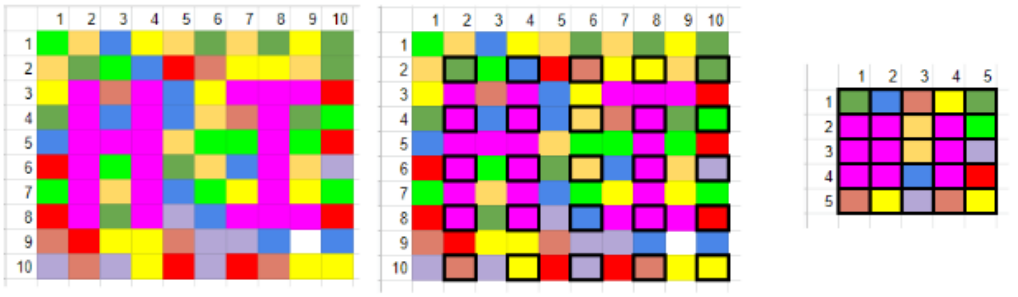

ภาพประกอบ 10 ตัวอย่างการปรับขนาดภาพโดยอัลกอลิทึม NEAREST

โดยตัวอย่างเป็นการปรับขนาดภาพจาก 10x10 พิกเซล เป็น 5x5 พิกเซล ซึ่งภาพผลลัพธ์จะเกิดจากสีที่อยู่ตำแหน่งที่เป็นสักส่วนกันกับภาพต้นฉบับ

3.6 **การสร้างแบบจำลอง** (Model Creation)

การสร้างแบบจำลองในงานวิจัยนี้เป็นการทำกระบวนการเพื่อจำแนกภาพเนื้อวัว และเนื้อหมู โดยใช้วิธี การจำแนกแบบไบนารี(Binary Classification)คือ ตัวแปรที่แบ่งเป็นสองหมวดหมู่ มีแบบจำลองพื้นฐานเพื่อใช้ในการเปรียบเทียบประสิทธิภาพที่เกิดจากการเปลี่ยนแปลงลักษณะของภาพ คือแบบจำลอง โครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยใช้พารามิเตอร์เหมือนกัน และแบบจำลองพื้นฐาน โครงข่ายประสาทเทียมแบบคอนโวลูชัน นี้จะถูกนำไปใช้เพื่อเปรียบเทียบประสิทธิภาพกับการเรียนรู้เชิงลึกแบบจำลองอื่นต่อไป

3.7 **การวัดประสิทธิภาพ และวิเคราะห์ผล**

งานวิจัยนี้ใช้เมทริกซ์ความสับสน(Confusion Matrix) และพื้นที่ใต้กราฟROC ในการวัดประสิทธิภาพและวิเคราะห์ผล

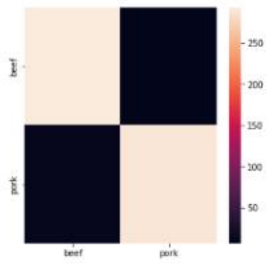

Confusion matrix

	precision	recall	f1-score	support
beef	0.96	0.98	0.97	300
pork	0.98	0.96	0.97	300
accuracy			0.97	600
macro avg	0.97	0.97	0.97	600
weighted avg	0.97	0.97	0.97	600

Classification report

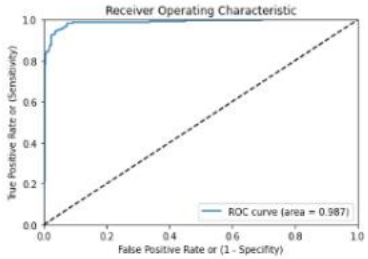

ROC curve

ภาพประกอบ 11 เครื่องมือวัดประสิทธิภาพ

เมทริกซ์ความสับสนคือตารางวัดประสิทธิภาพแบบจำลองจำแนกประเภท ที่มีขนาด C x C โดย C คือประเภทของผลลัพธ์ที่เราได้ เช่นหากเราสร้างแบบจำลองทำนายว่าเป็นเนื้อวัวหรือเนื้อหมู เมทริกซ์ความสับสน จะมีขนาด 2 x 2

เมทริกซ์ความสับสนจะแบ่งเป็น 2 ส่วน คือส่วนผลที่เกิดจริง และผลจากการทำนาย

		True Class: Positive	True Class: Negative
Predicted Class	Positive	TP	FP
	Negative	FN	TN

ภาพประกอบ 12 เมทริกซ์ความสับสน

True Positive (TP) : ทำนายว่าเป็น Positive ทำนายถูก ผลลัพธ์จริงเป็นPositive
คือ ทำนายว่าเป็นเนื้อหมู ทำนายถูก ที่จริงเป็นเนื้อหมู

True Negative(TN) : ทำนายว่าเป็น Negative ทำนายถูก ผลลัพธ์จริงเป็นNegative
คือ ทำนายว่าไม่ใช่เนื้อหมู ทำนายถูก ที่จริงไม่ใช่เนื้อหมู

False Positive (FP) : ทำนายว่าเป็น Positive ทำนายผิด ผลลัพธ์จริงเป็นNegative
คือ ทำนายว่าเป็นเนื้อหมู ทำนายผิด ที่จริงไม่ใช่เนื้อหมู
ทางสถิติเรียก ข้อผิดพลาดประเภทที่1 (Type 1 error)

False Negative(FN) : ทำนายว่าเป็น Negative ทำนายผิด ผลลัพธ์จริงเป็นPositive
คือ ทำนายว่าไม่ใช่เนื้อหมู ทำนายผิด ที่จริงเป็นเนื้อหมู
ทางสถิติเรียกข้อผิดพลาดประเภทที่2 (Type 2 error)

จำนวนข้อมูลที่ทายถูกคือนั่นคือ ข้อมูลที่อยู่ใน TP และ TN

ซึ่งเราสามารถนำเมทริกซ์ความสับสนมาวัดประสิทธิภาพแบบจำลองได้อีกด้วย
Accuracy คือ ความถูกต้องของการทำนายผลทั้งหมดของแบบจำลอง

$$Accuracy = \frac{TP + TN}{TP + FN + TN + FP} \quad (1)$$

Precision = ความถูกต้องของสิ่งที่แบบจำลองสนใจทำนาย

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

Recall = อัตราส่วนที่แบบจำลองสามารถทำนายประเด็นที่เราสนใจ

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

F1-Score = ค่าเฉลี่ยแบบฮาร์โมนิค (Harmonic) ของ ความถูกต้องของสิ่งที่แบบจำลองสนใจทำนาย และ อัตราส่วนที่แบบจำลองสามารถทำนายประเด็นที่เราสนใจ

$$F1 = \frac{2\ x\ Preciccion\ x\ Recall}{Preciccion + \ Recall} \quad (4)$$

พื้นที่ใต้กราฟROC (Receiver Operating Characteristic Curves)

ROC เป็นเครื่องมือในการประเมินแบบจำลองเป็นกราฟระหว่าง True Positive Rate(Sensitivity) และ False Positive Rate (1-Specificity) โดยมีค่าที่ใช้ด้วยกันคือพื้นที่ใต้กราฟ ROC(AUC : Area under the Curve) มีค่าระหว่าง 0 – 1 โดยหากพื้นที่ใต้กราฟROC มีค่ามาก แสดงว่าแบบจำลองมีความสามารถในการทำนายที่ดี

ในบทนี้แสดงถึงแนวคิดสำหรับกระบวนการวิจัย รวมทั้งลักษณะการประเมินผลสำหรับงานวิจัยนี้ สำหรับผลที่ได้รับจะกล่าวถึงในบทที่ 4

บทที่ 4
ผลการทดลอง

4.1 วิธีการทดลอง

ใช้ภาพจากต้นฉบับขนาด 3000x4000 พิกเซล และ 4000x3000 พิกเซล ทำการตัดขอบภาพ เป็นภาพขนาด 3000x3000 พิกเซล, 2000x2000 พิกเซล และ 1000x1000 พิกเซล ทำการปรับขนาดภาพในแต่ละแบบเป็นภาพขนาด 224x224 พิกเซล เพื่อให้สามารถใช้งานในการสร้างแบบจำลองในเทคนิคการเรียนรู้เชิงลึกได้

จากนั้นนำภาพขนาด 224x224 พิกเซล ที่เกิดจากการขนาดภาพ เข้าสู่แบบจำลอง เพื่อหาแบบจำลองที่เหมาะสมในการนำไปใช้งานที่สุด โดยทำการเปรียบเทียบ 2 ขั้นตอน

1. เปรียบเทียบประสิทธิภาพแบบจำลอง โครงข่ายประสาทเทียมแบบคอนโวลูชัน ที่เกิดจากการเปลี่ยนไฮเปอร์พารามิเตอร์

- รูปแบบภาพขนาด 224x224 พิกเซล ที่ทำการปรับขนาดมาจากภาพ ต้นฉบับ, 3000x3000 พิกเซล, 2000x2000 พิกเซล และ 1000x1000 พิกเซล ตามลำดับ
- อัตราการเรียนรู้ โดยแบ่งเป็น 1e-3, 1e-4 และ 1e-5 ตามลำดับ
- จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience) แบ่งเป็น 20, 30, 40 และ 50
- เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam และ RMSprop

2. เปรียบเทียบประสิทธิภาพแบบจำลอง โครงข่ายประสาทเทียมแบบคอนโวลูชัน และ แบบจำลองจากเทคนิคการเรียนรู้เชิงลึก

4.2 ขั้นตอนในการวิจัย

4.2.1 ทดสอบประสิทธิภาพของแบบจำลองซึ่งเครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam โดยมีข้อมูลรูปภาพขนาด 224x224 พิกเซล ที่ทำการปรับขนาดมาจากภาพ ต้นฉบับขนาด 3000x4000 พิกเซล, 3000x3000 พิกเซล, 2000x2000 พิกเซล และ 1000x1000 พิกเซล มีการทดลองอัตราการเรียนรู้ (Learning rate) ค่า 1e-3, 1e-4 และ 1e-5 ตามลำดับ และในแต่ละค่าอัตราการเรียนรู้ (Learning rate) มีการปรับ จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)แบ่งเป็น 20, 30, 40 และ 50

4.2.2 พิจารณาภาพที่ถูกปรับขนาดมาว่าภาพรูปแบบใด มีประสิทธิภาพสูงสุด ซึ่งงานวิจัยนี้คือภาพที่ถูกปรับขนาดจากภาพขนาด 3000x3000 พิกเซล

4.2.3 ทดสอบประสิทธิภาพของแบบจำลอง โดยการใช้ภาพที่ถูกปรับขนาดภาพมาจากภาพขนาด 3000x3000 พิกเซล โดยใช้เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop มีการทดลองอัตราการเรียนรู้ (Learning rate) ค่า 1e-3, 1e-4 และ 1e-5 ตามลำดับ และในแต่ละค่าอัตราการเรียนรู้ (Learning rate) มีการปรับ จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)แบ่งเป็น 20, 30, 40 และ 50

4.2.4 เปรียบเทียบประสิทธิภาพของแบบจำลองโดยใช้เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop โดยมีข้อมูลรูปภาพขนาด 224x224 พิกเซล ที่ทำการปรับขนาดมาจากภาพ ต้นฉบับขนาด 3000x3000 พิกเซล, 2000x2000 พิกเซล และ 1000x1000 พิกเซล มีการทดลองอัตราการเรียนรู้ (Learning rate) ค่า 1e-3, 1e-4 และ 1e-5 ตามลำดับ โดยผู้วิจัยพิจารณาใช้จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience) ซึ่งเหมาะสมกับการทำงานของกระบวนการ โดยใช้ประสิทธิภาพที่ดีและไม่ใช้เวลานานเกินไปอยู่ที่ค่า 20 และ 40 รอบ

4.2.5 เลือกพารามิเตอร์ที่ทำให้แบบจำลองมีประสิทธิภาพดี ทดสอบประสิทธิภาพของแบบจำลองโดยใช้เทคนิคการเรียนรู้เชิงลึก ซึ่งในงานวิจัยนี้เลือก

- เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ (Learning rate) ค่า 1e-3,จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience) ค่า 20
- เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ (Learning rate) ค่า 1e-4,จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience) ค่า 20
- เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ (Learning rate) ค่า 1e-4,จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience) ค่า 40
- เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ (Learning rate) ค่า 1e-5,จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience) ค่า 20

4.2.6 ทดสอบประสิทธิภาพของแบบจำลองโดยใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้พารามิเตอร์ดังข้อ 5 และชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล ทำการทดสอบระบบซึ่งใช้

เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) ดังนี้ Densenet121, Densenet201, MobileNetV2, NASNetMobile, Xception, Vgg16, ResNet50V2

ซึ่งแบบจำลองที่ผ่านการสอนมาแล้วที่เลือกใช้ จะเป็นแบบจำลองที่ใช้เวลาคำนวณไม่นานมาก แต่ประสิทธิภาพสูง โดยพิจารณาข้อมูลจากเคราส(Keras)

4.2.7 พิจารณาประสิทธิภาพจากข้อ 4.2.6 จะเห็นว่า แทบทุกแบบจำลอง จะได้ผลลัพธ์ดี โดยมี Densene201 ดีกว่าแบบจำลองอื่นเล็กน้อย จึงทดสอบประสิทธิภาพโดยการใช้ชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล และ แบบจำลองที่ผ่านการสอนมาแล้วชนิด Densenet201 โดยใช้มีการทดลองอัตราการเรียนรู้ (Learning rate) ค่า 1e-3, 1e-4 และ 1e-5 ตามลำดับ และในแต่ละค่าอัตราการเรียนรู้ (Learning rate) มีการปรับ จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience) แบ่งเป็น 20, 30, 40 และ 50

4.2.8 พิจารณาประสิทธิภาพจากข้อ 4.2.6 และ ข้อ 4.2.7 จะเห็นว่า แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) แบบจำลอง Densene121และ Densene201 มีประสิทธิภาพสูง และใช้เวลาในการประมวลผลไม่นาน จึงทดสอบแบบจำลองตามโดยทำพารามิเตอร์ตามข้อ 5 และใช้ข้อมูลรูปภาพขนาด 224x224 พิกเซล ที่ทำการปรับขนาดมาจากภาพต้นฉบับขนาด 3000x3000 พิกเซล, 2000x2000 พิกเซล และ 1000x1000 พิกเซล เพื่อทดสอบประสิทธิภาพของแบบจำลอง

เปรียบเทียบประสิทธิภาพแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันที่เกิดจากการเปลี่ยนไฮเปอร์พารามิเตอร์

กรณีภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนในแบบ (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลในแบบ	กราฟ ROC
1000x1000	Adam	1.00E-03	20	0.93	34	0.85	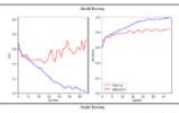	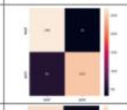	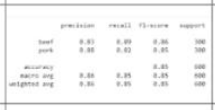	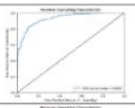
1000x1000	Adam	1.00E-03	30	0.959	54	0.89	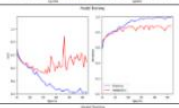	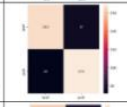	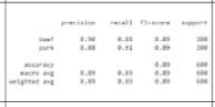	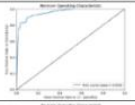
1000x1000	Adam	1.00E-03	40	0.949	63	0.87	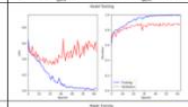	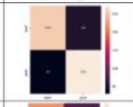	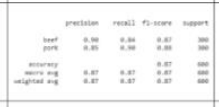	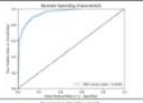
1000x1000	Adam	1.00E-03	50	0.932	69	0.86	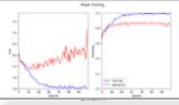	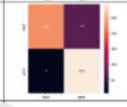	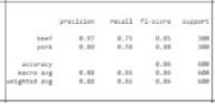	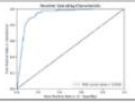

ภาพประกอบ 13 ผลลัพธ์กรณีภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3, และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 13 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.93 ถึง 0.959 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 34 ถึง 69 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.85 ถึง 0.89

กรณีภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
1000x1000	Adam	1.00E-04	20	0.926	76	0.81	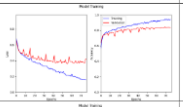	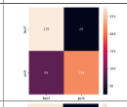	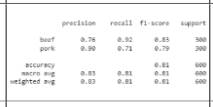	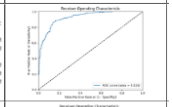
1000x1000	Adam	1.00E-04	30	0.944	146	0.85	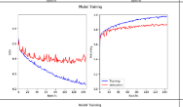	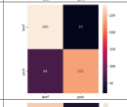	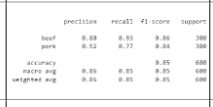	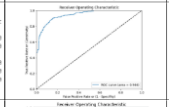
1000x1000	Adam	1.00E-04	40	0.941	94	0.87	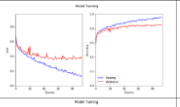	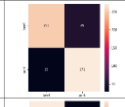	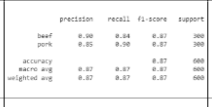	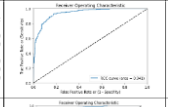
1000x1000	Adam	1.00E-04	50	0.947	146	0.85	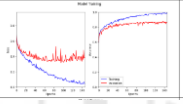	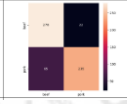	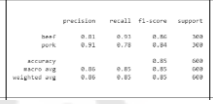	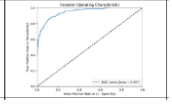

ภาพประกอบ 14 ผลลัพธ์กรณีภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4, และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 14 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.926 ถึง 0.947 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 76 ถึง 146 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.81 ถึง 0.87

กรณีภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
1000x1000	Adam	1.00E-05	20	0.948	465	0.87	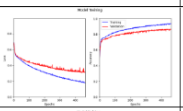	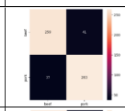	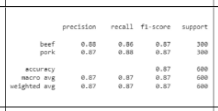	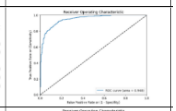
1000x1000	Adam	1.00E-05	30	0.924	250	0.83	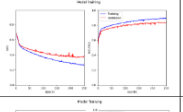	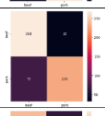	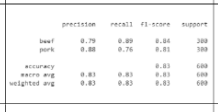	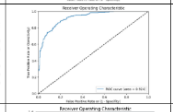
1000x1000	Adam	1.00E-05	40	0.936	430	0.85	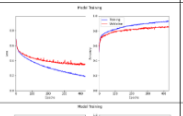	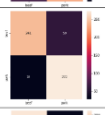	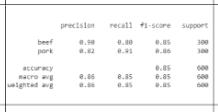	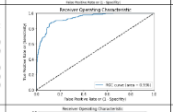
1000x1000	Adam	1.00E-05	50	0.935	538	0.86	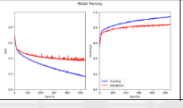	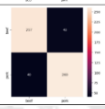	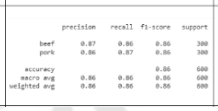	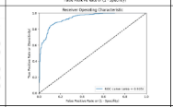

ภาพประกอบ 15 ผลลัพธ์กรณีภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 15 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.924 ถึง 0.936 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 250 ถึง 538 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.83 ถึง 0.87

กรณีภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accuracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
1000x1000	RMSprop	1.00E-03	20	0.897	40	0.82	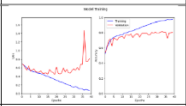	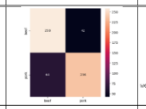	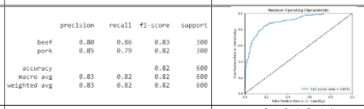	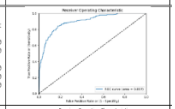
1000x1000	RMSprop	1.00E-03	40	0.906	60	0.85	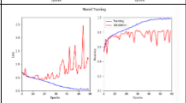	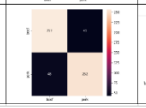	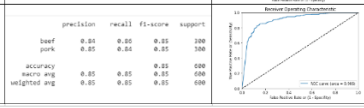	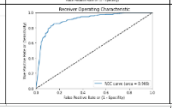
ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accuracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
1000x1000	RMSprop	1.00E-04	20	0.908	83	0.78	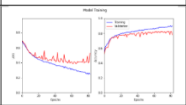	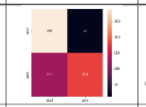	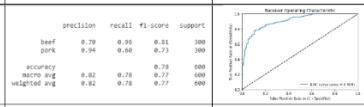	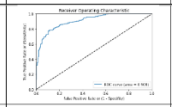
1000x1000	RMSprop	1.00E-04	40	0.93	134	0.85	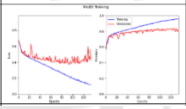	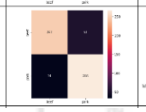	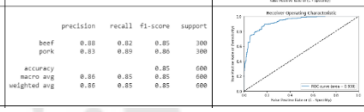	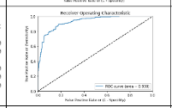
ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accuracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
1000x1000	RMSprop	1.00E-05	20	0.914	346	0.82	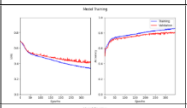	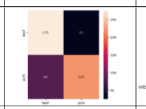	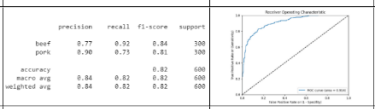	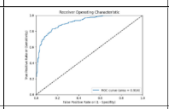
1000x1000	RMSprop	1.00E-05	40	0.929	895	0.84	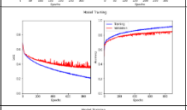	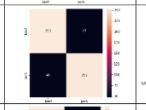	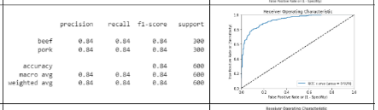	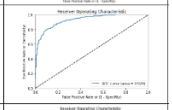
1000x1000	RMSprop	1.00E-05	50	0.949	1000	0.85	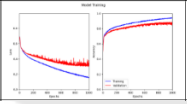	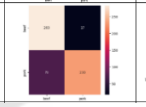	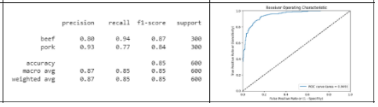	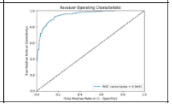

ภาพประกอบ 16 ผลลัพธ์กรณีภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3, 1e-4 และ

1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 40 และ 50 แสดงดังภาพประกอบ 16 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.897 ถึง 0.949 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 40 ถึง 1,000 รอบ(Epochs) ค่าความถูกต้อง (Accuracy) มีค่าในช่วง 0.78 ถึง 0.85

กรณีภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
2000x2000	Adam	1.00E-03	20	0.959	55	0.85	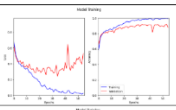	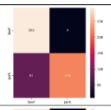	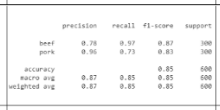	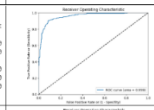
2000x2000	Adam	1.00E-03	30	0.958	65	0.89	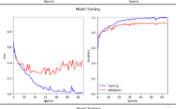	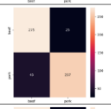	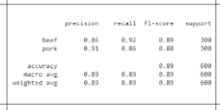	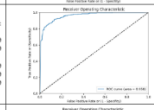
2000x2000	Adam	1.00E-03	40	0.966	64	0.91	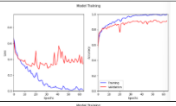	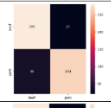	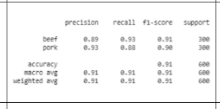	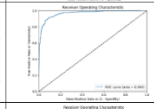
2000x2000	Adam	1.00E-03	50	0.965	75	0.9	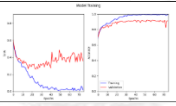	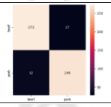	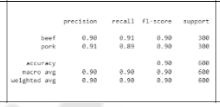	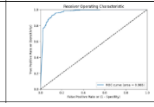

ภาพประกอบ 17 ผลลัพธ์กรณีภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 17 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.958 ถึง 0.966 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 55 ถึง 75 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.85 ถึง 0.91

กรณีภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์ที่นำมาใช้สำหรับวัดผลโมเดล	กราฟ ROC
2000x2000	Adam	1.00E-04	20	0.967	122	0.92	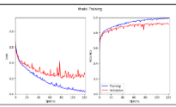	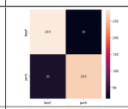	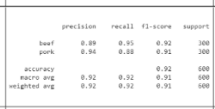	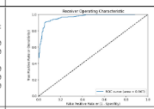
2000x2000	Adam	1.00E-04	30	0.972	133	0.9	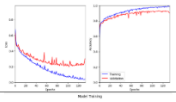	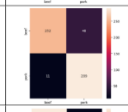	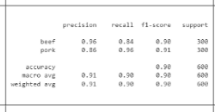	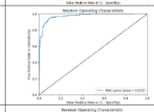
2000x2000	Adam	1.00E-04	40	0.961	152	0.85	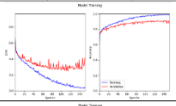	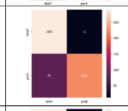	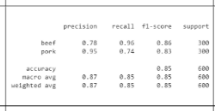	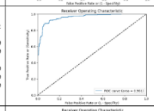
2000x2000	Adam	1.00E-04	50	0.958	144	0.89	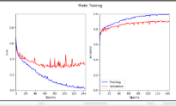	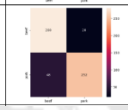	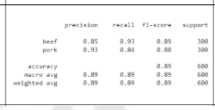	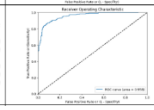

ภาพประกอบ 18 ผลลัพธ์กรณีภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 18 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.958 ถึง 0.972 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 122 ถึง 152 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.85 ถึง 0.92

กรณีภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
2000x2000	Adam	1.00E-05	20	0.958	423	0.88	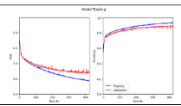	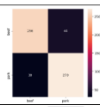	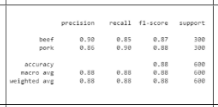	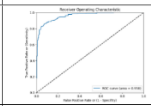
2000x2000	Adam	1.00E-05	30	0.965	665	0.91	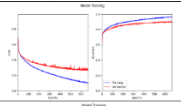	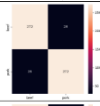	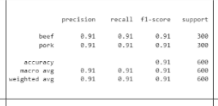	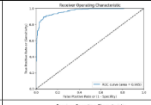
2000x2000	Adam	1.00E-05	40	0.977	1000	0.92	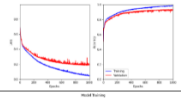	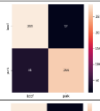	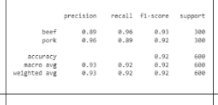	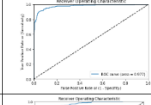
2000x2000	Adam	1.00E-05	50	0.957	723	0.87	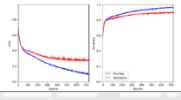	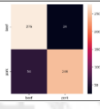	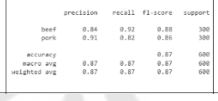	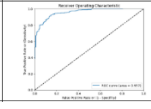

ภาพประกอบ 19 ผลลัพธ์กรณีภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 19 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.957 ถึง 0.977 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 423 ถึง 1,000 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.85 ถึง 0.92

กรณีภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
2000x2000	RMSprop	1.00E-03	20	0.929	41	0.84	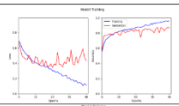	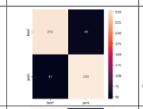	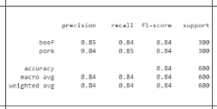	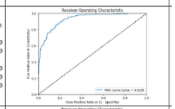
2000x2000	RMSprop	1.00E-03	40	0.918	69	0.84	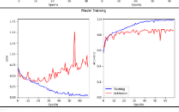	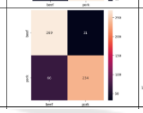	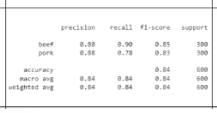	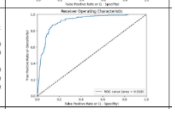

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
2000x2000	RMSprop	1.00E-04	20	0.97	190	0.9	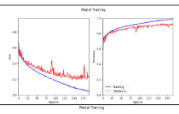	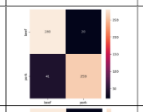	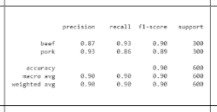	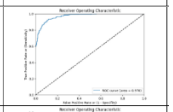
2000x2000	RMSprop	1.00E-04	40	0.946	128	0.86	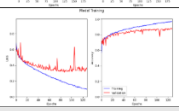	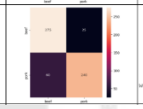	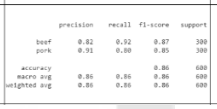	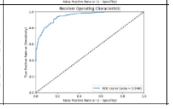

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
2000x2000	RMSprop	1.00E-05	40	0.945	894	0.88	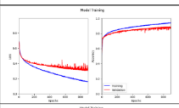	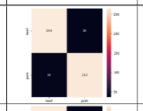	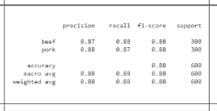	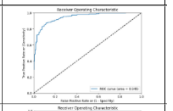
2000x2000	RMSprop	1.00E-05	50	0.955	1000	0.86	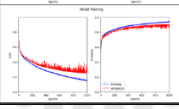	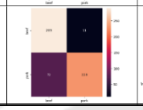	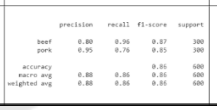	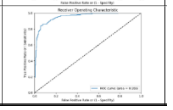

