

การจำแนกเนื้อวัวและเนื้อหมูโดยใช้เทคนิคการเรียนรู้เชิงลึก

ปิยพัทธ์ สมวิฑูร¹, เรืองศักดิ์ ตระกูลพุทธิรักษ์²

บทคัดย่อ

ด้วยความหลากหลายของวัฒนธรรมสังคมไทย บางคนกินเนื้อวัวแต่ไม่กินหมู บางคนกินหมูแต่ไม่กินเนื้อวัว ข้อห้ามเหล่านี้สร้างข้อกำหนดเพื่อให้แน่ใจว่าเนื้อสัตว์ที่กินได้นั้นเหมาะสมที่จะบริโภคได้ การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อสร้างแบบจำลองการเรียนรู้ของเครื่องเพื่อจำแนกเนื้อวัวและเนื้อหมูโดยใช้ภาพเนื้อวัวและเนื้อหมู เราแบ่งข้อมูลออกเป็นชุดข้อมูลการเทรนและการทดสอบ การศึกษาที่ทดสอบความถูกต้องของโมเดลโดยใช้ภาพต้นฉบับขนาด 3000x4000 พิกเซล และ 4000x3000 พิกเซล ทำการครอบตัดรูปภาพจากกึ่งกลางโดยใช้ขนาดครอบตัด 1000x1000 พิกเซล, 2000x2000 พิกเซล และ 3000x3000 พิกเซลตามลำดับ ผลลัพธ์ที่ได้คือขนาดภาพที่มีประสิทธิภาพสูงสุดคือ 3000x3000 พิกเซล เมื่อปรับขนาดภาพเป็น 224x224 พิกเซล อัตราส่วนภาพต้นฉบับจะเปลี่ยนไป แต่สำหรับภาพขนาด 3000x3000 พิกเซล อัตราส่วนภาพจะคงเดิม สำหรับเทคนิคการเรียนรู้เชิงลึก โมเดล DenseNet201 เผยให้เห็นโมเดลที่ดีที่สุดโดยพิจารณาจากประสิทธิภาพและจำนวนรอบการเทรน พื้นที่ใต้กราฟ ROC คือ 0.996

คำสำคัญ : เทคนิคการเรียนรู้เชิงลึก, การเรียนรู้ของเครื่อง

¹ หลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิทยาการข้อมูล คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ กรุงเทพฯ 10110

² คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ กรุงเทพฯ 10110

* Corresponding author: Tel.: 096-7078558 E-mail address: peeyapak.somvittoon@g.swu.ac.th

CLASSIFICATION OF BEEF AND PORK USING DEEP LEARNING TECHNIQUES

Peeyapak Somvitoon^{1*}, Ruangsak Trakunphutthirak²

Abstract

With the variety of Thai social culture, some people consume beef but do not consume pork, while some people consume pork but do not consume beef. These prohibitions create the requirement to ensure that edible meat is proper that they can consume. 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. We crop the image from the center by using the cropping size of 1000x1000 pixels, 2000x2000 pixels and 3000x3000 pixels respectively. The result shows that the most effective image size is 3000x3000 pixels. When resizing an image to 224x224 pixels, the original image's aspect ratio will be changed, but for an image of 3000x3000 pixels, the aspect ratio will remain the same. For deep learning techniques, the DenseNet201 model reveals the best model by considering the performance and the number of epochs. The area under the ROC graph is 0.997.

Keywords : Customer Segmentation, Text Analytics, Machine Learning, Clustering, RFM Technique

¹ Data Science, Faculty of Science, Srinakharinwirot University, Bangkok, 10110, Thailand

² Faculty of Science, Srinakharinwirot University, Bangkok, 10110, Thailand

* Corresponding author: Tel.: 080-5488355 E-mail address: aekpreya.baisani@g.swu.ac.th

บทนำ

เนื้อสัตว์ที่คนนิยมบริโภคในประเทศไทย มี เนื้อหมู, เนื้อไก่, เนื้อปลา, เนื้อวัว และเนื้อเป็ด โดยลักษณะของเนื้อสัตว์ที่คล้ายกันคือ เนื้อวัวและ เนื้อหมู ซึ่งหากคนไม่สังเกต อาจทานผิดได้ โดยเฉพาะตามร้านอาหารที่เป็นลักษณะให้บริการเนื้อหมูหรือเนื้อวัวสไลด์ ทั้งนี้จากวัฒนธรรมทางสังคมทำให้ปรากฏว่า คนไทยบางส่วนบริโภคเนื้อวัว ไม่บริโภคเนื้อหมู และมองว่าเป็นสัตว์สกปรก และมีวัฒนธรรมทางสังคมบางแห่งเช่นกันที่มีคนที่บริโภคเนื้อหมูไม่บริโภคเนื้อวัว หรือแม้กระทั่ง คนที่บริจาคโลหิต โค กระบือ บางคนจะไม่ทานเนื้อวัวอีกเลย เนื่องจากถือว่า ได้ช่วยชีวิตวัวแล้ว จึงไม่ทานเนื้อวัว ซึ่งความเชื่อ หรือข้อห้ามต่างๆเหล่านี้ทำให้เกิดความต้องการที่จะมั่นใจว่า เนื้อที่บริโภคเป็นเนื้อสัตว์ที่คนนั้นๆบริโภคได้ ไม่ต้องการที่จะผลลบบริโภคเนื้อสัตว์ต้องห้ามของตัวเองเข้า ความแตกต่างโดยทั่วไปของเนื้อวัว เนื้อหมู มีหลายคุณลักษณะ คือ สี โดยเนื้อวัวสีจะเข้มกว่าเนื้อหมู, โยของเนื้อ โดยเนื้อวัว โยของเนื้อจะเป็นริ้วตามแนวยาว เนื้อหมู จะมีริ้วน้อย, ไขมัน โดยไขมันวัวจะแข็งกระด้างกว่า แยกออกจากเนื้อ ไขมันหมูจะนุ่มและแยกจากจากเนื้อ, เนื้อสัมผัส เนื้อวัวเหนียวกว่า, กลิ่น เนื้อวัวจะมีกลิ่นคาวของเนื้อ ซึ่งความแตกต่างเหล่านี้หากไม่คุ้นเคยสามารถทำให้เกิดการเข้าใจผิดคิดว่าเนื้อวัว เป็นเนื้อหมู หรือ เนื้อหมูเป็นเนื้อวัวได้

