

## การจำแนกคุณภาพของเมล็ดกาแฟโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ

ชาคริต เสรีพงษ์<sup>1\*</sup>, นุรีย์ วิวัฒน์วัฒนา<sup>2</sup>

### บทคัดย่อ

เมล็ดกาแฟมีข้อบกพร่องต่าง ๆ หลายแบบที่ต้องจำแนกออกจากเมล็ดกาแฟแบบปกติในการนำไปจำหน่ายและบริโภค วัตถุประสงค์ของงานวิจัยนี้คือการพัฒนาแบบจำลองที่ใช้การเรียนรู้เชิงลึกโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการโดยเปรียบเทียบกับแบบจำลองที่ใช้การเรียนรู้ด้วยเครื่องแบบดั้งเดิม เพื่อจำแนกคุณภาพของเมล็ดกาแฟที่มีข้อบกพร่องทั้ง 5 ชนิดได้แก่ เมล็ดดำ เมล็ดขึ้นรา ขึ้นเมล็ดแตก เมล็ดไม่สมบูรณ์ และเมล็ดถูกแมลงทำลาย ออกจากเมล็ดกาแฟแบบปกติ โดยได้ใช้ข้อมูลรูปภาพเมล็ดกาแฟมาจากการวิจัยเรื่อง การสกัดและคัดเลือกคุณลักษณะของเมล็ดกาแฟเพื่อจำแนกประเภทตามคุณภาพด้วยการประมวลผลภาพถ่าย มาสร้างแบบจำลองต่าง ๆ ได้แก่ ResNet50, ResNet101, ResNet50 โดยใช้เทคนิคการเพิ่มข้อมูลรูปภาพ ResNet101 โดยใช้เทคนิคการเพิ่มข้อมูลรูปภาพ และ SGDClassifier โดยใช้เทคนิคการเพิ่มข้อมูลรูปภาพ ซึ่งจากการวัดผลด้วยชุดข้อมูลทดสอบได้ค่าความแม่นยำ (Accuracy) อยู่ที่ 0.74, 0.75, 0.77, 0.74 และ 0.61 ตามลำดับ เห็นได้ชัดว่าแบบจำลองที่ใช้สถาปัตยกรรมแบบ ResNet ให้ผลลัพธ์ที่ดีกว่า SGDClassifier ซึ่งเป็นการเรียนรู้ด้วยเครื่องแบบดั้งเดิม

**คำสำคัญ** : การเรียนรู้เชิงลึก, การเรียนรู้ด้วยเครื่อง, โครงข่ายประสาทเทียมแบบสังวัตนาการ, การจำแนกคุณภาพเมล็ดกาแฟ

<sup>1</sup> หลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิทยาการข้อมูล คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ กรุงเทพฯ 10110

<sup>2</sup> คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ กรุงเทพฯ 10110

\* Corresponding author: Tel.: 083-0609475 E-mail address: chakrit.ser@g.swu.ac.th

## Coffee Bean Quality Classification using Convolutional Neural Network

Chakrit Sereepong<sup>1\*</sup>, Nuwee Wiwatwattana<sup>2</sup>

### Abstract

Coffee beans include a variety of defects that must be removed before they can be processed for sale and consumption. The goal of this study is to develop deep learning-based models using convolutional neural networks and compare them to a traditional machine learning-based model for classifying five different types of defective coffee bean images: black, moldy, broken, incomplete, and bitten out of green coffee beans. The models were built using coffee bean images from previous research on "Coffee Beans Feature Extraction and Selection for Quality Classification Using Image Processing," which included ResNet50, ResNet101, ResNet50 with data augmentation, ResNet101 with data augmentation, and SGDClassifier with data augmentation. According to the test dataset, the accuracy was 0.74, 0.75, 0.77, 0.74, and 0.61. ResNet architecture models based on deep learning clearly outperformed SGDClassifier, a typical machine learning model.

**Keywords** : Deep Learning, Machine Learning, ResNet, Concolutional Neural Network, Coffee Beans Quality Classification

---

<sup>1</sup> Data Science, Faculty of Science, Srinakharinwirot University, Bangkok, 10110, Thailand

<sup>2</sup> Faculty of Science, Srinakharinwirot University, Bangkok, 10110, Thailand

\* Corresponding author: Tel.: 083-0609475 E-mail address: chakrit.ser@g.swu.ac.th