ภาพประกอบ 20 ผลลัพธ์กรณีภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20, 40 และ 50 แสดงดังภาพประกอบ

20 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.918 ถึง 0.97 จำนวนรอบที่สอนแบบจำลอง (Epochs)มีค่าในช่วง 141-1,000 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.84 ถึง 0.90

กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x3000	Adam	1.00E-03	20	0.983	47	0.94	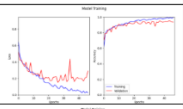	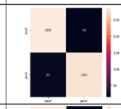	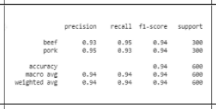	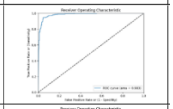
3000x3000	Adam	1.00E-03	30	0.989	73	0.95	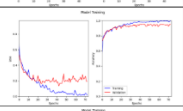	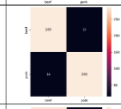	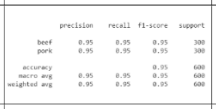	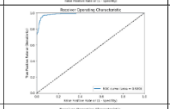
3000x3000	Adam	1.00E-03	40	0.98	59	0.95	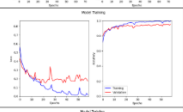	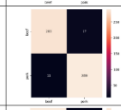	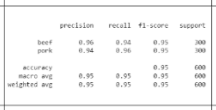	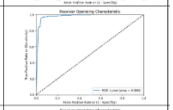
3000x3000	Adam	1.00E-03	50	0.975	81	0.94	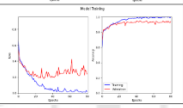	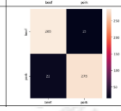	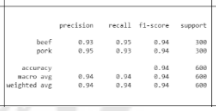	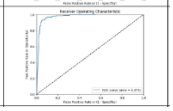

ภาพประกอบ 21 ผลลัพธ์กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 21 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.975 ถึง 0.989 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 47 ถึง 81 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.94 ถึง 0.95

กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x3000	Adam	1.00E-04	20	0.983	138	0.93	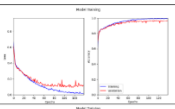	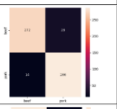	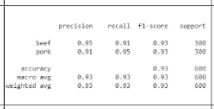	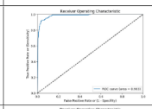
3000x3000	Adam	1.00E-04	30	0.98	132	0.93	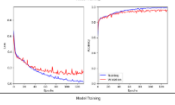	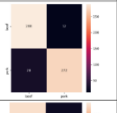	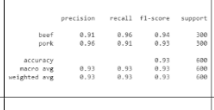	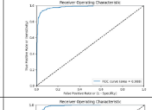
3000x3000	Adam	1.00E-04	40	0.983	217	0.94	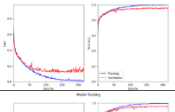	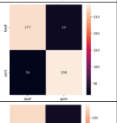	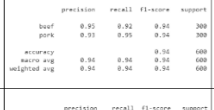	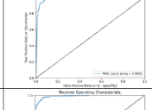
3000x3000	Adam	1.00E-04	50	0.987	164	0.95	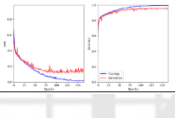		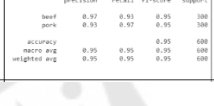	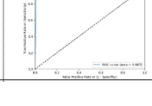

ภาพประกอบ 22 ผลลัพธ์กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 22 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.980 ถึง 0.987 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 132 ถึง 217 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.93 ถึง 0.95

กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนในโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x3000	Adam	1.00E-05	20	0.965	563	0.91	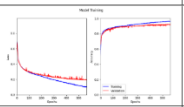	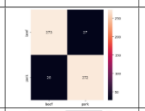	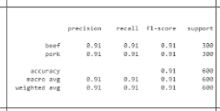	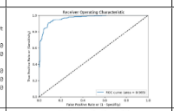
3000x3000	Adam	1.00E-05	30	0.974	755	0.92	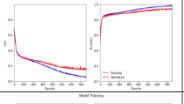	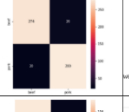	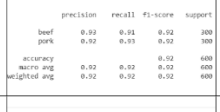	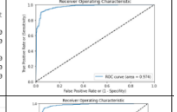
3000x3000	Adam	1.00E-05	40	0.984	845	0.94	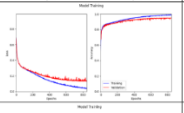	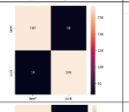	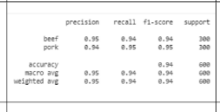	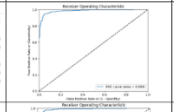
3000x3000	Adam	1.00E-05	50	0.986	1000	0.955	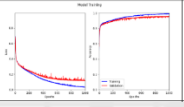	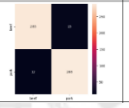	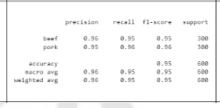	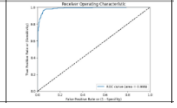

ภาพประกอบ 23 ผลลัพธ์กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 23 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.965 ถึง 0.986 จำนวนรอบที่สอนแบบจำลอง(Epochs) มีค่าในช่วง 563 ถึง 1,000 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.91 ถึง 0.955

กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accuracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x3000	RMSprop	1.00E-03	20	0.973	79	0.93	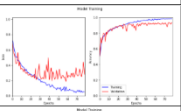	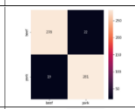	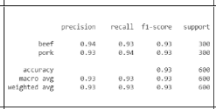	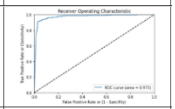
3000x3000	RMSprop	1.00E-03	30	0.97	70	0.93	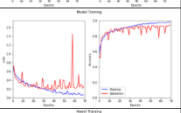	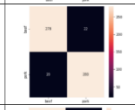	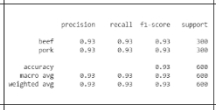	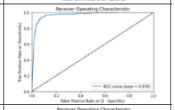
3000x3000	RMSprop	1.00E-03	40	0.975	86	0.92	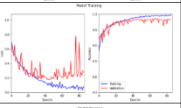	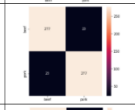	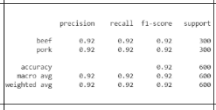	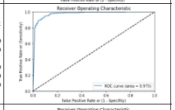
3000x3000	RMSprop	1.00E-03	50	0.97	92	0.91	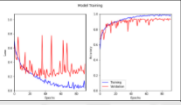	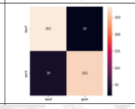	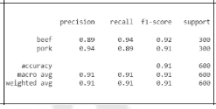	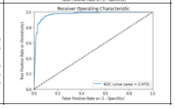

ภาพประกอบ 24 ผลลัพธ์กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 24 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.97 ถึง 0.975 จำนวนรอบที่สอนแบบจำลอง (Epochs)มีค่าในช่วง 70 ถึง 92 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.91 ถึง 0.93

กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x3000	RMSprop	1.00E-04	20	0.979	179	0.92	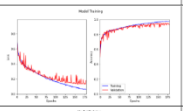	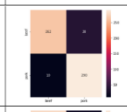	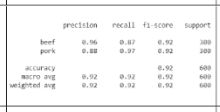	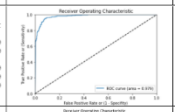
3000x3000	RMSprop	1.00E-04	30	0.972	205	0.93	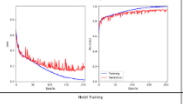	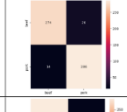	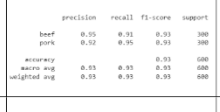	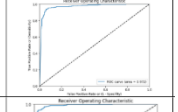
3000x3000	RMSprop	1.00E-04	40	0.985	251	0.94	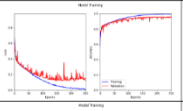	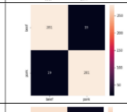	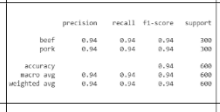	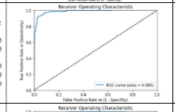
3000x3000	RMSprop	1.00E-04	50	0.972	193	0.92	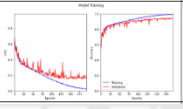	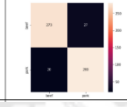	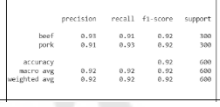	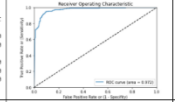

ภาพประกอบ 25 ผลลัพธ์กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 25 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.972 ถึง 0.985 จำนวนรอบที่สอนแบบจำลอง (Epochs)มีค่าในช่วง 179 ถึง 251 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.92 ถึง 0.94

กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนในโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x3000	RMSprop	1.00E-05	20	0.973	1000	0.93	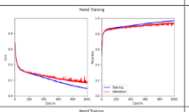	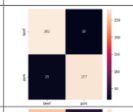	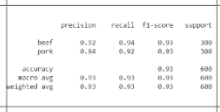	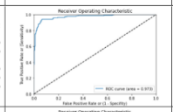
3000x3000	RMSprop	1.00E-05	30	0.978	1000	0.92	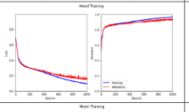	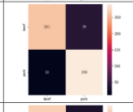	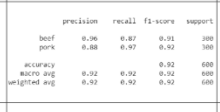	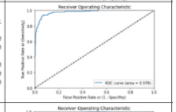
3000x3000	RMSprop	1.00E-05	40	0.97	1000	0.92	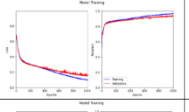	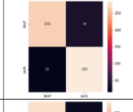	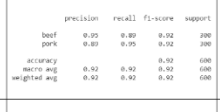	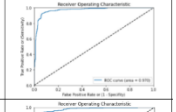
3000x3000	RMSprop	1.00E-05	50	0.972	1000	0.93	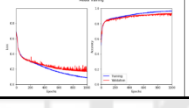	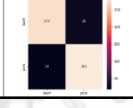	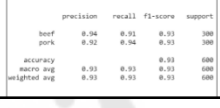	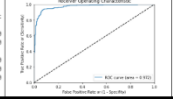

ภาพประกอบ 26 ผลลัพธ์กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 26 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.97 ถึง 0.978 จำนวนรอบที่สอนแบบจำลอง (Epochs) คือ 1,000 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.92 ถึง 0.93

กรณีภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accuracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x4000	Adam	1.00E-03	20	0.931	56	0.84	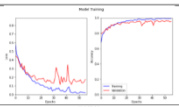	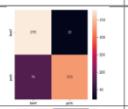	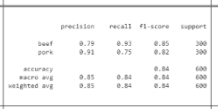	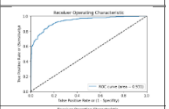
3000x4000	Adam	1.00E-03	30	0.959	99	0.83	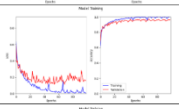	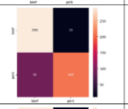	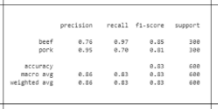	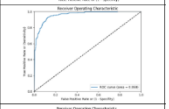
3000x4000	Adam	1.00E-03	40	0.932	85	0.81	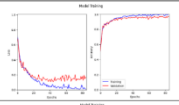	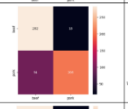	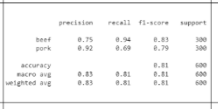	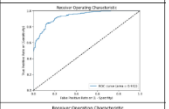
3000x4000	Adam	1.00E-03	50	0.934	115	0.81	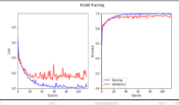	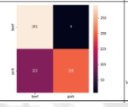	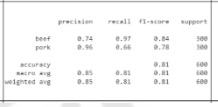	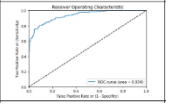

ภาพประกอบ 27 ผลลัพธ์กรณีภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 27 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.931 ถึง 0.959 จำนวนรอบที่สอนแบบจำลอง (Epochs)คือ มีค่าในช่วง 59 ถึง 115 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.81 ถึง 0.84

กรณีภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x4000	Adam	1.00E-04	20	0.874	123	0.76	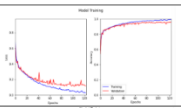	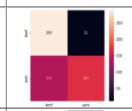	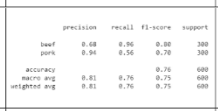	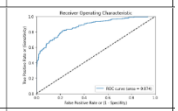
3000x4000	Adam	1.00E-04	30	0.876	147	0.73	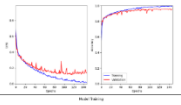		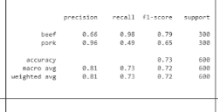	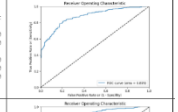
3000x4000	Adam	1.00E-04	40	0.884	144	0.75	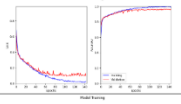		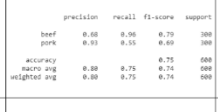	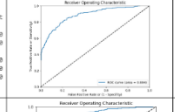
3000x4000	Adam	1.00E-04	50	0.891	193	0.77	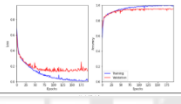		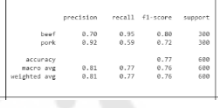	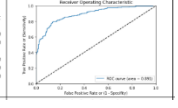

ภาพประกอบ 28 ผลลัพธ์กรณีภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 28 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.874 ถึง 0.891 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 123 ถึง 193 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.73 ถึง 0.77

กรณีภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x4000	Adam	1.00E-05	20	0.869	611	0.73	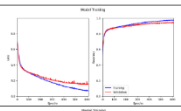	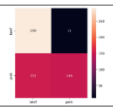	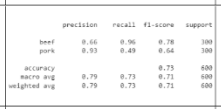	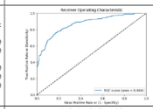
3000x4000	Adam	1.00E-05	30	0.864	598	0.76	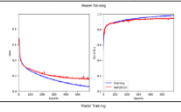	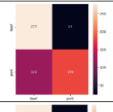	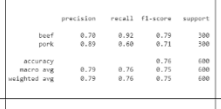	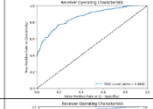
3000x4000	Adam	1.00E-05	40	0.872	701	0.72	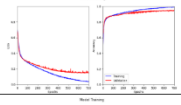	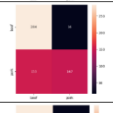	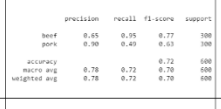	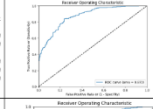
3000x4000	Adam	1.00E-05	50	0.869	500	0.76	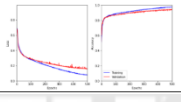		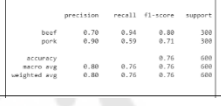	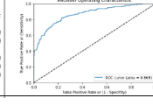