แนวคิงานวิจัยชิ้นนี้เป็นการใช้ภาพเนื้อหมู เนื้อวัว สร้างวิธีการแยกประเภทเนื้อวัวและเนื้อหมูด้วยวิธีการเรียนรู้ของเครื่องจักร (Machine Learning) โดยใช้โครงข่ายประสาทแบบคอนโวลูชัน (CNN) เป็นการนำวิธีการทางวิทยาศาสตร์ข้อมูลมาสร้างระบบการเรียนรู้เพื่อสอนระบบให้สามารถตัดสินใจในการคัดแยกเนื้อวัว เนื้อหมู ได้อย่างมีประสิทธิภาพ โดยใช้งานร่วมกับการปรับ Hyper parameter และการใช้โมเดลที่ถูกเทรนแล้วมาเป็นส่วนประกอบสำหรับการสร้างโมเดล

โดยงานวิจัยชิ้นนี้เป็นลักษณะ การจำแนกแบบไบนารี คือการใช้วิธีการเรียนรู้ของเครื่องจักร เพื่อจำแนกประเภทของเนื้อสัตว์ 2 ประเภท คือ เนื้อวัว และ เนื้อหมู โดยนำข้อมูลรูปภาพมาใช้ในการฝึกฝนระบบ เพื่อสร้างโมเดล และจำแนกผลออกมาเป็น 2 ประเภท จากนั้นทำการทดสอบโดยนำรูปภาพทดสอบกับแบบจำลองที่สร้างขึ้น เพื่อทดสอบค่าความถูกต้องของแบบจำลอง

งานวิจัยที่เกี่ยวข้อง

บทความวิจัยที่เกี่ยวข้องกับการแยกเนื้อวัว และเนื้อหมู นั้น มีตัวอย่างดังต่อไปนี้ Muhammadiy, W., & Fahmi, F. (2016)[1] มีบทความวิจัยเรื่อง “Mobile Application to Differentiate Flesh Meat between Beef and Pork” ซึ่งใช้การประมวลผลภาพดิจิทัลในการวิเคราะห์ที่พื้นผิวร่วมกับโครงข่ายประสาทเทียมเพื่อการตัดสินใจ โดยวิธีการนี้จะถูกนำไปใช้กับโทรศัพท์มือถือเป็นการทำงานแบบเวลาจริง ความแม่นยำในการจำแนกเนื้อวัว เนื้อหมูอยู่ที่ 89% โดยภาพที่ถ่าย ถ่ายจากกล้องสมาร์ทโฟน มีขนาด 8 เมกะพิกเซล ทำการปรับขนาดภาพ ปรับสีเป็นภาพระดับสีเทา ใช้โครงข่ายประสาทเทียม(ANN) ในการสอน โดยซอฟต์แวร์ชื่อ “Neuroph Studio” ซึ่งสร้างเครือข่ายที่มีนามสกุล.nnet และไฟล์นี้จะถูกฝังบนซอฟต์แวร์แอนดรอย ชุดข้อมูลที่ใช้คือภาพเนื้อวัว และเนื้อหมูรวม 50 ภาพ แบ่งเป็นชุดข้อมูลสอน 20ภาพ เป็นภาพเนื้อวัว และเนื้อหมูอย่างละ 10 ภาพ และชุดข้อมูลทดสอบ 30 ภาพ เป็นภาพเนื้อวัว และเนื้อหมูอย่างละ 15 ภาพ มีการเปรียบเทียบประสิทธิภาพจากจำนวนชั้นซ่อน(Hidden Layer) โดยประสิทธิภาพสูงสุดมาจากโมเดลที่มีจำนวนชั้นซ่อน(Hidden Layer) 6ชั้น มีความแม่นยำที่ 89%สำหรับเนื้อวัว และ 89.674% สำหรับเนื้อหมู ต่อมาคืองานวิจัยของ Chairunnisa, J., Muda, T. I., Fikriah, F. K., Pramunendar, R. A., Shidik, G. F., Fanani, A. Z., & Soeleman, A. (2018)[2]. จะพิจารณาสีและพื้นผิวของเนื้อสัตว์ เป็นลักษณะเฉพาะของเนื้อทุกประเภท จึงใช้การพิจารณาเนื้อสัตว์จากรูปภาพโดยการสกัดพื้นผิวตามฮิสโตแกรมและการสกัดคุณสมบัตินี้ (HIS) ผลของการสกัดคุณลักษณะเพื่อนำไป