## บทนำ

เมล็ดกาแฟเป็นสินค้าเกษตรที่ประเทศไทยมีศักยภาพในการผลิตและมีแนวโน้มในการส่งออกเพิ่มขึ้น ดังนั้น เพื่อให้การผลิตเมล็ดกาแฟของไทยเป็นที่ยอมรับมากขึ้นในระดับชาติ และนานาชาติ สร้างความปลอดภัยให้กับผู้บริโภคและส่งเสริมการส่งออกคณะกรรมการมาตรฐานสินค้าเกษตรจึงได้มีการจัดทำมาตรฐานการปฏิบัติทางการเกษตรที่ดีสำหรับกาแฟขึ้น ซึ่งสามารถตรวจสอบรายละเอียดได้จากมาตรฐานสินค้าเกษตร มกษ. 5903-2553 หัวข้อการปฏิบัติทางการเกษตรที่ดีสำหรับกาแฟ [1] และจากมาตรฐานสินค้าเกษตร มกษ. 5701-2561 หัวข้อเมล็ดกาแฟอะราบิกา [2] ได้มีการกำหนดนิยามข้อบกพร่องของเมล็ดกาแฟทั้งหมด 8 ชนิด ซึ่งการคัดแยกข้อบกพร่องเหล่านี้จัดการด้วยขั้นตอนปกติที่ใช้มนุษย์ในการคัดแยกนั้นอาจใช้เวลามากในการคัดแยกเมล็ดกาแฟจากข้อบกพร่องต่าง ๆ ออกจากเมล็ดกาแฟแบบปกติ และไม่สามารถรู้ได้ว่าจำนวนเมล็ดกาแฟที่คัดแยกมานั้นมีข้อผิดพลาดมากเท่าใด

ในงานวิจัยนี้ผู้วิจัยเล็งเห็นถึงความสำคัญของกาแฟ และเห็นถึงปัญหาของกระบวนการคัดแยกตามข้อบกพร่องแต่ละชนิดดังข้างต้น ประกอบกับปัจจุบันนี้มีความรู้เรื่องโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) ซึ่งเป็นกระบวนการที่สามารถนำไปใช้เพื่อแก้ปัญหาการรับรู้ภาพเป็นอย่างดีซึ่งผู้วิจัยได้นำรูปภาพเมล็ดกาแฟแต่ละประเภทมาใช้ และสนใจที่จะนำความรู้เรื่องการเรียนรู้เชิงลึก (Deep Learning) มาใช้แทนที่จะใช้การเรียนรู้ด้วยเครื่อง (Machine Learning) แบบอื่น เนื่องจากการเรียนรู้เชิงลึกนั้นเป็นองค์ความรู้ที่มีความนิยมและมีการใช้งานอย่างแพร่หลายในสมัยนี้ อีกทั้งการเรียนรู้เชิงลึกยังช่วยลดเวลาในการปรับเปลี่ยนข้อมูลหรือการจัดการกับคุณลักษณะต่างๆของข้อมูลลง เพราะวิธีการนี้ไม่มีความจำเป็นที่จะต้องจัดการหรือเปลี่ยนแปลงตัวข้อมูลมาก และยังให้ผลลัพธ์ที่ดีถ้านำมาใช้กับปัญหาที่มีความซับซ้อนสูง จากข้อดีที่พบข้างต้น ทางผู้วิจัยจึงได้จัดทำแบบจำลองการทำนายเพื่อคัดแยกเมล็ดกาแฟแบบอัตโนมัติขึ้นโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ ที่มีโครงสร้างแบบ Residual Network ซึ่งเป็นที่นิยม และมีประสิทธิภาพที่ดีมากในปัจจุบัน โดยจะคัดแยกเมล็ดกาแฟแบบปกติและเมล็ดกาแฟตามนิยามความบกพร่อง 5 ชนิดจากทั้งหมด 8 ชนิด ได้แก่ เมล็ดดำ เมล็ดขึ้นรา ขึ้นเมล็ดแตก เมล็ดไม่สมบูรณ์ และเมล็ดถูกแมลงทำลาย โดยภายในงานวิจัยได้มีการนำการเรียนรู้ด้วยเครื่องแบบดั้งเดิมมาเปรียบเทียบกับการเรียนรู้เชิงลึกด้วย เพื่อเปรียบเทียบประสิทธิภาพกัน