ภาพประกอบ 29 กรณีภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 29 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.864 ถึง 0.872 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 500 ถึง 701 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.72 ถึง 0.76

กรณีภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 40 และ 50

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x4000	RMSprop	1.00E-03	20	0.944	72	0.84	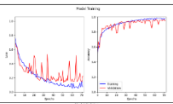	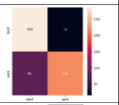	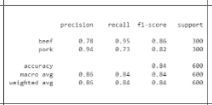	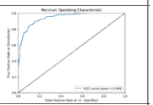
3000x4000	RMSprop	1.00E-03	40	0.948	95	0.84	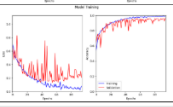	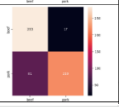	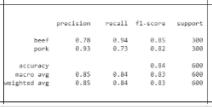	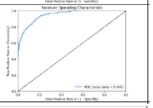

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x4000	RMSprop	1.00E-04	20	0.917	133	0.73	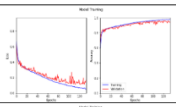	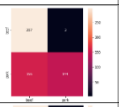	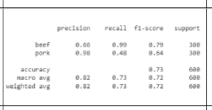	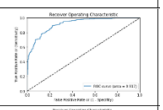
3000x4000	RMSprop	1.00E-04	40	0.915	192	0.8	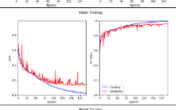	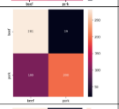	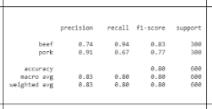	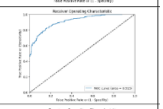
3000x4000	RMSprop	1.00E-04	50	0.904	226	0.76	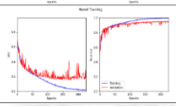	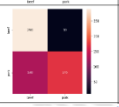	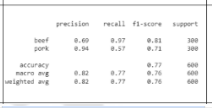	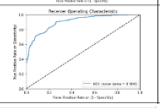

ตัวแปรในการวิจัย				ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x4000	RMSprop	1.00E-05	40	0.909	1000	0.81	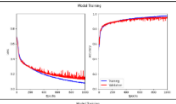	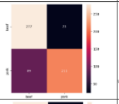	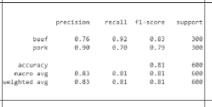	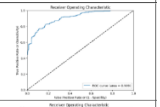
3000x4000	RMSprop	1.00E-05	50	0.912	1000	0.78	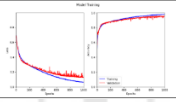	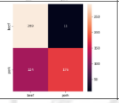	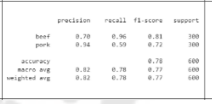	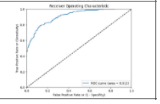

ภาพประกอบ 30 กรณีภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 40 และ 50

การเปรียบเทียบประสิทธิภาพของแบบจำลอง สำหรับภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20, 40 และ 50 แสดงดังภาพประกอบ 30 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.904 ถึง 0.948 จำนวนรอบที่สอนแบบจำลอง (Epochs)มีค่าในช่วง 72 ถึง 1,000 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.76 ถึง 0.84

เปรียบเทียบประสิทธิภาพแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันและแบบจำลองจากเทคนิคการเรียนรู้เชิงลึก

ใช้เทคนิคการเรียนรู้เชิงลึกในการสร้างแบบจำลองการเรียนรู้โดยนำแบบจำลองสำเร็จรูปแบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) จากเคราส(Keras) มาใช้งานโดยเปลี่ยนขนาดภาพ, อัตราการเรียนรู้, จำนวนรอบที่หยุดคำนวณแบบจำลอง, Optimizer และ แบบจำลองสำเร็จรูปจากเคราส(Keras) เพื่อเปรียบเทียบประสิทธิภาพของระบบ โดยแบ่งเป็นกรณีต่างๆ ดังนี้

กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 7 แบบจำลอง

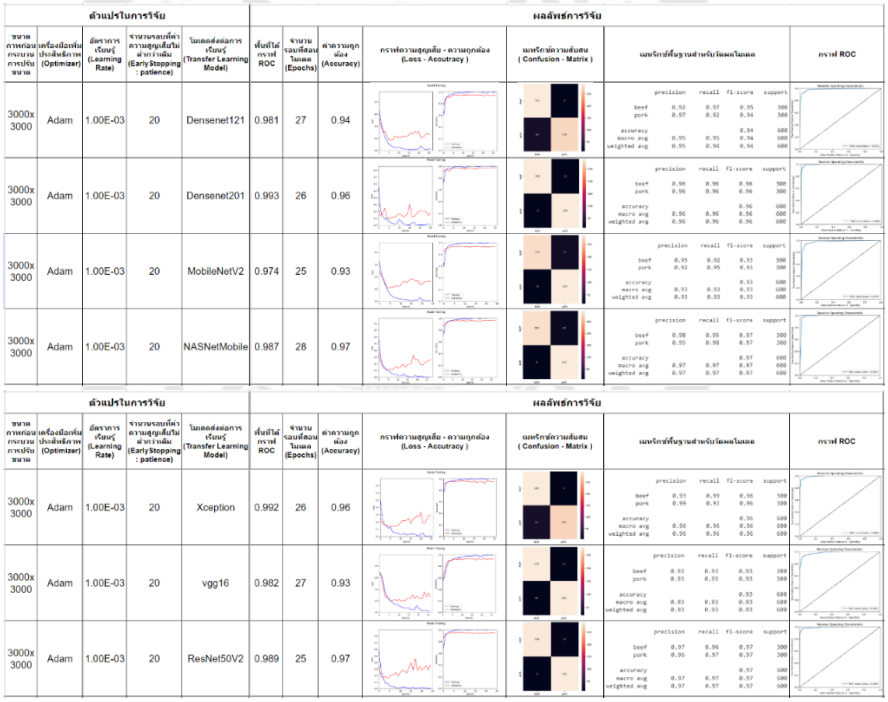

ภาพประกอบ 31 ผลลัพธ์กรณีภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 7 แบบจำลอง

การเปรียบเทียบประสิทธิภาพของแบบจำลองซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 7 แบบจำลอง สำหรับภาพขนาด 3000x3000 พิกเซล เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20 แสดงดังภาพประกอบ 31 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.974 ถึง 0.993 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 25 ถึง 28 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.93 ถึง 0.97

กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 7 แบบจำลอง

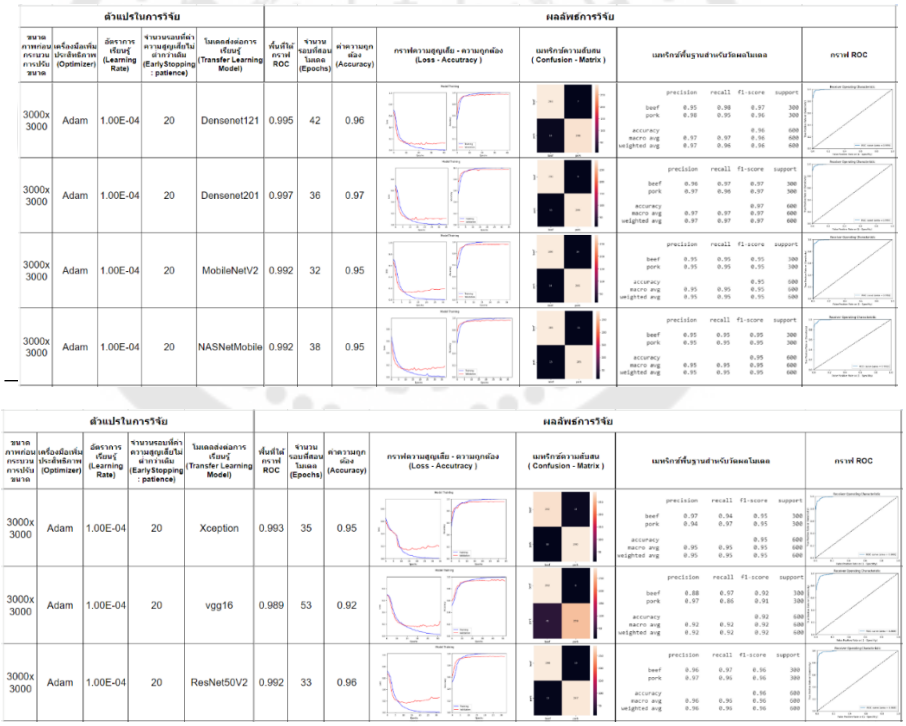

ภาพประกอบ 32 ผลลัพธ์กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 7 แบบจำลอง

การเปรียบเทียบประสิทธิภาพของแบบจำลองซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 7 แบบจำลอง สำหรับภาพขนาด 3000x3000 พิกเซล เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20 แสดงดังภาพประกอบ 32 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.989 ถึง 0.997 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 32 ถึง 53 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.92 ถึง 0.97

กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 40 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 7 แบบจำลอง

ตัวแปรในการวิจัย					ผลลัพธ์การวิจัย					
ขนาดภาพต้นแบบที่กระบวนการทำงานรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	โมเดลส่งผ่านการเรียนรู้ (Transfer Learning Model)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accuracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์ที่บ่งบอกประสิทธิภาพของโมเดล	กราฟ ROC
3000x3000	Adam	1.00E-04	40	Densenet121	0.996	67	0.97	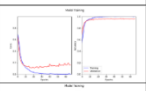		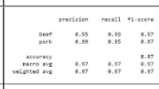	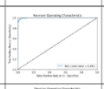
3000x3000	Adam	1.00E-04	40	Densenet201	0.997	55	0.97	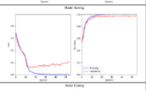		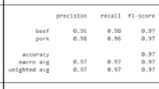	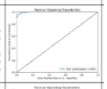
3000x3000	Adam	1.00E-04	40	MobileNetV2	0.993	54	0.96	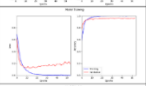		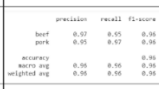	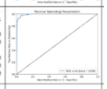
3000x3000	Adam	1.00E-04	40	NASNetMobile	0.992	57	0.95	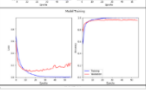		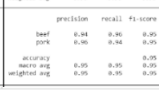	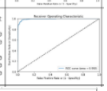

ตัวแปรในการวิจัย					ผลลัพธ์การวิจัย					
ขนาดภาพต้นแบบที่กระบวนการทำงานรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	โมเดลส่งผ่านการเรียนรู้ (Transfer Learning Model)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accuracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์ที่บ่งบอกประสิทธิภาพของโมเดล	กราฟ ROC
3000x3000	Adam	1.00E-04	40	Xception	0.993	55	0.95	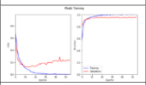		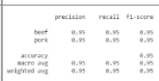	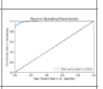
3000x3000	Adam	1.00E-04	40	vgg16	0.989	69	0.94	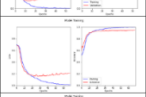		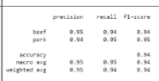	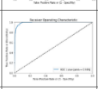
3000x3000	Adam	1.00E-04	40	ResNet50V2	0.964	60	0.92	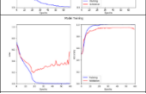		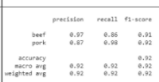	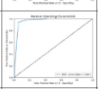

ภาพประกอบ 33 ผลลัพธ์กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 40 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 7 แบบจำลอง

การเปรียบเทียบประสิทธิภาพของแบบจำลองซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 7 แบบจำลอง สำหรับภาพขนาด 3000x3000 พิกเซล เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 40 แสดงดังภาพประกอบ 33 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.964 ถึง 0.997 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 55 ถึง 69 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.92 ถึง 0.97

กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 7 แบบจำลอง

ตัวแปรในการวิจัย					ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (EarlyStopping : patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนในแต่ละโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accuracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x3000	Adam	1.00E-05	20	Densenet121	0.995	182	0.97	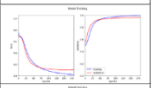	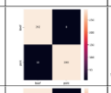	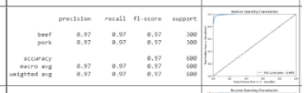	
3000x3000	Adam	1.00E-05	20	Densenet201	0.995	116	0.96	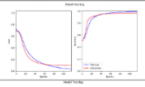	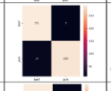	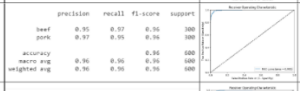	
3000x3000	Adam	1.00E-05	20	MobileNetV2	0.992	121	0.95	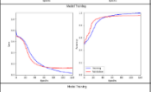	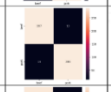	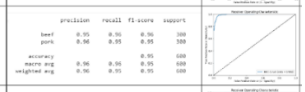	
3000x3000	Adam	1.00E-05	20	NASNetMobile	0.989	157	0.95	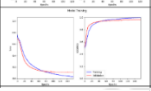		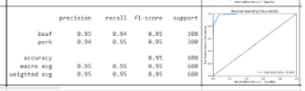	

ตัวแปรในการวิจัย					ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (EarlyStopping : patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนในแต่ละโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accuracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x3000	Adam	1.00E-05	20	Xception	0.992	128	0.95	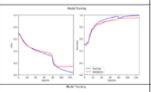	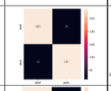	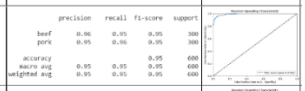	
3000x3000	Adam	1.00E-05	20	vgg16	0.987	300	0.94	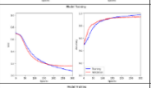	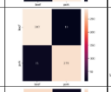	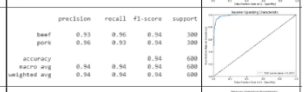	
3000x3000	Adam	1.00E-05	20	ResNet50V2	0.989	115	0.95	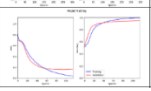	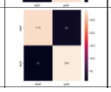	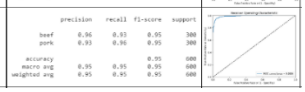	

ภาพประกอบ 34 ผลลัพธ์กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 7 แบบจำลอง

การเปรียบเทียบประสิทธิภาพของแบบจำลองซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) สำหรับภาพขนาด 3000x3000 พิกเซล เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20 แสดงดังภาพประกอบ 34 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.987 ถึง 0.995 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 115 ถึง 300 รอบ (Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.94 ถึง 0.97

กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 40 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 7 แบบจำลอง