ประมวลผลโดยใช้วิธีโครงข่ายประสาทเทียม(ANN), SVM และ KNN เพื่อจัดกลุ่มเป็นเนื้อสัตว์ 2 ประเภทคือเนื้อหมูและเนื้อวัว พิจารณาความสำเร็จของการจำแนกนี้โดยใช้เมตริกซ์ความสับสนและความแม่นยำสูงสุด โดยชุดข้อมูลที่ใช้คือภาพ RGB ของเนื้อวัว 40 ภาพ และ เนื้อหมู 40 ภาพ 4032 เปลี่ยนขนาดภาพเป็นภาพขนาด 400 คูณ 400 พิกเซล จากนั้นสร้างภาพ HSI จากการแยกคุณสมบัติสีบนภาพ RGB ออกเป็นภาพ HSI เพื่อให้มี 12 คุณสมบัติของแต่ละภาพ และแยกพื้นผิวฮิสโตแกรม ซึ่งจะมีสร้าง 6 คุณสมบัติพื้นผิวของภาพเนื้อวัวและหมู จากนั้น นำข้อมูลสอนเข้าสู่โมเดลที่ใช้ทดสอบ ซึ่งมี 3 วิธี คือ โครงข่ายประสาทเทียม(ANN), SVM และ KNN ซึ่งวิธีที่ดีที่สุดให้ความแม่นยำ 93.75% โดยใช้ k-fold 20 ด้วยวิธีโครงข่ายประสาทเทียม ถัดมาคือ Aisah, S. A., Setyaningrum, A. H., Wardhani, L. K., & Bahaweres, R. (2020) [3]. จาก “Identifying Pork Raw-Meat Based on Color and Texture Extraction Using Support Vector Machine” เพื่อพิจารณาประสิทธิภาพของ Support Vector Machine (SVM) ในการระบุความแตกต่างระหว่างเนื้อวัวกับเนื้อหมูตามสีและลักษณะเนื้อสัมผัสด้วยการจำลองใน Matlab 2015a การแยกคุณสมบัติสีใช้การแปลง RGB เป็น HSV ซึ่งส่งผลให้เกิดสีสัน ความอิมตัว และค่า การแยกคุณลักษณะพื้นผิวโดยใช้การแปลง Local Binary Pattern (LBP) ผลลัพธ์ของ LBP นี้จะได้รับการประมวลผลโดยการดึงคุณลักษณะทางสถิติอันดับที่หนึ่ง ส่งผลให้เกิดค่าเฉลี่ย เอนโทรปี ความแปรปรวน ความโด่ง และความเบ้ และจาก 8 พารามิเตอร์ของการแยกสีและพื้นผิวจะถูกรวบรวมเป็นอินพุตสำหรับการจัดหมวดหมู่โดยใช้ SVM ความแม่นยำสูงสุดที่ได้จากการวิจัยครั้งนี้คือ 90% โดยใช้ภาพข้อมูลเนื้อวัว เนื้อหมู และหมูป่า ทั้งหมด 30 ภาพ ใช้กล้องจากโทรศัพท์มือถือถ่ายภาพรูปเนื้อสัตว์ ความละเอียด 8เมกะพิกเซล ปรับขนาดภาพเป็น 150 คูณ 150 พิกเซล และเป็น 100 คูณ 100 พิกเซล จากนั้นทำภาพเป็น ภาพHSV และภาพLBP เพื่อใช้ในการแยกคุณลักษณะของคุณสมบัติการแยกสีและคุณสมบัติพื้นผิว การเปรียบเทียบประสิทธิภาพสำหรับงานวิจัยนี้มีการทดสอบภาพอินพุต 4 แบบ คือ ภาพขนาด เป็น 150 คูณ 150 พิกเซล ทำการแยกคุณสมบัตการแยกสีและคุณสมบัติพื้นผิว, ภาพขนาด เป็น 100 คูณ 100 พิกเซล ทำการแยกคุณสมบัตการแยกสีและคุณสมบัติพื้นผิว, ภาพขนาด เป็น 150 คูณ 150 พิกเซล ทำการแยกคุณสมบัตการแยกสี และภาพขนาด เป็น 150 คูณ 150 พิกเซลทำการแยกคุณสมบัตพื้นผิว โดยผลลัพธ์ที่ได้ั้น หากเป็นภาพที่มีการสกัดคุณลักษณะทั้งจากคุณสมบัตการแยกสีและคุณสมบัติพื้นผิว มาเข้าโมเดลSVM จะได้ผลลัพธ์ที่ดีกว่าซึ่งอยู่ที่ 90% และบทความวิจัยถัดมาของ Salsabila, A. F., & Sartono, B. (2021).[4] เรื่อง Image Classification Modelling of Beef and Pork Using Convolutional Neural Network. Int. J. Sci. Basic Appl. Res, 57(2), 26-38. มีวัตถุประสงค์เพื่อการจำแนกภาพที่ดีที่สุดของภาพเนื้อหมูและเนื้อวัว โดยสร้างโมเดล CNN พื้นฐาน และเปรียบเทียบวิธีการทำให้เป็นมาตรฐานหลายวิธี เพื่อเอาชนะอาการโอเวอร์ฟิตติ้ง(overfitting) ชุดข้อมูลที่ใช้คือรูปภาพเนื้อวัว และเนื้อหมู รวม 3,000 ภาพ แบ่งเป็น ข้อมูลสอน 2,550 ภาพ และ ข้อมูลทดสอบ 450 ภาพ วิธีการเป็นการนำรูปภาพเนื้อหมู ขนาด 1536 คูณ 2048 และรูปภาพ เนื้อวัว ขนาด 3024 คูณ 4032 เปลี่ยนขนาดภาพเป็นภาพขนาด 128 คูณ 128 จากนั้นแปลงเป็นภาพขาวดำ และนำข้อมูลเข้าโมเดลCNN พื้นฐาน ซึ่งจะมีการเปรียบเทียบค่าต่างในการใช้ เทคนิค ดรอปเอาท์ (dropout), L2 และ max-norm เพื่อหาวิธีที่เหมาะสมที่สุด ซึ่งผลการวิจัยของบทความนี้ คือความแม่นยำสูงสุด 97.56% จาก โมเดล CNN ที่ใช้เทคนิคดรอปเอาท์ (dropout) p=0.7 และบทความของ Alhawas, N., & Tüfekci, Z. (2022)[5]. ในงานวิจัย “The Identification of Red-Meat Types using The Fine-Tuned Vision Transformer and MobileNet Models” เพื่อใช้เทคนิค ปัญญาประดิษฐ์ขั้นสูงช่วยในการจำแนกเนื้อสัตว์3ประเภท จาก3,000 ภาพ โดยเปรียบเทียบประสิทธิภาพของโมเดล Vision Transformer ViT และ โมเดลMobile Net ในการจำแนกภาพ บนชุดข้อมูลขนาดเล็ก โดยเป็นภาพสี RGB ของ เนื้อวัว เนื้อหมู และเนื้อหมู จำนวนทั้งหมด 365 ภาพ แบ่งเป็น ข้อมูลสอน 335 ภาพ และข้อมูลทดสอบ 30 ภาพ ทำการเปรียบเทียบโมเดล Vision Transformer ViTและ โมเดล MobileNet ด้วยการปรับโมเดล และไม่ปรับโมเดล ผลการวิจัยคือ ทั้งโมเดล Vision Transformer ViTและ โมเดล MobileNet ที่ไม่มี การปรับโมเดล มีการโอเวอร์ฟิตติ้งและไม่ดีในการใช้งานกับข้อมูลทดสอบ เพราะจำนวนข้อมูลมี