## งานวิจัยที่เกี่ยวข้อง

บทความวิจัยที่ใช้โครงข่ายประสาทเทียมแบบสังวัตนาการมาแก้ปัญหาานั้น มีตัวอย่างดังต่อไปนี้ Huang และคณะ [3] ได้ทำการศึกษาวิธีการสร้างแบบจำลองการทำนายโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ เพื่อจำแนกประเภทของเมล็ดกาแฟซึ่งมีการใช้การประมวลผลรูปภาพ และเทคโนโลยี Data Augmentation เพื่อจัดการกับข้อมูลและใช้ใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ เพื่อวิเคราะห์ข้อมูลรูปภาพ ซึ่งผู้วิจัยได้ทำการคิดค้นรูปแบบของแบบจำลองขึ้นมาเอง และขั้นตอนสุดท้ายคือนำแบบจำลองการทำนายที่ได้ไปใช้กับ Webcam เพื่อประมวลผลรูปภาพที่ผ่านเข้ามา ซึ่งโครงข่ายประสาทเทียมแบบสังวัตนาการทำงานได้ดีกับการแยกสี และรูปร่างของภาพ และสามารถแยกเมล็ดกาแฟที่ดีและไม่ดีได้โดยง่าย โดยมีค่า False Positive Rate ที่ 0.1007 และให้ค่า Accuracy โดยประมาณอยู่ที่ 93.34 เปอร์เซ็นต์ ซึ่งประโยชน์ที่ได้รับจากงานนี้จะช่วยลดเวลาในการคัดเลือกเมล็ด

กาแฟ และใช้เวลาในการสร้างเมตริกภาพชนิดพิเศษให้มากขึ้นได้ บทความวิจัยถัดไป Walleign และคณะ [4] ได้ทำการศึกษาเรื่องการแบ่งแยกคุณภาพของเมตริกภาพด้วยข้อมูลตัวอย่างที่น้อยและมีความแปรปรวนสูง โดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการเพื่อสร้างแบบจำลองการทำนายซึ่งได้มีการทำ Pre-Processing กับข้อมูลเพื่อลดคุณสมบัติที่ไม่เกี่ยวข้องออกแต่ก็ไม่ได้ช่วยให้แบบจำลองการทำนายมีประสิทธิภาพที่ดีขึ้น และได้มีการใช้ Ensemble Methods เพื่อมาช่วยลดปัญหาเรื่องความแปรปรวนและจำนวนข้อมูลตัวอย่างที่น้อย ขั้นตอนสุดท้ายคือทำการเทรนแบบจำลองการทำนายด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ ซึ่งทางผู้วิจัยนั้นได้มีการใช้ VGG ซึ่งเป็นแบบจำลองที่สร้างมาก่อนแล้ว (Pre-trained Model) โดยตัดขั้นสุดท้ายจากชั้น Fully Connected ออก และได้ทำการออกแบบแบบจำลองขึ้นมาเองเพื่อนำมาเปรียบเทียบกับแบบจำลองของ VGG ซึ่งใช้เค้าโครงมาจากโมเดลนี้ และออกแบบเพิ่มเติมขึ้นมา และได้ค่าความแม่นยำในการจำแนกเมตริกภาพอยู่ที่ 89 เปอร์เซ็นต์ ซึ่งมีผลลัพธ์ของค่า Accuracy ต่ำกว่าสถาปัตยกรรม VGG ที่มีค่า Accuracy อยู่ในช่วง 70 – 73 เปอร์เซ็นต์เท่านั้น นอกจากนี้ยังแสดงให้เห็นว่าโครงข่ายประสาทเทียมแบบสังวัตนาการ สามารถแบ่งแยกคุณสมบัติและจำแนกข้อมูลได้ดีมากโดยที่ไม่ใช้เวลาไปทำขั้นตอน Preprocessing มากนัก บทความวิจัยถัดไป Pinto และคณะ [5] ได้ศึกษาการสร้างระบบคัดแยกกาแฟสำหรับผู้ผลิตในประเทศติมอร์-เลสเต จากจุดบกพร่องของเมตริกภาพโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการในการสร้างแบบจำลองการทำนาย และได้มีการออกแบบแบบจำลองขึ้นมาเอง มีการแบ่งข้อมูลตามชนิดของเมตริกภาพเพื่อนำมาใช้ทำนายกับแบบจำลองแยกกัน ซึ่งได้ค่า Accuracy สูงสุดถึง 98.7 เปอร์เซ็นต์ ในการคัดแยกชนิดเมล็ดแบบเมล็ดดำ และ 92.93 เปอร์เซ็นต์ ในการคัดแยกชนิดเมล็ดแบบเมล็ดเปรี้ยว และเมตริกภาพแบบอื่นก็ได้ Accuracy น้อยลงมาอย่างเห็นได้ชัด เนื่องจากเมื่อเทียบกับเมตริกภาพแบบดำ และเมตริกภาพแบบเปรี้ยว แล้ว เมตริกภาพชนิดอื่น ข้อมูลของรูปจะไม่ค่อยมีเอกลักษณ์เท่าไร เมื่อเทียบกับเมตริกภาพแบบดำและแบบเปรี้ยว บทความวิจัยถัดไป Hong Son และคณะ [6] ได้สร้างวิธีการคัดแยกคุณภาพของข้าว โดยใช้การประมวลผลรูปภาพ (Image Processing) และการเรียนรู้ด้วยเครื่อง (Machine Learning) ในการจดจำและแบ่งแยกข้าวเป็น 2 ประเภท คือ ข้าวดีและข้าวเสีย ซึ่งอยู่บนพื้นฐานของขนาดของข้าวแบบมาตรฐานที่บ่งบอกได้ถึงคุณภาพของข้าว โดยใช้ โครงข่ายประสาทเทียมแบบสังวัตนาการ และได้ใช้ Support Vector Machines โดยใช้กับคุณสมบัติ HOG (SVM-HOG) และ K-Nearest Neighbors (KNN) ในการนำมาคัดแยกข้าวและนำมาเปรียบเทียบประสิทธิภาพกัน โดยแบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ จะมีค่า Accuracy อยู่ที่ 89.75 เปอร์เซ็นต์ ซึ่งมีค่ามากกว่าวิธีการที่ใช้ SVM-HOG ที่มีค่า Accuracy อยู่ที่ 85.06 เปอร์เซ็นต์ และมากกว่าวิธีการที่ใช้ KNN ที่มีค่า Accuracy อยู่ที่ 84.33 0เปอร์เซ็นต์ ซึ่งแสดงให้เห็นว่าการคัดแยก และวัดคุณภาพข้าวก็สามารถทำได้โดยใช้วิธีการแบบ Deep Learning ได้ดีเช่นกัน