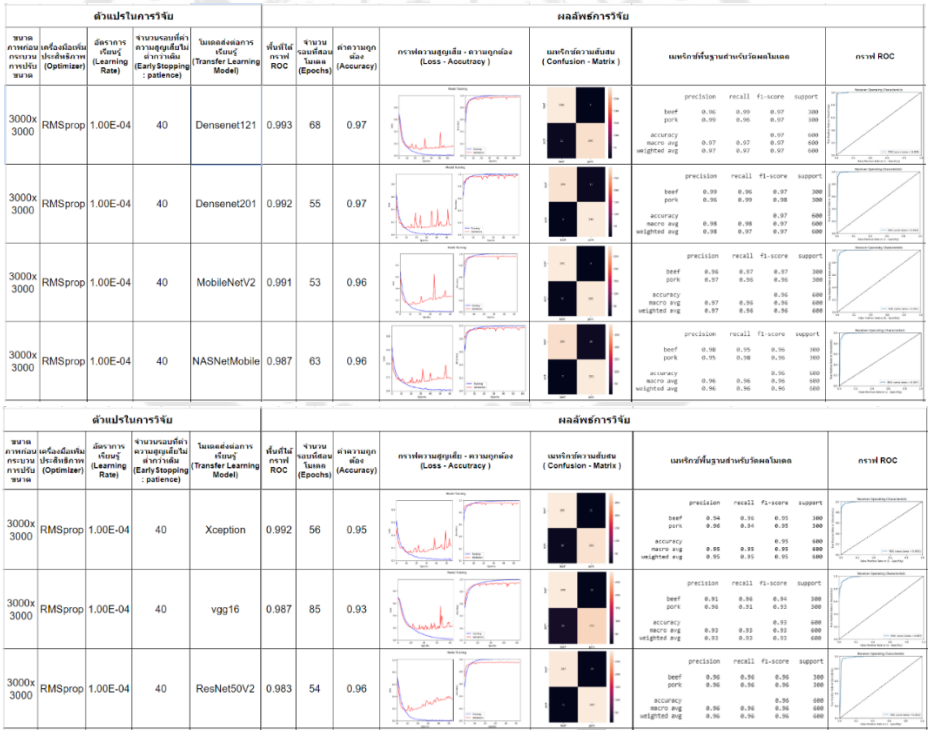

ตัวแปรในการวิจัย					ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ลำกว่าเดิม (Early Stopping : patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accuracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x3000	RMSprop	1.00E-04	40	Densenet121	0.993	68	0.97				
3000x3000	RMSprop	1.00E-04	40	Densenet201	0.992	55	0.97				
3000x3000	RMSprop	1.00E-04	40	MobileNetV2	0.991	53	0.96				
3000x3000	RMSprop	1.00E-04	40	NASNetMobile	0.987	63	0.96				

ตัวแปรในการวิจัย					ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ลำกว่าเดิม (Early Stopping : patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accuracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x3000	RMSprop	1.00E-04	40	Xception	0.992	56	0.95				
3000x3000	RMSprop	1.00E-04	40	vgg16	0.987	85	0.93				
3000x3000	RMSprop	1.00E-04	40	ResNet50V2	0.983	54	0.96				

ภาพประกอบ 35 ผลลัพธ์กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 40 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models)

การเปรียบเทียบประสิทธิภาพของแบบจำลองซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) 7 แบบจำลอง สำหรับภาพขนาด 3000x3000 พิกเซล เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 40 แสดงดังภาพประกอบ 35 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.983 ถึง 0.992 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 53 ถึง 85 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.93 ถึง 0.97

กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201

ตัวแปรในการวิจัย					ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (EarlyStopping : patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accuracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x3000	Adam	1.00E-03	40	Densenet201	0.984	45	0.94	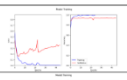		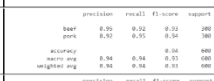	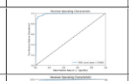
3000x3000	Adam	1.00E-03	50	Densenet201	0.974	54	0.95	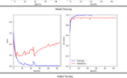		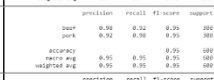	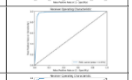
3000x3000	Adam	1.00E-04	20	Densenet201	0.997	36	0.97	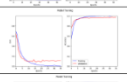		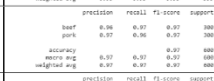	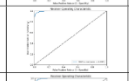
3000x3000	Adam	1.00E-04	30	Densenet201	0.993	42	0.96	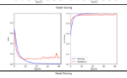		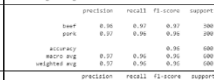	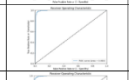
3000x3000	Adam	1.00E-04	40	Densenet201	0.997	55	0.97	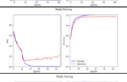	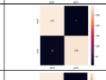	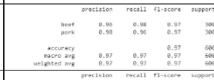	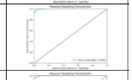
3000x3000	Adam	1.00E-04	50	Densenet201	0.997	68	0.97	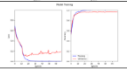		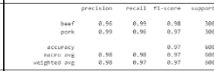	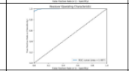

ภาพประกอบ 36 ผลลัพธ์กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201

การเปรียบเทียบประสิทธิภาพของแบบจำลองซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201 สำหรับภาพขนาด 3000x3000 พิกเซล เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3 และ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 36 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.974 ถึง 0.997 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 36 ถึง 68 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.94 ถึง 0.97

กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201

ตัวแปรในการวิจัย					ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x3000	RMSprop	1.00E-03	20	Densenet201	0.979	31	0.95	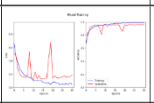	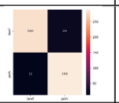	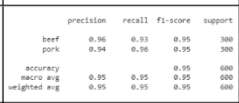	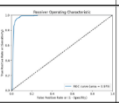
3000x3000	RMSprop	1.00E-03	30	Densenet201	0.995	51	0.96	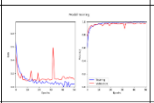	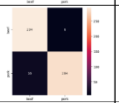	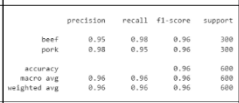	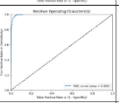
3000x3000	RMSprop	1.00E-03	40	Densenet201	0.991	55	0.96	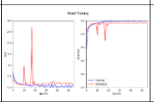	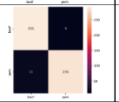	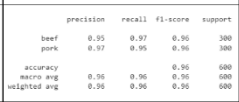	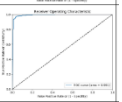
3000x3000	RMSprop	1.00E-03	50	Densenet201	0.975	61	0.9233	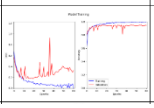	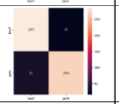	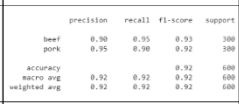	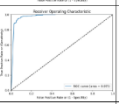

ภาพประกอบ 37 กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201

การเปรียบเทียบประสิทธิภาพของแบบจำลองซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201 สำหรับภาพขนาด 3000x3000 พิกเซล เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิดRMSprop อัตราการเรียนรู้ 1e-3 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 37 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.975 ถึง 0.995 จำนวนรอบที่สอนแบบจำลอง (Epochs)มีค่าในช่วง 31 ถึง 55 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.9233 ถึง 0.95

กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30 และ 50 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201

ตัวแปรในการวิจัย					ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accuracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x3000	RMSprop	1.00E-04	20	Densenet201	0.997	37	0.97	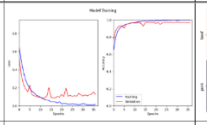	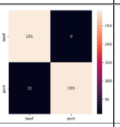	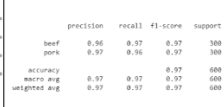	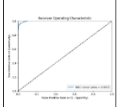
3000x3000	RMSprop	1.00E-04	30	Densenet201	0.995	47	0.97	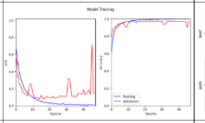	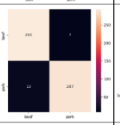	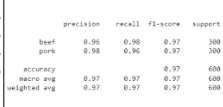	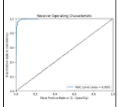
3000x3000	RMSprop	1.00E-04	50	Densenet201	0.997	63	0.96	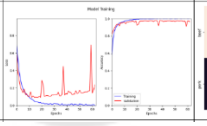	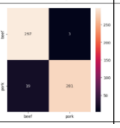	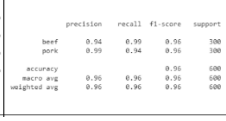	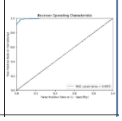

ภาพประกอบ 38 กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop, อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30 และ 50 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201

การเปรียบเทียบประสิทธิภาพของแบบจำลองซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201 สำหรับภาพขนาด 3000x3000 พิกเซล เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิดRMSprop อัตราการเรียนรู้ 1e-4 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20, 30 และ 50 แสดงดังภาพประกอบ 38 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.995 ถึง 0.997 จำนวนรอบที่สอนแบบจำลอง (Epochs)มีค่าในช่วง 36 ถึง 63 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.96 ถึง 0.97

กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201

ตัวแปรในการวิจัย					ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x3000	Adam	1.00E-05	20	Densenet201	0.995	116	0.96	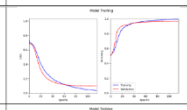	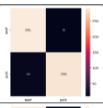	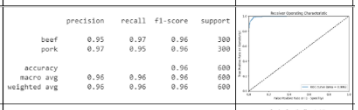	
3000x3000	Adam	1.00E-05	30	Densenet201	0.995	144	0.96	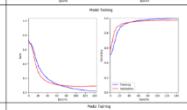	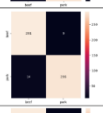	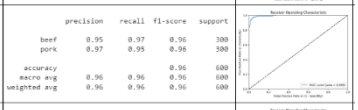	
3000x3000	Adam	1.00E-05	40	Densenet201	0.995	159	0.96	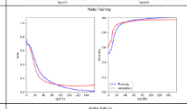	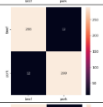	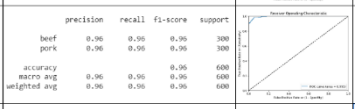	
3000x3000	Adam	1.00E-05	50	Densenet201	0.995	152	0.97	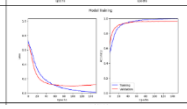	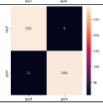	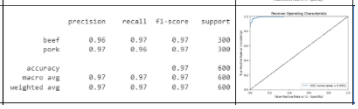	

ภาพประกอบ 39 ผลลัพธ์กรณีชุดข้อมูลจากภาพขนาด 3000x3000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20, 30, 40 และ 50 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201

การเปรียบเทียบประสิทธิภาพของแบบจำลองซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201 สำหรับภาพขนาด 3000x3000 พิกเซล เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิดRMSprop อัตราการเรียนรู้ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20, 30, 40 และ 50 แสดงดังภาพประกอบ 39 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่า 0.995 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 116 ถึง 159 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.96 ถึง 0.97

กรณีชุดข้อมูลจากภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3, 1e-4, 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 และ 40 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201

ตัวแปรในการวิจัย					ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนในแบบจำลอง (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accuracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
1000x1000	Adam	1.00E-03	20	Densenet201	0.944	38	0.9	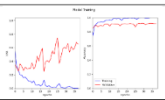	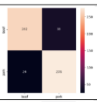	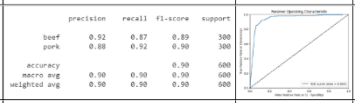	
1000x1000	Adam	1.00E-04	20	Densenet201	0.964	30	0.91	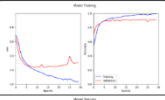	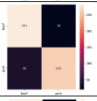	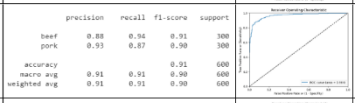	
1000x1000	Adam	1.00E-04	40	Densenet201	0.966	55	0.92	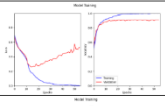	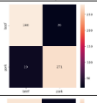	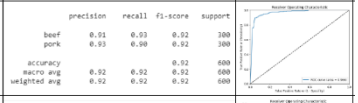	
1000x1000	Adam	1.00E-05	20	Densenet201	0.963	128	0.91	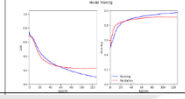	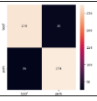	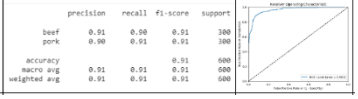	

ภาพประกอบ 40 ผลลัพธ์กรณีชุดข้อมูลจากภาพขนาด 1000x1000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 และ 40 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201

การเปรียบเทียบประสิทธิภาพของแบบจำลองซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201 สำหรับภาพขนาด 1000x1000 พิกเซล เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20 และ 40 แสดงดังภาพประกอบ 40 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.944 ถึง 0.966 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 30 ถึง 128 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.90 ถึง 0.92

กรณีชุดข้อมูลจากภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 และ 40 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201

ตัวแปรในการวิจัย					ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
2000x 2000	Adam	1.00E-03	20	Densenet201	0.974	26	0.93	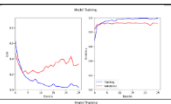	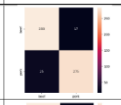	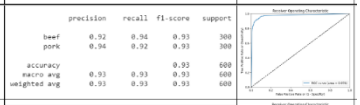	
2000x 2000	Adam	1.00E-04	20	Densenet201	0.989	36	0.94	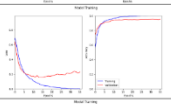	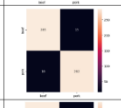	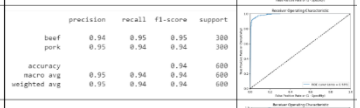	
2000x 2000	Adam	1.00E-04	40	Densenet201	0.988	53	0.95	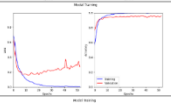	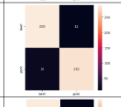	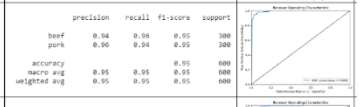	
2000x 2000	Adam	1.00E-05	20	Densenet201	0.99	112	0.95	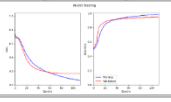	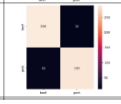	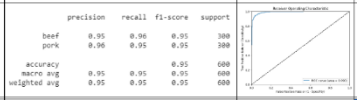	

ภาพประกอบ 41 ผลลัพธ์กรณีชุดข้อมูลจากภาพขนาด 2000x2000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 และ 40 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201

การเปรียบเทียบประสิทธิภาพของแบบจำลองซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201 สำหรับภาพขนาด 2000x2000 พิกเซล เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20 และ 40 แสดงดังภาพประกอบ 41 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.974 ถึง 0.99 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 26 ถึง 112 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.93 ถึง 0.95