จำกัด สำหรับโมเดลที่มีการปรับจูนนั้น โมเดล Vision Transformer ViT มีประสิทธิภาพดีกว่า คือความแม่นยำ 97% แต่ใช้เวลานานกว่า เนื่องจากมีจำนวนพารามิเตอร์ในการสอนมากกว่า

วิธีดำเนินการ


ขั้นตอนที่ 1 : แนะนำชุดข้อมูลที่ใช้ในการศึกษา

การทดลองนี้มีวัตถุประสงค์เพื่อทดลองว่า ภาพลักษณะใด และขนาดภาพเป็นเท่าไร ที่จะทำได้ประสิทธิภาพดีที่สุด หาก ใช้โมเดลเบสเดียวกัน และเมื่อได้ขนาดภาพที่ทำให้ได้ผลลัพธ์ที่มีประสิทธิภาพสูงแล้ว หากเราจะนำไปทดลองต่อกับ Deep Learning Technique อื่น รวมทั้งปรับพารามิเตอร์ต่างๆ ที่ใช้ในการสร้างโมเดล ประสิทธิภาพโมเดลจะเป็นอย่างไร และอะไรที่ทำให้โมเดลมีประสิทธิภาพดียิ่งขึ้น โดยชุดข้อมูลภาพเนื้อวัวและเนื้อหมูในการวิจัยนี้ เป็นการถ่ายรูปโดยใช้กล้องโทรศัพท์มือถือ ขนาดของภาพที่ได้คือ 3000x4000 และ 4000x3000 เรียกว่าภาพต้นแบบ เป็นภาพเนื้อวัวและเนื้อหมูจำนวนอย่างละ 3,519 ภาพ

ขั้นตอนที่ 2 : การนำเข้าข้อมูล ตรวจสอบข้อมูล และพิจารณาข้อมูล

การตัดส่วนของภาพ (Image Cropping)

เมื่อได้ภาพต้นแบบแล้ว จะทำการตัดขอบให้ได้ภาพขนาด 1000x1000, 2000x2000 และ 3000x3000 พิกเซล จากนั้นนำภาพที่ได้ทั้ง 4 ชุด ปรับขนาดภาพเป็น 224 x224 พิกเซล เพื่อทดสอบประสิทธิภาพโมเดล ต่อไป



ภาพประกอบ 1 วิธีการตัดสัดส่วนภาพ

จุดประสงค์คือ ต้องการทราบว่า ภาพชุดข้อมูล แบบใด เหมาะกับการใช้งาน โดยมีตัวเลือกคือ

ภาพต้นฉบับ ที่ถ่ายมาจากโทรศัพท์มือถือ โดยไม่ตัดส่วนภาพ

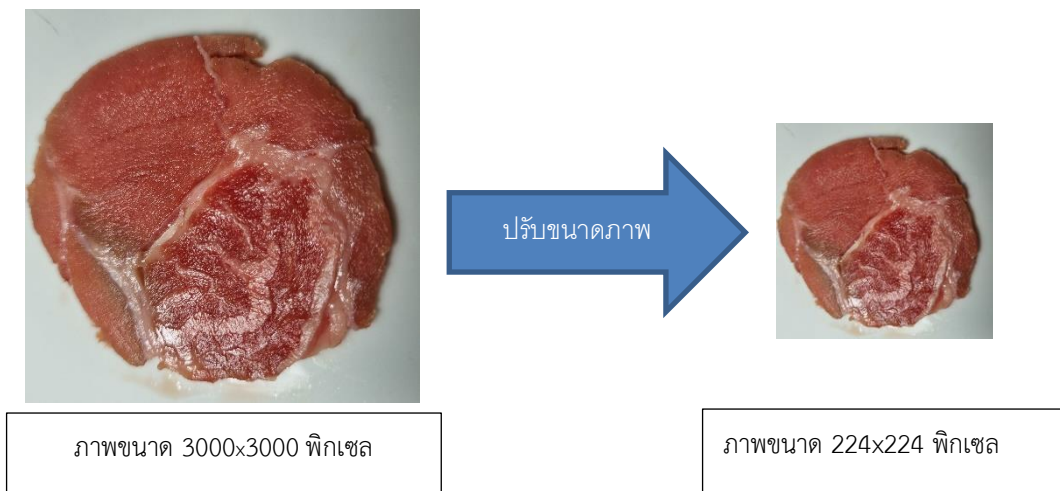
ภาพต้นฉบับแต่ทำเป็นรูปสี่เหลี่ยมจัตุรัส ขนาด 3000x3000 ซึ่งจะมีขอบของภาพ และรายละเอียดของเนื้อสัตว์อยู่มาก

ภาพต้นฉบับแต่ทำเป็นรูปสี่เหลี่ยมจัตุรัส ขนาด 2000x2000 ซึ่งจะมีขอบของภาพ และรายละเอียดของเนื้อสัตว์อยู่ไม่มากนัก หรือ บางภาพจะไม่เห็นขอบของภาพ

ภาพต้นฉบับแต่ทำเป็นรูปสี่เหลี่ยมจัตุรัส ขนาด 1000x1000 ซึ่งภาพส่วนใหญ่ไม่มีขอบของภาพ และองค์ประกอบโดยรวมของภาพ จะเห็นแต่ลักษณะผิว และสี

การปรับขนาดภาพ (Image Resizing)

เมื่อทำการตัดส่วนภาพแล้ว ถัดมาจะเป็นการปรับขนาดภาพชุดข้อมูล เพื่อเตรียมนำชุดข้อมูลนี้เข้ายังโมเดล



ภาพประกอบ 2 การปรับขนาดภาพ

ขั้นตอนที่ 3 : ขั้นตอนการวิจัย

นำภาพขนาด 224x224 ที่เกิดจากการปรับขนาดภาพ เข้าสู่โมเดล เพื่อหาโมเดลที่เหมาะสมในการนำไปใช้งานที่สุด โดยทำการเปรียบเทียบ 2 ขั้นตอน

1. เปรียบเทียบประสิทธิภาพโมเดล CNN ที่เกิดจากการเปลี่ยนไฮเปอร์พารามิเตอร์
 - a. รูปแบบภาพขนาด 224x224 ที่ทำการปรับขนาดมาจากภาพ ต้นฉบับ, 3000x3000, 2000x2000 และ 1000x100 ตามลำดับ
 - b. อัตราการเรียนรู้ โดยแบ่งเป็น 1e-3, 1e-4 และ 1e-5 ตามลำดับ
 - c. จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (easy stopping repetition)แบ่งเป็น 20, 30, 40 และ 50

- d. เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam และ RMSprop
2. เปรียบเทียบประสิทธิภาพโมเดล CNN และ โมเดลจากเทคนิคการเรียนรู้เชิงลึก

ขั้นตอนที่ 5 : การสร้างโมเดล

1. ทดสอบประสิทธิภาพของโมเดลซึ่งเครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam โดยมีข้อมูลรูปภาพขนาด 224x224 พิกเซล ที่ทำการปรับขนาดมาจากภาพ ต้นฉบับขนาด 3000x4000, 3000x3000, 2000x2000 และ 1000x100 พิกเซล มีการทดลองอัตราการเรียนรู้ (learning rate) ค่า 1e-3, 1e-4 และ 1e-5 ตามลำดับ และในแต่ละค่าอัตราการเรียนรู้ (learning rate) มีการปรับ จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (easy stopping repetition) แบ่งเป็น 20, 30, 40 และ 50
2. พิจารณาภาพที่ถูกปรับขนาดมาว่าภาพรูปแบบใด มีประสิทธิภาพสูงสุด ซึ่งงานวิจัยนี้คือภาพที่ถูกปรับขนาดจากภาพขนาด 3000x3000 พิกเซล
3. ทดสอบประสิทธิภาพของโมเดล โดยการใช้ภาพที่ถูกปรับขนาดภาพมาจากภาพขนาด 3000x3000 พิกเซล โดยใช้เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop มีการทดลองอัตราการเรียนรู้ (learning rate) ค่า 1e-3, 1e-4 และ 1e-5 ตามลำดับ และในแต่ละค่าอัตราการเรียนรู้ (learning rate) มีการปรับ จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (easy stopping repetition)แบ่งเป็น 20, 30, 40 และ 50
4. เปรียบเทียบประสิทธิภาพของโมเดลโดยใช้เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด RMSprop โดยมีข้อมูลรูปภาพขนาด 224x224 พิกเซล ที่ทำการปรับขนาดมาจากภาพ ต้นฉบับขนาด 3000x3000, 2000x2000 และ 1000x100 พิกเซล มีการทดลองอัตราการเรียนรู้ (learning rate) ค่า 1e-3, 1e-4 และ 1e-5 ตามลำดับ โดยผู้วิจัยพิจารณาใช้จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (easy stopping repetition) ซึ่งเหมาะสมกับการทำงานของกระบวนการ โดยใช้ประสิทธิภาพที่ดีและไม่ใช้เวลานานเกินไปอยู่ที่ค่า 20 และ 40 รอบ
5. เลือกพารามิเตอร์ที่ทำให้โมเดลมีประสิทธิภาพดี ทดสอบประสิทธิภาพของโมเดลโดยใช้เทคนิคการเรียนรู้เชิงลึก ซึ่งในงานวิจัยนี้เลือก
 - a. เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ (learning rate) ค่า 1e-3,จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (easy stopping repetition) ค่า 20
 - b. เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ (learning rate) ค่า 1e-4,จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (easy stopping repetition) ค่า 20
 - c. เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ (learning rate) ค่า 1e-4,จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (easy stopping repetition) ค่า 40