กรณีชุดข้อมูลจากภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3, 1e-4, 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 และ 40 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201

ตัวแปรในการวิจัย					ผลลัพธ์การวิจัย						
ขนาดภาพก่อนกระบวนการปรับขนาด	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (EarlyStopping : patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	พื้นที่ใต้กราฟ ROC	จำนวนรอบที่สอนโมเดล (Epochs)	ค่าความถูกต้อง (Accuracy)	กราฟความสูญเสีย - ความถูกต้อง (Loss - Accutracy)	เมทริกซ์ความสับสน (Confusion - Matrix)	เมทริกซ์พื้นฐานสำหรับวัดผลโมเดล	กราฟ ROC
3000x4000	Adam	1.00E-03	20	densenet201	0.982	28	0.94	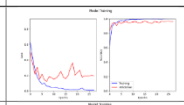	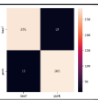	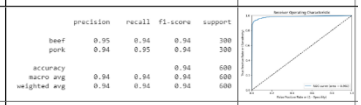	
3000x4000	Adam	1.00E-04	20	densenet201	0.997	32	0.97	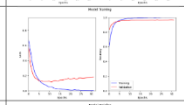	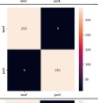	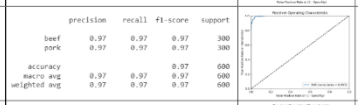	
3000x4000	Adam	1.00E-04	40	densenet201	0.994	50	0.97	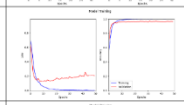	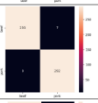	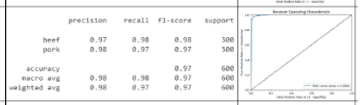	
3000x4000	adam	1.00E-05	20	densenet201	0.995	109	0.97	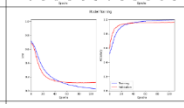	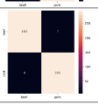	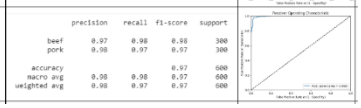	

ภาพประกอบ 42 กรณีชุดข้อมูลจากภาพขนาด 3000x4000 พิกเซล, เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 และ 40 ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201

การเปรียบเทียบประสิทธิภาพของแบบจำลองซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) คือ Densenet201 สำหรับภาพขนาด 3000x4000 พิกเซล เครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam อัตราการเรียนรู้ 1e-3, 1e-4 และ 1e-5 และจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม = 20 และ 40 แสดงดังภาพประกอบ 42 จะเห็นได้ว่าค่าพื้นที่ใต้กราฟROC มีค่าในช่วง 0.982 ถึง 0.997 จำนวนรอบที่สอนแบบจำลอง(Epochs)มีค่าในช่วง 28 ถึง 109 รอบ(Epochs) ค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.94 ถึง 0.97

เปรียบเทียบค่าพื้นที่ใต้กราฟ ROC ค่าความถูกต้อง (Accuracy) และจำนวนรอบที่สอนแบบจำลอง(Epochs)

กรณีเปรียบเทียบค่าพื้นที่ใต้กราฟ ROC ค่าความถูกต้อง(Accuracy) และจำนวนรอบที่สอนแบบจำลอง(Epochs) จากการทดสอบประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันโดยใช้เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam และ RMSprop ชุดข้อมูลที่ใช้คือข้อมูลรูปภาพขนาด224x224 พิกเซล ที่ทำการปรับขนาดมาจากภาพ ต้นฉบับขนาด 3000x4000 พิกเซล, 3000x3000 พิกเซล, 2000x2000 พิกเซล และ 1000x1000 พิกเซล มีการทดลองอัตราการเรียนรู้ (Learning rate) ค่า 1e-3, 1e-4 และ 1e-5 ตามลำดับ และในแต่ละค่าอัตราการเรียนรู้ (Learning rate) มีการปรับจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)แบ่งเป็น 20, 30, 40 และ 50 ได้ผลดังภาพประกอบที่ 43, 44 และ 45

	ขนาดภาพก่อนกระบวนการปรับขนาด	1000x1000	1000x1000	2000x2000	2000x2000	3000x3000	3000x3000	3000x4000	3000x4000
	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	Adam	RMSprop	Adam	RMSprop	Adam	RMSprop	Adam	RMSprop
ตัวแปรในการวิจัย		ผลลัพธ์การวิจัย							
อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping: patience)	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC
1.00E-03	20	0.93	0.897	0.959	0.929	0.983	0.973	0.931	**0.944**
1.00E-03	30	**0.959**		0.958		**0.989**	0.97	**0.959**	
1.00E-03	40	**0.949**	0.906	**0.966**	0.918	0.98	0.975	0.932	**0.948**
1.00E-03	50	0.932		0.965		0.975	0.97	**0.934**	
1.00E-04	20	0.926	**0.908**	0.967	**0.97**	***0.983***	**0.979**	0.874	0.917
1.00E-04	30	0.944		**0.972**		0.98	0.972	0.876	
1.00E-04	40	0.941	0.93	0.961	**0.946**	***0.983***	**0.985**	0.884	0.915
1.00E-04	50	0.947		0.958		**0.987**	0.972	0.891	0.904
1.00E-05	20	**0.948**	0.914	0.958		0.965	0.973	0.869	
1.00E-05	30	0.924		0.965		0.974	**0.978**	0.864	
1.00E-05	40	0.936	**0.929**	**0.977**	0.945	0.984	0.97	0.872	0.909
1.00E-05	50	0.935	**0.949**	0.957	**0.955**	**0.986**	0.972	0.869	0.912

ภาพประกอบ 43 เปรียบเทียบพื้นที่ใต้กราฟ ROC ในงานวิจัยนี้

	ขนาดภาพก่อนกระบวนการปรับขนาด	1000x1000	1000x1000	2000x2000	2000x2000	3000x3000	3000x3000	3000x4000	3000x4000
	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	Adam	RMSprop	Adam	RMSprop	Adam	RMSprop	Adam	RMSprop
ตัวแปรในการวิจัย		ผลลัพธ์การวิจัย							
อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping: patience)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)
1.00E-03	20	0.85	0.82	0.85	0.84	0.94	**0.93**	0.84	**0.84**
1.00E-03	30	**0.89**		0.89		**0.95**	**0.93**	**0.83**	
1.00E-03	40	**0.87**	**0.85**	0.91	0.84	**0.95**	0.92	0.81	**0.84**
1.00E-03	50	0.86		0.9		0.94	0.91	0.81	
1.00E-04	20	0.81	0.78	**0.92**	**0.9**	***0.93***	0.92	0.76	0.73
1.00E-04	30	0.85		0.9		0.93	**0.93**	0.73	
1.00E-04	40	**0.87**	**0.85**	0.85	**0.86**	***0.94***	**0.94**	0.75	**0.8**
1.00E-04	50	0.85		0.89		**0.95**	0.92	0.77	0.76
1.00E-05	20	**0.87**	0.82	0.88		0.91	**0.93**	0.73	
1.00E-05	30	0.83		0.91		0.92	0.92	0.76	
1.00E-05	40	0.85	0.84	**0.92**	**0.88**	0.94	0.92	0.72	0.81
1.00E-05	50	0.86	**0.85**	0.87	**0.86**	**0.955**	**0.93**	0.76	0.78

ภาพประกอบ 44 เปรียบเทียบค่าความถูกต้อง(accuracy)ในงานวิจัยนี้

	ขนาดภาพก่อนกระบวนการปรับขนาด	1000x1000	1000x1000	2000x2000	2000x2000	3000x3000	3000x3000	3000x4000	3000x4000
	เครื่องมือเพิ่มประสิทธิภาพ (Optimizer)	Adam	RMSprop	Adam	RMSprop	Adam	RMSprop	Adam	RMSprop
ตัวแปรในการวิจัย		ผลลัพธ์การวิจัย							
อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping: patience)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)
1.00E-03	20	34	40	55	41	47	79	56	72
1.00E-03	30	54		65		73	70	99	
1.00E-03	40	63	60	64	69	59	86	85	95
1.00E-03	50	69		75		81	92	115	
1.00E-04	20	76	83	122	190	138	179	123	133
1.00E-04	30	146		133		132	205	147	
1.00E-04	40	94	134	152	128	217	251	144	192
1.00E-04	50	146		144		164	193	193	226
1.00E-05	20	465	346	423		563	1000	611	
1.00E-05	30	250		665		755	1000	598	
1.00E-05	40	430	895	1000	894	845	1000	701	1000
1.00E-05	50	538	1000	723	1000	1000	1000	500	1000

ภาพประกอบ 45 เปรียบเทียบจำนวนรอบที่มีการสอนแบบจำลอง(Epochs)

เมื่อพิจารณาจากการเปรียบเทียบ พื้นที่ใต้กราฟ ROC ตามภาพประกอบ 43 ค่าความถูกต้อง(accuracy) ตามภาพประกอบ 44 และจำนวนรอบที่มีการสอนแบบจำลอง(Epochs) ตามภาพประกอบ 45 จะเห็นได้ว่าภาพ ขนาด 3000x3000 มีค่าพื้นที่ใต้กราฟ ROC และ ค่าความถูกต้อง(accuracy) สูงกว่าจากภาพขนาดอื่น และเมื่อพิจารณาประสิทธิภาพและความเหมาะสมในการนำไปใช้ จะเห็นได้ว่าเครื่องมือเพิ่มประสิทธิภาพ คือ Adam, อัตราการเรียนรู้ที่ 1e-3 จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม ค่า 40 และ อัตราการเรียนรู้ที่ 1e-4 จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) ค่า 20 และ 40 มีประสิทธิภาพในการสอนแบบจำลองสูง และใช้จำนวนรอบการสอนไม่สูงมาก ซึ่งจะประหยัดเวลาในการสอนกว่าการใช้อัตราการเรียนรู้ที่ 1e-5

กรณีเปรียบเทียบค่าพื้นที่ใต้กราฟROC ค่าความถูกต้อง(Accuracy) และจำนวนรอบที่มีการสอนแบบจำลอง จากการทดสอบประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันซึ่งใช้เทคนิคการเรียนรู้เชิงลึก ใช้แบบจำลองที่ผ่านการสอนมาแล้ว (Pretrained models) จำนวน 7 แบบจำลอง โดยใช้เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam และ RMSprop ชุดข้อมูลที่ใช้คือข้อมูลรูปภาพขนาด224x224 พิกเซล ที่ทำการปรับขนาดมาจากภาพต้นฉบับขนาด 3000x4000 พิกเซล, 3000x3000 พิกเซล, 2000x2000 พิกเซล และ 1000x1000 พิกเซล มีการทดลองอัตราการเรียนรู้ (Learning rate) ค่า 1e-3, 1e-4 และ 1e-5 ตามลำดับ และในแต่ละค่าอัตราการเรียนรู้ (Learning rate) มีการปรับจำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (Early Stopping : patience)แบ่งเป็น 20, 30, 40 และ 50

			1000x1000	2000x2000	3000x3000	3000x3000	3000x4000
			Adam	Adam	Adam	RMSprop	Adam
			ผลลัพธ์การวิจัย				
อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (EarlyStopping:patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC
1.00E-03	20	Densenet121	0.961	0.991	0.981	0.979	0.982
1.00E-03	20	Densenet201	0.944	0.974	0.993	0.995	0.982
1.00E-03	20	MobileNetV2			0.974		
1.00E-03	20	NASNetMobile			0.987		
1.00E-03	20	Xception			0.992		
1.00E-03	20	vgg16			0.982		
1.00E-03	20	ResNet50V2			0.989		
1.00E-03	30	Densenet201			0.991		
1.00E-03	40	Densenet121			0.99		0.996
1.00E-03	40	Densenet201			0.984	0.991	0.997
1.00E-03	40	MobileNetV2			0.993		
1.00E-03	50	Densenet201			0.974	0.975	

ภาพประกอบ 46 เปรียบเทียบพื้นที่ใต้กราฟ ROC หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณี อัตราการเรียนรู้ (Learning rate) ค่า 1e-3

การเปรียบเทียบพื้นที่ใต้กราฟ ROC หลังจากใช้เทคนิคการเรียนรู้เชิงลึก สำหรับอัตราการเรียนรู้ (Learning rate) ค่า 1e-3 ปรากฏดังภาพประกอบที่ 46 ซึ่งจะเห็นได้ว่าค่าพื้นที่ใต้กราฟ ROC) มีค่าในช่วง 0.944 ถึง 0.997 โดยชุดข้อมูลที่ทำการปรับขนาดมาจากภาพต้นฉบับขนาด 3000x3000 พิกเซล มีค่าพื้นที่ใต้กราฟ ROC สูงกว่าภาพขนาดอื่น

			1000x1000	2000x2000	3000x3000	3000x3000	3000x4000
			Adam	Adam	Adam	RMSprop	Adam
			ผลลัพธ์การวิจัย				
อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (EarlyStopping:patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC
1.00E-04	20	Densenet121	0.964	0.979	0.995		
1.00E-04	20	Densenet201	0.964	0.989	0.997	0.997	
1.00E-04	20	MobileNetV2			0.992		
1.00E-04	20	NASNetMobile			0.992		
1.00E-04	20	Xception			0.993		
1.00E-04	20	vgg16			0.989		
1.00E-04	20	ResNet50V2			0.992		
1.00E-04	30	Densenet201			0.993	0.995	
1.00E-04	40	Densenet121	0.968	0.988	0.996	0.993	0.996
1.00E-04	40	Densenet201	0.966	0.988	0.997	0.992	0.994
1.00E-04	40	MobileNetV2			0.993	0.991	
1.00E-04	40	NASNetMobile			0.992	0.987	
1.00E-04	40	Xception			0.993	0.992	
1.00E-04	40	vgg16			0.989	0.987	
1.00E-04	40	ResNet50V2			0.964	0.983	
1.00E-04	50	Densenet201			0.997	0.997	

ภาพประกอบ 47 เปรียบเทียบพื้นที่ใต้กราฟ ROC หลังจากใช้เทคนิคการเรียนรู้เชิงลึกกรณีอัตราการเรียนรู้ (Learning rate) ค่า 1e-4

การเปรียบเทียบพื้นที่ใต้กราฟ ROC หลังจากใช้เทคนิคการเรียนรู้เชิงลึก สำหรับอัตราการเรียนรู้ (Learning rate) ค่า 1e-4 ปรากฏดังภาพประกอบที่ 47 ซึ่งจะเห็นได้ว่าค่าพื้นที่ใต้กราฟ ROC) มีค่าในช่วง 0.964 ถึง 0.997 โดยชุดข้อมูลที่ทำการปรับขนาดมาจากภาพต้นฉบับขนาด 3000x3000 พิกเซล มีค่าพื้นที่ใต้กราฟ ROC สูงกว่าภาพขนาดอื่น