- d. เครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam, อัตราการเรียนรู้ (learning rate) ค่า $1e-5$, จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (easy stopping repetition) ค่า 20
6. ทดสอบประสิทธิภาพของโมเดลโดยใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้พารามิเตอร์ดังข้อ 5 และชุดข้อมูลจากภาพขนาด 3000×3000 พิกเซล ทำการทดสอบระบบซึ่งใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้โมเดลที่ผ่านการเทรนมาแล้ว (pretrained models) ดังนี้
 - a. Densenet121
 - b. Densenet201
 - c. MobileNetV2
 - d. NASNetMobile
 - e. Xception
 - f. vgg16
 - g. ResNet50V2

ซึ่งโมเดลที่ผ่านการเทรนมาแล้วที่เลือกใช้ จะเป็นโมเดลที่ใช้เวลาคำนวณไม่นานมาก แต่ประสิทธิภาพสูง โดยพิจารณาข้อมูลจาก Keras

7. พิจารณาประสิทธิภาพที่จากข้อ 6 จะเห็นว่า แทบทุกโมเดล จะได้ผลลัพธ์ดี โดยมี Densenet201 ดีกว่าโมเดลอื่นนิดหน่อย จึงทดสอบประสิทธิภาพโดยการใช้ชุดข้อมูลจากภาพขนาด 3000×3000 พิกเซล และ โมเดลที่ผ่านการเทรนมาแล้วชนิด Densenet201 โดยใช้มีการทดลองอัตราการเรียนรู้ (learning rate) ค่า $1e-3$, $1e-4$ และ $1e-5$ ตามลำดับ และในแต่ละค่าอัตราการเรียนรู้ (learning rate) มีการปรับ จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (EarlyStopping : patience) แบ่งเป็น 20, 30, 40 และ 50
8. พิจารณาประสิทธิภาพที่จากข้อ 6 และ ข้อ 7 จะเห็นว่า โมเดลที่ผ่านการเทรนมาแล้ว (pretrained models) โมเดล Densenet121 และ Densenet201 มีประสิทธิภาพสูง และใช้เวลาในการประมวลผลไม่นาน จึงทดสอบโมเดลตามโดยทำพารามิเตอร์ตามข้อ 5 และใช้

ข้อมูลรูปภาพขนาด 224×224 พิกเซล ที่ทำการปรับขนาดมาจากภาพ ต้นฉบับขนาด 3000×3000 , 2000×2000 และ 1000×1000 พิกเซล เพื่อทดสอบประสิทธิภาพของโมเดล

ผลการวิจัยและอภิปรายผลการวิจัย

1. เปรียบเทียบประสิทธิภาพโมเดล CNN ที่เกิดจากการเปลี่ยนไฮเปอร์พารามิเตอร์

เมื่อนำผลการวิจัยมาเปรียบเทียบและแสดงดังรูปด้านล่าง เป็นการเปรียบเทียบ ค่าพื้นที่ใต้กราฟ ROC และเปรียบเทียบค่าความถูกต้อง (Accuracy) สำหรับโมเดล CNN จากการทดสอบประสิทธิภาพของโมเดลซึ่งเครื่องมือเพิ่มประสิทธิภาพ (Optimizer) ชนิด Adam และ RMSprop โดยมีข้อมูลรูปภาพขนาด 224×224 พิกเซล ที่ทำการปรับขนาดมาจากภาพ ต้นฉบับขนาด 3000×4000 , 3000×3000 , 2000×2000 และ 1000×1000 พิกเซล มีการทดลองอัตราการเรียนรู้ (learning rate) ค่า $1e-3$, $1e-4$

และ 1e-5 ตามลำดับ และในแต่ละค่าอัตราการเรียนรู้ (Learning rate) มีการปรับ จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม (easy stopping repetition)แบ่งเป็น 20, 30, 40 และ 50

		ขนาดภาพก่อน กระบวนการปรับ ขนาด	1000x1000	1000x1000	2000x2000	2000x2000	3000x3000	3000x3000	3000x4000	3000x4000
		เครื่องมือเพิ่ม ประสิทธิภาพ (Optimizer)	Adam	RMSprop	Adam	RMSprop	Adam	RMSprop	Adam	RMSprop
ตัวแปรในการวิจัย		ผลลัพธ์การวิจัย								
อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่า ความสูญเสียไม่ ต่ำกว่าเดิม (Early Stopping: patience)	พื้นที่ใต้ กราฟ ROC	พื้นที่ใต้ กราฟ ROC	พื้นที่ใต้ กราฟ ROC	พื้นที่ใต้ กราฟ ROC	พื้นที่ใต้ กราฟ ROC	พื้นที่ใต้ กราฟ ROC	พื้นที่ใต้ กราฟ ROC	พื้นที่ใต้ กราฟ ROC	พื้นที่ใต้ กราฟ 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 3 เปรียบเทียบพื้นที่ใต้กราฟ ROC ในงานวิจัยนี้