			1000x1000	2000x2000	3000x3000	3000x3000	3000x4000
			Adam	Adam	Adam	RMSprop	Adam
			ผลลัพธ์การวิจัย				
อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (EarlyStopping:patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC	พื้นที่ใต้กราฟ ROC
1.00E-05	20	Densenet121	0.962	0.992	0.995	0.994	0.995
1.00E-05	20	Densenet201	0.963	0.99	0.995		0.995
1.00E-05	20	MobileNetV2			0.992		
1.00E-05	20	NASNetMobile			0.989		
1.00E-05	20	Xception			0.992		
1.00E-05	20	vgg16			0.987		
1.00E-05	20	ResNet50V2			0.989		
1.00E-05	30	Densenet201			0.995	0.996	
1.00E-05	40	Densenet121			0.996	0.995	
1.00E-05	40	Densenet201			0.995		
1.00E-05	50	Densenet201			0.995	0.996	

ภาพประกอบ 48 เปรียบเทียบพื้นที่ใต้กราฟ ROC หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณี อัตราการเรียนรู้ (Learning rate) ค่า 1e-5

การเปรียบเทียบพื้นที่ใต้กราฟ ROC หลังจากใช้เทคนิคการเรียนรู้เชิงลึก สำหรับอัตราการเรียนรู้ (Learning rate) ค่า 1e-5 ปรากฏดังภาพประกอบที่ 48 ซึ่งจะเห็นได้ว่าค่าพื้นที่ใต้กราฟ ROC) มีค่าในช่วง 0.962 ถึง 0.996 โดยชุดข้อมูลที่ทำการปรับขนาดมาจากภาพต้นฉบับขนาด 3000x3000 พิกเซล และ 3000x4000 พิกเซล มีค่าพื้นที่ใต้กราฟ ROC สูงกว่าภาพขนาดอื่น

			1000x1000	2000x2000	3000x3000	3000x3000	3000x4000
			Adam	Adam	Adam	RMSprop	adam
			ผลลัพธ์การวิจัย				
อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (EarlyStopping: patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)
1.00E-03	20	Densenet121	0.91	0.94	0.94	0.95	0.95
1.00E-03	20	Densenet201	0.9	0.93	0.96	0.96	0.94
1.00E-03	20	MobileNetV2			0.93		
1.00E-03	20	NASNetMobile			0.97		
1.00E-03	20	Xception			0.96		
1.00E-03	20	vgg16			0.93		
1.00E-03	20	ResNet50V2			0.97		
1.00E-03	30	Densenet201			0.94		
1.00E-03	40	Densenet121			0.94		0.96
1.00E-03	40	Densenet201			0.94	0.96	0.97
1.00E-03	40	MobileNetV2			0.96		
1.00E-03	50	Densenet201			0.95	0.9233	

ภาพประกอบ 49 เปรียบเทียบค่าความถูกต้อง(Accuracy)หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณีอัตราการเรียนรู้ (Learning rate) ค่า 1e-3

การเปรียบเทียบพื้นที่ใต้กราฟ ROC หลังจากใช้เทคนิคการเรียนรู้เชิงลึก สำหรับอัตราการเรียนรู้ (Learning rate) ค่า 1e-3 ปรากฏดังภาพประกอบที่ 49 ซึ่งจะเห็นได้ว่าค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.90 ถึง 0.97 โดยชุดข้อมูลที่ทำการปรับขนาดมาจากภาพต้นฉบับขนาด 3000x3000 พิกเซล และ 3000x4000 พิกเซล มีค่าความถูกต้อง(Accuracy)สูงกว่าภาพขนาดอื่น

			1000x1000	2000x2000	3000x3000	3000x3000	3000x4000
			Adam	Adam	Adam	RMSprop	Adam
			ผลลัพธ์การวิจัย				
อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (EarlyStopping:patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)
1.00E-04	20	Densenet121	0.91	0.95	0.96		
1.00E-04	20	Densenet201	0.91	0.94	0.97	0.97	
1.00E-04	20	MobileNetV2			0.95		
1.00E-04	20	NASNetMobile			0.95		
1.00E-04	20	Xception			0.95		
1.00E-04	20	vgg16			0.92		
1.00E-04	20	ResNet50V2			0.96		
1.00E-04	30	Densenet201			0.96	0.97	
1.00E-04	40	Densenet121	0.92	0.96	0.97	0.97	0.96
1.00E-04	40	Densenet201	0.92	0.95	0.97	0.97	0.97
1.00E-04	40	MobileNetV2			0.96	0.96	
1.00E-04	40	NASNetMobile			0.95	0.96	
1.00E-04	40	Xception			0.95	0.95	
1.00E-04	40	vgg16			0.94	0.93	
1.00E-04	40	ResNet50V2			0.92	0.96	
1.00E-04	50	Densenet201			0.97	0.96	

ภาพประกอบ 50 เปรียบเทียบค่าความถูกต้อง(Accuracy) หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณี อัตราการเรียนรู้ (Learning rate) ค่า 1e-4

การเปรียบเทียบพื้นที่ใต้กราฟ ROC หลังจากใช้เทคนิคการเรียนรู้เชิงลึก สำหรับอัตราการเรียนรู้ (Learning rate) ค่า 1e-4 ปรากฏดังภาพประกอบที่ 50 ซึ่งจะเห็นได้ว่าค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.91 ถึง 0.97 โดยชุดข้อมูลที่ทำการปรับขนาดมาจากภาพต้นฉบับขนาด 3000x3000 พิกเซล และ 3000x4000 พิกเซล มีค่าความถูกต้อง(Accuracy)สูงกว่าภาพขนาดอื่น

A	B	C	F	M	U	AB	AJ
			1000x1000	2000x2000	3000x3000	3000x3000	3000x4000
			Adam	Adam	Adam	RMSprop	Adam
			ผลลัพธ์การวิจัย				
อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (EarlyStopping:patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)	ค่าความถูกต้อง (Accuracy)
1.00E-05	20	Densenet121	0.91	0.95	0.97	0.96	0.97
1.00E-05	20	Densenet201	0.91	0.95	0.96		0.97
1.00E-05	20	MobileNetV2			0.95		
1.00E-05	20	NASNetMobile			0.95		
1.00E-05	20	Xception			0.95		
1.00E-05	20	vgg16			0.94		
1.00E-05	20	ResNet50V2			0.95		
1.00E-05	30	Densenet201			0.96	0.96	
1.00E-05	40	Densenet121			0.97	0.96	
1.00E-05	40	Densenet201			0.96		
1.00E-05	50	Densenet201			0.97	0.97	

ภาพประกอบ 51 เปรียบเทียบค่าความถูกต้อง(Accuracy)หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณีอัตราการเรียนรู้ (Learning rate) ค่า 1e-5

การเปรียบเทียบพื้นที่ใต้กราฟ ROC หลังจากใช้เทคนิคการเรียนรู้เชิงลึก สำหรับอัตราการเรียนรู้ (Learning rate) ค่า 1e-5 ปรากฏดังภาพประกอบที่ 51 ซึ่งจะเห็นได้ว่าค่าความถูกต้อง(Accuracy) มีค่าในช่วง 0.91 ถึง 0.97 โดยชุดข้อมูลที่ทำการปรับขนาดมาจากภาพต้นฉบับขนาด 3000x3000 พิกเซล และ 3000x4000 พิกเซล มีค่าความถูกต้อง(Accuracy)สูงกว่าภาพขนาดอื่น

			1000x1000	2000x2000	3000x3000	3000x3000	3000x4000
			Adam	Adam	Adam	RMSprop	Adam
			ผลลัพธ์การวิจัย				
อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (EarlyStopping:patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)
1.00E-03	20	Densenet121	26	27	27	31	28
1.00E-03	20	Densenet201	38	26	26	51	28
1.00E-03	20	MobileNetV2			25		
1.00E-03	20	Xception			26		
1.00E-03	20	vgg16			27		
1.00E-03	20	ResNet50V2			25		
1.00E-03	30	Densenet201			37		
1.00E-03	40	Densenet121			69		42
1.00E-03	40	Densenet201			45	55	32
1.00E-03	40	MobileNetV2			54		
1.00E-03	50	Densenet201			54	61	

ภาพประกอบ 52 เปรียบเทียบจำนวนรอบที่สอนแบบจำลอง(Epochs) หลังจากใช้เทคนิคการเรียนรู้เชิงลึกกรณีอัตราการเรียนรู้ (Learning rate) ค่า 1e-3

การเปรียบเทียบจำนวนรอบที่สอนแบบจำลอง(Epochs) หลังจากใช้เทคนิคการเรียนรู้เชิงลึก สำหรับอัตราการเรียนรู้ (Learning rate) ค่า 1e-3 ปรากฏดังภาพประกอบที่ 52 ซึ่งจะเห็นได้ว่าจำนวนรอบที่สอนแบบจำลอง(Epochs) มีค่าในช่วง 25 ถึง 69 รอบ(Epochs)โดยที่จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) = 20 และเครื่องมือเพิ่มประสิทธิภาพ(Optimizer) ชนิด Adam ผลลัพธ์ที่ได้จะมีจำนวนรอบที่สอนแบบจำลอง(Epochs) ใกล้เคียงกัน คือประมาณ 27 รอบ(Epochs)

			1000x1000	2000x2000	3000x3000	3000x3000	3000x4000
			Adam	Adam	Adam	RMSprop	Adam
			ผลลัพธ์การวิจัย				
อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (EarlyStopping:patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)
1.00E-04	20	Densenet201	30	36	36	37	
1.00E-04	20	MobileNetV2			32		
1.00E-04	20	NASNetMobile			38		
1.00E-04	20	Xception			35		
1.00E-04	20	vgg16			53		
1.00E-04	20	ResNet50V2			33		
1.00E-04	30	Densenet201			42	47	
1.00E-04	40	Densenet121	56	59	67	68	61
1.00E-04	40	Densenet201	55	53	55	55	50
1.00E-04	40	MobileNetV2			54	53	
1.00E-04	40	NASNetMobile			57	63	
1.00E-04	40	Xception			55	56	
1.00E-04	40	vgg16			69	85	
1.00E-04	40	ResNet50V2			60	54	

ภาพประกอบ 53 เปรียบเทียบจำนวนรอบที่สอนแบบจำลอง(Epochs) หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณี อัตราการเรียนรู้ (Learning rate) ค่า 1e-4

การเปรียบเทียบจำนวนรอบที่สอนแบบจำลอง(Epochs) หลังจากใช้เทคนิคการเรียนรู้เชิงลึก สำหรับอัตราการเรียนรู้ (Learning rate) ค่า 1e-4 ปรากฏดังภาพประกอบที่ 53 ซึ่งจะเห็นได้ว่าจำนวนรอบที่สอนแบบจำลอง(Epochs) มีค่าในช่วง 30 ถึง 69 รอบ(Epochs)

			1000x1000	2000x2000	3000x3000	3000x3000	3000x4000
			Adam	Adam	Adam	RMSprop	Adam
			ผลลัพธ์การวิจัย				
อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (EarlyStopping:patience)	โมเดลส่งต่อการเรียนรู้ (Transfer Learning Model)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)	จำนวนรอบที่สอนโมเดล (Epochs)
1.00E-05	20	Densenet121	184	143	182	136	176
1.00E-05	20	Densenet201	128	112	116		109
1.00E-05	20	MobileNetV2			121		
1.00E-05	20	NASNetMobile			157		
1.00E-05	20	Xception			128		
1.00E-05	20	vgg16			300		
1.00E-05	20	ResNet50V2			115		
1.00E-05	30	Densenet201			144	132	
1.00E-05	40	Densenet121			218	140	
1.00E-05	40	Densenet201			159		
1.00E-05	50	Densenet201			152	149	

ภาพประกอบ 54 เปรียบเทียบจำนวนรอบที่สอนแบบจำลอง(Epochs) หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณีอัตราการเรียนรู้ (Learning rate) ค่า 1e-5

การเปรียบเทียบจำนวนรอบที่สอนแบบจำลอง(Epochs) หลังจากใช้เทคนิคการเรียนรู้เชิงลึก สำหรับอัตราการเรียนรู้ (Learning rate) ค่า 1e-5 ปรากฏดังภาพประกอบที่ 54 ซึ่งจะเห็นได้ว่าจำนวนรอบที่สอนแบบจำลอง(Epochs) มีค่าในช่วง 109 ถึง 300 รอบ(Epochs)

ในบทนี้แสดงประสิทธิภาพของแบบจำลองที่เกิดขึ้นในงานวิจัยนี้ ซึ่งเกิดจากการปรับเปลี่ยนไฮเปอร์พารามิเตอร์ต่างๆ เปลี่ยนชุดข้อมูลสำหรับการสอนและทดสอบ รวมทั้งเปลี่ยนแบบจำลองที่ผ่านการสอนแล้ว โดยข้อสรุปสำหรับงานวิจัยนี้เสนอในบทที่ 5

บทที่ 5
สรุปผล อภิปรายผล และข้อเสนอแนะ

ในการวิจัยเรื่องการจำแนกเนื้อวัวและเนื้อหมูโดยใช้เทคนิคการเรียนรู้เชิงลึก ผู้วิจัยได้ศึกษาวิธีการเรียนรู้เชิงลึกแบบใช้แบบจำลองที่ผ่านการสอนมาแล้วซึ่งทำการปรับไฮเปอร์พารามิเตอร์ต่างๆ ในการจำแนกเนื้อวัวและเนื้อหมูสำหรับชุดข้อมูลที่มีการถ่ายภาพจากกล้องมือถือแบบใช้แบบจำลองที่ผ่านการสอนมาแล้ว เพื่อหาแบบจำลองและไฮเปอร์พารามิเตอร์ที่เหมาะสมในการแยกเนื้อวัวและเนื้อหมู หลังจากได้ผลการดำเนินแล้ว แบ่งหัวข้อสรุปผลได้ดังนี้

5.1 สรุปผลการวิจัย

5.2 อภิปรายผลการวิจัย

5.3 ข้อเสนอแนะ

5.1 สรุปผลการวิจัย

จากการวิจัยจะเห็นได้ว่า

หลังการใช้เทคนิคการเรียนรู้เชิงลึก โดยการใช้ แบบจำลองที่มีการสอนแล้วมาใช้งาน จากการเปรียบเทียบ พื้นที่ใต้กราฟ ROC, ค่าความถูกต้อง(Accuracy)และจำนวนรอบที่มีการสอนแบบจำลอง จะเห็นได้ว่าภาพ ขนาด 3000x3000 พิกเซล มีค่าพื้นที่ใต้กราฟ ROC และ ค่าความถูกต้อง(Accuracy) สูงกว่าจากภาพขนาดอื่นเล็กน้อย และเมื่อพิจารณาประสิทธิภาพและความเหมาะสมในการนำไปใช้ จะเห็นได้ว่าที่เครื่องมือเพิ่มประสิทธิภาพ คือแบบจำลองที่เหมาะสมกับชุดข้อมูลในการวิจัยชิ้นนี้คือ Densenet201 อัตราการเรียนรู้ที่ 1e-4 จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม ค่า 40 มีประสิทธิภาพในการสอนแบบจำลองสูง และใช้จำนวนรอบการสอนไม่สูงมาก ซึ่งจะประหยัดเวลาในการสอนมากกว่าการใช้อัตราการเรียนรู้ที่ 1e-5