	ขนาดภาพก่อน กระบวนการปรับ ขนาด	1000x1000	1000x1000	2000x2000	2000x2000	3000x3000	3000x3000	3000x4000	3000x4000
	เครื่องมือเพิ่ม ประสิทธิภาพ (Optimizer)	Adam	RMSprop	Adam	RMSprop	Adam	RMSprop	Adam	RMSprop
ตัวแปรในการวิจัย		ผลลัพธ์การวิจัย							
อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่า ความสูญเสียไม่ ต่ำกว่าเดิม (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 4 เปรียบเทียบค่าความถูกต้อง(accuracy)ในงานวิจัยนี้

	ขนาดภาพก่อน กระบวนการปรับ ขนาด	1000x1000	1000x1000	2000x2000	2000x2000	3000x3000	3000x3000	3000x4000	3000x4000
	เครื่องมือเพิ่ม ประสิทธิภาพ (Optimizer)	Adam	RMSprop	Adam	RMSprop	Adam	RMSprop	Adam	RMSprop
ส่วนประกอบการวิจัย		ผลลัพธ์การวิจัย							
อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบที่ค่า ความสูญเสียไม่ ต่ำกว่าเดิม (Early Stopping: patience)	จำนวน รอบที่สอน โมเดล (Epochs)	จำนวน รอบที่สอน โมเดล (Epochs)	จำนวนรอบ ที่สอน โมเดล (Epochs)	จำนวนรอบ ที่สอน โมเดล (Epochs)	จำนวนรอบ ที่สอน โมเดล (Epochs)	จำนวนรอบ ที่สอน โมเดล (Epochs)	จำนวนรอบ ที่สอนโมเดล (Epochs)	จำนวนรอบ ที่สอน โมเดล (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 5 เปรียบเทียบจำนวนรอบที่มีการเทรนโมเดล

เมื่อพิจารณาจากการเปรียบเทียบ พื้นที่ใต้กราฟ ROC, ค่าความถูกต้อง(accuracy)และจำนวนรอบที่มีการเทรนโมเดล จะเห็นได้ว่า ภาพ ขนาด 3000x3000 มีค่าพื้นที่ใต้กราฟ ROC และ ค่าความถูกต้อง(accuracy) สูงกว่าจากภาพขนาดอื่น และเมื่อพิจารณา ประสิทธิภาพและความเหมาะสมในการนำไปใช้ จะเห็นได้ว่า ที่ เครื่องมือเพิ่มประสิทธิภาพ คือ Adam, อัตราการเรียนรู้ที่ 1e-3 จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม ค่า 40 และ อัตราการเรียนรู้ที่ 1e-4 จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม ค่า 20

และ 40 มีประสิทธิภาพในการเทรนโมเดลสูง และใช้จำนวนรอบการเทรนไม่สูงมาก ซึ่งจะประหยัดเวลาในการเทรนกว่าการใช้ อัตราการเรียนรู้ที่ 1e-5

2. เปรียบเทียบประสิทธิภาพโมเดล CNN และ โมเดลจากเทคนิคการเรียนรู้เชิงลึก

ใช้เทคนิคการเรียนรู้เชิงลึกในการสร้างโมเดลการเรียนรู้โดยนำโมเดลที่ผ่านการเทรนมาแล้ว (pretrained models) จาก Keras มาใช้งานโดยการวิจัยเป็นการปรับเปลี่ยนเปลี่ยน ขนาดภาพ, อัตราการเรียนรู้, จำนวนรอบที่หยุดคำนวณโมเดล, Optimizer และ โมเดลสำเร็จรูปจาก Keras เพื่อพิจารณาหาพารามิเตอร์ที่เหมาะสมที่สุดกับชุดข้อมูลเนื้อวัวเนื้อหมู ชุดนี้

			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 6 เปรียบเทียบพื้นที่ใต้กราฟ ROC หลังจากใช้เทคนิคการเรียนรู้เชิงลึกกรณีอัตราการเรียนรู้ (learning rate) ค่า 1e-3

			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 7 เปรียบเทียบพื้นที่ใต้กราฟ ROC หลังจากใช้เทคนิคการเรียนรู้เชิงลึกกรณีอัตราการเรียนรู้ (learning rate) ค่า 1e-4

			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 8 เปรียบเทียบพื้นที่ใต้กราฟ ROC หลังจากใช้เทคนิคการเรียนรู้เชิงลึกกรณีอัตราการเรียนรู้ (learning rate) ค่า 1e-5

			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 9 เปรียบเทียบค่าความถูกต้อง(Accuracy) หลังจากใช้เทคนิคการเรียนรู้เชิงลึกกรณีอัตราการเรียนรู้ (learning rate)

ค่า 1e-3

			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 10 เปรียบเทียบค่าความถูกต้อง(Accuracy) หลังจากใช้เทคนิคการเรียนรู้เชิงลึกกรณีอัตราการเรียนรู้(learning rate) ค่า 1e-4

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 11 เปรียบเทียบค่าความถูกต้อง(Accuracy) หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณี อัตราการเรียนรู้ (learning rate) ค่า 1e-5

			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 12 เปรียบเทียบจำนวนรอบที่สอนโมเดล หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณี อัตราการเรียนรู้ (learning rate) ค่า 1e-3

			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 13 เปรียบเทียบจำนวนรอบที่สอนโมเดล หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณี อัตราการเรียนรู้ (learning rate) ค่า 1e-4

			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 14 เปรียบเทียบจำนวนรอบที่สอนโมเดล หลังจากใช้เทคนิคการเรียนรู้เชิงลึก กรณี อัตราการเรียนรู้ (learning rate) ค่า 1e-5

หลังการใช้เทคนิคการเรียนรู้เชิงลึก โดยการใช้ โมเดลที่มีการเทรนแล้วมาใช้งาน จากการเปรียบเทียบ พื้นที่ใต้กราฟ ROC, ค่าความถูกต้อง(accuracy)และจำนวนรอบที่มีการเทรนโมเดล จะเห็นได้ว่าภาพ ขนาด 3000x3000 มีค่าพื้นที่ใต้กราฟ ROC และ ค่าความถูกต้อง(accuracy) สูงกว่าจากภาพขนาดอื่นนิดหน่อย และเมื่อพิจารณาประสิทธิภาพและความเหมาะสมในการนำไปใช้ จะเห็นได้ว่า ที่ เครื่องมือเพิ่มประสิทธิภาพ คือ โมเดลที่เหมาะสมกับชุดข้อมูลในการวิจัยชิ้นนี้คือ Densenet201 อัตราการเรียนรู้ที่ 1e-4 จำนวนรอบที่ค่าความสูญเสียไม่ต่ำกว่าเดิม ค่า 40 มีประสิทธิภาพในการเทรนโมเดลสูง และใช้จำนวนรอบการเทรนไม่สูงมาก ซึ่งจะประหยัดเวลาในการเทรนกว่าการใช้, อัตราการเรียนรู้ที่ 1e-5

สรุปผลการวิจัย

งานวิจัยนี้เป็นการศึกษาวิธีการลักษณะภาพ และพารามิเตอร์ต่างๆ ที่ทำให้การแยกเนื้ออวัยวะ เนื้อหามีประสิทธิภาพ และเหมาะสมกับการใช้งานกับชุดข้อมูลนี้ โดยใช้วิธี 1) ใช้ CNN และปรับพารามิเตอร์ต่างๆ เพื่อดูผลลัพธ์ของภาพแต่ละแบบ 2) ใช้

โมเดลที่มีการเทรนแล้ว เป็นส่วนประกอบในการสร้างโมเดลใหม่ ซึ่งผลการวิจัย พบว่า เมื่อพิจารณารูปแบบภาพที่เมื่อเข้าสู่โมเดลแล้ว ทำให้โมเดลมีประสิทธิภาพสูงสุด คือ ภาพที่เกิดจากการตัดขอบขนาด 3000x3000 เนื่องจากภาพประเภทนี้ สามารถมองเห็นขอบของเนื้อสัตว์ได้ โดยไม่โดนการรบกวนจากภาชนะที่ใส่เนื้อสัตว์, อัตราการเรียนรู้ที่เหมาะสมในการใช้งานคือ $1e-4$ ซึ่งประสิทธิภาพจะสูงกว่าค่าอื่น และจำนวน Epochs ไม่มากเกินไป ทำงานได้ไวขึ้น, จำนวนรอบที่หยุดคำนวณโมเดล คือ 40 รอบ เพราะหากใช้ค่า 50 รอบ จะใช้จำนวนรอบในการเทรนโมเดลจำนวนมากแต่ไม่ทำให้ ค่าพื้นที่ได้กราฟเปลี่ยนแปลงดีขึ้นมากนัก แต่หากใช้ค่า 20 รอบ โมเดลจะหยุดทำงานถึงแม้ว่าหากทำงานต่อไป โมเดลจะมีประสิทธิภาพดีขึ้น, เมื่อมีการใช้เทคนิคการเรียนรู้เชิงลึกจะทำให้โมเดลมีประสิทธิภาพดีขึ้น โดยใช้จำนวนรอบในการเทรนโมเดลน้อยลง โดย โมเดลที่ทำให้ระบบมีประสิทธิภาพสูงสุดคือ DenseNet201, หากเปรียบเทียบประสิทธิภาพจาก การใช้CNN และการใช้เทคนิคการเรียนรู้เชิงลึกโดยการนำโมเดลที่ถูกเทรนแล้ว มาใช้งาน จะเห็นได้ว่า การใช้การนำโมเดลที่ถูกเทรนแล้วแล้วมาใช้งานมีประสิทธิภาพอยู่ที่มากขึ้น ใช้จำนวนรอบในการเทรนน้อยลง

กิตติกรรมประกาศ

การจัดทำวิจัยได้รับการสนับสนุนจากบัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ ในการนำเสนอผลงานวิจัย ผู้วิจัยจึงขอขอบคุณมา ณ ที่นี้

เอกสารอ้างอิง

- [1] Muhammadiy, W., & 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.
- [2] Chairunnisa, J., Muda, T. I., Fikriah, F. K., Pramunendar, R. A., Shidik, G. F., Fanani, A. Z., & Soeleman, A. (2018). Pork and Beef Features Extractions. Paper presented at the 2018 International Seminar on Application for Technology of Information and Communication.
- [3] Aisah, S. A., Setyaningrum, A. H., Wardhani, L. K., & 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).
- [4] Salsabila, A. F., & Sartono, B. (2021). Image Classification Modelling of Beef and Pork Using Convolutional Neural Network. *Int. J. Sci. Basic Appl. Res.*, 57(2), 26-38.
- [5] Alhawas, N., & Tüfekçi, Z. (2022). The Identification of Red-Meat Types using The Fine-Tuned Vision Transformer and MobileNet Models. *European Journal of Science and Technology*. doi:10.31590/ejosat.1112892