เมื่อพิจารณารูปแบบภาพที่เมื่อเข้าสู่แบบจำลอง แล้ว ทำให้แบบจำลองมีประสิทธิภาพสูงสุด คือ ภาพที่เกิดจากการตัดขอบขนาด 3000x3000 พิกเซล เนื่องจากภาพประเภทนี้ สามารถมองเห็นขอบของเนื้อสัตว์ได้ โดยไม่โดนการรบกวนจากภาชนะที่ใส่เนื้อสัตว์

อัตราการเรียนรู้ที่เหมาะสมในการใช้งานคือ 1e-4 ซึ่งประสิทธิภาพจะสูงกว่าค่าอื่น และจำนวนรอบที่สอนแบบจำลอง(Epochs) ไม่มากเกินไป ทำงานได้ไวขึ้น

จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่ารอบเดิม(Early Stopping : patience) ที่เหมาะสม คือ 40 รอบ เพราะหากใช้ค่า 50 รอบ จะใช้จำนวนรอบในการสอนแบบจำลอง

(Epochs)จำนวนมากแต่ไม่ทำให้ ค่าพื้นที่ใต้กราฟROC เปลี่ยนแปลงดีขึ้นมากนัก แต่หากใช้ค่า 20 รอบ แบบจำลองจะหยุดทำงานถึงแม้ว่าหากทำงานต่อไป แบบจำลองจะมีประสิทธิภาพดีขึ้น

เมื่อมีการใช้เทคนิคการเรียนรู้เชิงลึกจะทำให้แบบจำลองมีประสิทธิภาพดีขึ้น โดยใช้จำนวนรอบในการสอนแบบจำลองน้อยลง โดย แบบจำลองที่ทำให้ระบบมีประสิทธิภาพสูงสุดคือ DenseNet201

หากเปรียบเทียบประสิทธิภาพจาก การใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันและการใช้เทคนิคการเรียนรู้เชิงลึกโดยการนำแบบจำลองที่ถูกสอนแล้วมาใช้งาน จะเห็นได้ว่า การใช้การนำแบบจำลองที่ถูกสอนแล้วแล้วมาใช้งานมีประสิทธิภาพอยู่ที่มากขึ้น ใช้จำนวนรอบในการสอนน้อยลง

5.2 อภิปรายผลการวิจัย

ข้อแนะนำการนำงานวิจัยไปใช้งานจริงและข้อจำกัดการวิจัย

งานวิจัยนี้มีข้อจำกัดคือผลลัพธ์ที่ได้จะเป็นผลลัพธ์จากการทดลองกับชุดข้อมูลนี้เท่านั้น เนื่องจากงานวิจัยนี้เป็นการถ่ายภาพด้วยโทรศัพท์มือถือและทำการหมุนกล้องเพื่อถ่ายภาพมีการถ่ายใกล้และไกล ซึ่งเป็นการทำการเสริมข้อมูล(Data Augmentation) ด้วยมือ (Ambiance Setting) โดยการเสริมข้อมูล(Data Augmentation) คือการนำภาพเดิมสร้างเป็นหลายแบบเพื่อสามารถสอนได้หลายรูปแบบ แต่การถ่ายรูปโดยวัตถุเดิม แต่หลายแบบซึ่งจะมีหลายตัวแปรที่ทำให้ภาพนั้นไม่เป็นภาพเดิมอย่างแท้จริง เช่นการเปลี่ยนมุมจะทำให้ความเข้มแสง และสีในภาพที่ได้แตกต่างกัน หากแบบจำลองไปใช้กับข้อมูลชุดอื่นผลลัพธ์ที่ได้อาจแตกต่างออกไป

งานวิจัยนี้เป็นงานวิจัยเกี่ยวกับการแยกเนื้อวัวและเนื้อหมูซึ่งลักษณะความแตกต่างของเนื้อวัวและเนื้อหมูจะแตกต่างที่ไฟเบอร์และไขมันของชิ้นเนื้อ ดังนั้น สามารถใช้ภาพที่ครอบคลุมเฉพาะชิ้นเนื้อ โดยไม่ต้องใช้ภาพที่ใหญ่มาก เช่นสำหรับงานวิจัยนี้คือภาพขนาด 1000x1000 พิกเซลได้ ทั้งนี้เพื่อลดปัญหาเรื่องพื้นหลังของภาพที่ไม่เหมือนกันอีกด้วย

ผลลัพธ์งานวิจัยนี้คือแบบจำลองที่มีการเรียนรู้อย่างมีประสิทธิภาพ แต่ไม่มีการเปรียบเทียบระหว่างมนุษย์และคอมพิวเตอร์ว่าสิ่งไหนสามารถจำแนกเนื้อวัวเนื้อหมูได้ดีกว่ากัน สำหรับการนำไปใช้ประโยชน์ต่อไปนั้น เราอาจจะนำแบบจำลองที่เหมาะสมมาเป็นส่วนหนึ่งในแอพพลิเคชั่นแยกเนื้อวัวเนื้อหมูในโทรศัพท์มือถือ โดยผู้ใช้งานเปิดแอพพลิเคชั่น แล้วถ่ายรูปเนื้อจากนั้นตัวแอปทำการประมาลผล และส่งผลลัพธ์ออกมาเพื่อแจ้งว่าภาพที่ถ่ายนั้นเป็นภาพเนื้อวัวหรือเนื้อหมู ซึ่งสำหรับแอพพลิเคชั่นเอง จะมีข้อจำกัดในการประมวลผล ซึ่งอาจต้องใช้เวลานาน

และต้องเลือกแบบจำลองที่มีขนาดเล็กที่เป็นแบบจำลองสำหรับโทรศัพท์มือถือเพื่อให้เหมาะสมกับการใช้งานบนโทรศัพท์มือถือ หรือผู้พัฒนาแอพพลิเคชั่นอาจใช้การทำงานบนก้อนเมฆ(Cloud Computing) ซึ่งมีบริการทางด้านการเรียนรู้ด้วยเครื่องให้ด้วย ซึ่งมีข้อดีคือ สามารถใช้ได้ทุกที่ ซึ่งมีอินเทอร์เน็ต ข้อจำกัดอีกข้อคือความเข้มแสง สี ของรูปถ่ายที่ถ่ายมาเพื่อเป็นข้อมูลเข้า อาจไม่เหมือนชุดข้อมูลที่ใช้ในการทดลองนี้ทำให้จำแนกชนิดของเนื้อผิดไป

ตัวอย่างการประยุกต์ใช้งานการจำแนกเนื้อวัว เนื้อหมูอีกตัวอย่างคือสามารถนำไปใช้ในอุตสาหกรรมอาหารสดเช่นในการเตรียมเนื้อวัว เนื้อหมูเพื่อจำหน่าย หากมีการแล่เนื้อเป็นชิ้นๆ และส่งมาทางสายพานเพื่อประกอบลงกล่อง ผู้ใช้งานสามารถติดตั้งกล้องและคอมพิวเตอร์ในการประมวลผล เพื่อจำแนกเนื้อวัวเนื้อหมูได้ โดยกล้องจะทำการรับภาพมาจากสายพาน คอมพิวเตอร์จะรับภาพจากกล้องตัดขอบภาพ และปรับขนาดภาพ ก่อนเข้าประมวลผล รวมทั้งการควบคุมสภาวะแวดล้อมให้คงที่ในการถ่ายภาพ ซึ่งอาจมีข้อจำกัดให้แก้ไข เช่น ความเร็วในการประมวลผลสำหรับการจำแนกชนิดของเนื้อ ซึ่งอาจต้องมีการตั้งค่าระบบคอมให้มีข้อกำหนดสูงในการทำงาน, เลือกขนาดภาพให้เหมาะสม และนำเทคนิคทางด้านคอมพิวเตอร์วิชั่นมาใช้เพิ่มความสามารถในการสอนแบบจำลอง เป็นต้น

5.3 ข้อเสนอแนะ

ควรมีการทำการเสริมข้อมูล(Data Augmentation) โดยการใช้การเขียนคำสั่งในคอมพิวเตอร์ เพื่อลดการเกิดผลกระทบจากปัจจัยต่างๆต่อภาพ และได้ผลเสถียรกว่าการถ่ายรูปเอง เนื่องจากสามารถประยุกต์พารามิเตอร์ต่างๆได้คงที่มากกว่า ซึ่งการเสริมข้อมูล (Data Augmentation) เป็นการสอนภาพเดิมในหลายๆรูปแบบเช่นกลับด้าน หมุนซ้าย หมุนขวา จะช่วยลดการเกิดโอเวอร์ฟิตติ้ง ทำให้แบบจำลองมีประสิทธิภาพดีขึ้น

สำหรับผลการวิจัย อาจใช้เทคนิคแชฟ(SHAP) เพื่อเพิ่มความน่าเชื่อถือในการทำนายผลด้วยปัญญาประดิษฐ์ สามารถอธิบายผลได้ โดยแชฟเป็นวิธีอธิบายแบบจำลองและทำความเข้าใจว่าคุณลักษณะข้อมูลสัมพันธ์กับผลลัพธ์อย่างไร จะเป็นการแสดงว่าพิกเซลไหนมีผลกับการตัดสินใจ ทำให้สามารถวัดปริมาณการมีส่วนร่วมของคุณลักษณะต่อการทำนาย ยิ่งค่าใกล้ศูนย์คือมีส่วนร่วมในการทำนายต่ำ

บรรณานุกรม

Abuzaid, A., และ Atia, A. (2022, 28-30 May 2022). *Exploring and Classifying Beef Retail Cuts Using Transfer Learning.* Paper presented at the 2022 IEEE 9th International Conference on Sciences of Electronics, Technologies of Information and Telecommunications (SETIT).

Aisah, S. A., Setyaningrum, A. H., Wardhani, L. K., และ Bahaweres, R. (2020). *Identifying pork raw-meat based on color and texture extraction using support vector machine.* Paper presented at the 2020 8th International Conference on Cyber and IT Service Management (CITSM).

Al-Sarayreh, M., Reis, M. M., Yan, W. Q., และ Klette, R. (2018, 19-21 Nov. 2018). *Deep Spectral-spatial Features of Snapshot Hyperspectral Images for Red-meat Classification.* Paper presented at the 2018 International Conference on Image and Vision Computing New Zealand (IVCNZ).

Alawi, A. E. B., และ Qasem, A. M. (2021, 4-5 July 2021). *Lightweight CNN-based Models for Masked Face Recognition.* Paper presented at the 2021 International Congress of Advanced Technology and Engineering (ICOTEN).

Alhawas, N., และ Tüfekci, Z. (2022). The Identification of Red-Meat Types using The Fine-Tuned Vision Transformer and MobileNet Models. *European Journal of Science and Technology*.

Altaf, Y., Wahid, A., และ Kirmani, M. M. (2023, 18-19 Feb. 2023). *Deep Learning Approach for Sign Language Recognition Using DenseNet201 with Transfer Learning.* Paper presented at the 2023 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS).

Chairunnisa, J., Muda, T. I., Fikriah, F. K., Pramunendar, R. A., Shidik, G. F., Fanani, A. Z., และ Soeleman, A. (2018). *Pork and Beef Features Extractions.* Paper presented at the 2018 International Seminar on Application for Technology of Information and Communication.

Chanasupaprakit, P., Khusita, N., Chootong, C., Charoensuk, J., Gunarathne, W. K. T., และ Ruengittinun, S. (2022, 22-24 July 2022). *Fake Beef Detection with Machine Learning Technique.* Paper presented at the 2022 IEEE 5th International Conference on Knowledge Innovation and Invention (ICKII).

Ciaburro, G. (2020). Sound Event Detection in Underground Parking Garage Using Convolutional Neural Network. https://www.mdpi.com/2504-2289/4/3/20

Kanjanasurat, I., Domepananakorn, N., Archevapanich, T., และ Purahong, B. (2022, 8-10 June 2022). *Comparison of image enhancement techniques and CNN models for COVID-19 classification using chest x-rays images.* Paper presented at the 2022 8th International Conference on Engineering, Applied Sciences, and Technology (ICEAST).

Kothala, L. P., และ Guntur, S. R. (2022, 23-25 Dec. 2022). *Multi-Class Classification of Intracranial Hemorrhages in a 3-Channel CT image by using a Transfer Learning based DenseNet121 model.* Paper presented at the 2022 International Conference on Smart Generation Computing, Communication and Networking (SMART GENCON).

Muhammadiy, W., และ Fahmi, F. (2016). *Mobile application to differentiate flesh meat between beef and pork.* Paper presented at the 2016 International Conference on Computational Intelligence and Cybernetics.

ProjectPro. (2023). Top 10 Deep Learning Algorithms in Machine Learning [2023]. https://www.projectpro.io/article/deep-learning-algorithms/443

Salsabila, A. F., และ Sartono, B. (2021). Image Classification Modelling of Beef and Pork Using Convolutional Neural Network. *Int. J. Sci. Basic Appl. Res, 57*(2), 26-38.

Shakeri, E., Crump, T., Weis, E., Souza, R., และ Far, B. (2022, 9-11 Aug. 2022). *Using SHAP Analysis to Detect Areas Contributing to Diabetic Retinopathy Detection.* Paper presented at the 2022 IEEE 23rd International Conference on Information Reuse and Integration for Data Science (IRI).

Smith, S. (2023). An Easy Guide to Neuron Anatomy with Diagrams. https://www.healthline.com/health/neurons

Wahid, M. F., Hasan, M. J., และ Alom, M. S. (2019, 26-28 Sept. 2019). *Deep Convolutional Neural Network for Microscopic Bacteria Image Classification.* Paper presented at the 2019 5th International Conference on Advances in Electrical Engineering (ICAEE).

West, M. (2023a). Convolutional Neural Networks : The Theory. https://www.bouvet.no/bouvet-deler/understanding-convolutional-neural-networks-part-1

West, M. (2023b). An Introduction to Deep Learning. https://www.bouvet.no/bouvet-deler/an-introduction-to-deep-learning

Xiao, P., Pang, Y., Feng, H., และ Hao, Y. (2022, 13-16 Dec. 2022). *Optimized MobileNetV2 Based on Model Pruning for Image Classification.* Paper presented at the 2022 IEEE International Conference on Visual Communications and Image Processing (VCIP).

ประวัติผู้เขียน