## วิธีดำเนินการ

### 1. สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบสังวัตนาการที่ใช้

ตารางที่ 1 แสดงโครงสร้างของสถาปัตยกรรมของโครงข่ายประสาทเทียมแบบสังวัตนาการที่ใช้ในการสร้างแบบจำลอง ได้แก่ ResNet50 และ ResNet101 ซึ่งบล็อกแต่ละบล็อกของทั้ง 2 สถาปัตยกรรมนั้นจะมีลักษณะเหมือนกัน แต่ใน Layer ต่างๆนั้น จะมีจำนวนของบล็อกไม่เท่ากัน ได้แก่ Layer Conv\_3x ของ ResNet50 นั้นจะมีบล็อกเพียง 3 ชุด ส่วน ResNet101 นั้นมี 4 ชุด และ Layer Conv\_5x ของ Resnet50 นั้นมีบล็อกเพียง 3 ชุด ส่วน ResNet101 นั้นมีถึง 23 ชุด โดย Layer สุดท้ายได้ทำการแก้ไข ให้ Output นั้นเหลือเพียง 6 รูปแบบซึ่งคือเมล็ดกาแฟทั้ง 6 ชนิดที่เราคัดแยก


ตารางที่ 1 สถาปัตยกรรม ResNet50, ResNet101 ที่ใช้ในงานวิจัย

Layer Name	Output Size	50-Layer	101-Layer
Conv1	112 x 112	7 x 7, 64, Stride 2	
Conv2_x	56 x 56	3 x 3 Max Pool, Stride 2	
		$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
Conv3_x	28 x 28	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$
Conv4_x	14 x 14	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$
Conv5_x	7 x 7	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1 x 1	Average Pool, 6-d fc, Softmax	

### 2. การสำรวจข้อมูล

ข้อมูลรูปภาพประกอบไปด้วยรูปภาพของเมล็ดกาแฟปกติ (Green) และเมล็ดกาแฟที่มีความบกพร่องทั้ง 5 ประเภทซึ่ง ได้แก่ เมล็ดดำ (Black) เมล็ดขึ้นรา (Moldy) เมล็ดไม่สมบูรณ์ (Incomplete) ขึ้นเมล็ดแตก (Broken) และเมล็ดถูกแมลงทำลาย

(Bitten) โดยตัวอย่างเมล็ดแสดงในรูปที่ 1 ซึ่งข้อมูลของรูปภาพนั้นได้ทำการนำแสงเงาออกไปเรียบร้อยแล้ว โดยข้อมูลต้นฉบับนั้นมีจำนวนรูปภาพทั้งหมด 5,696 รูป โดยภาพประกอบ 23 แสดงถึงสัดส่วนรูปภาพเมล็ดกาแฟแต่ละชนิดซึ่งประกอบไปด้วย เมล็ดถูกแมลงทำลาย 700 รูป เมล็ดดำ 1,002 รูป ขึ้นเมล็ดแตก 781 รูป เมล็ดขึ้นรา 944 รูป เมล็ดไม่สมบูรณ์ 969 รูป และ เมล็ดปกติ 1,300 รูป



รูปที่ 1 ตัวอย่างเมล็ดกาแฟทั้ง 6 ชนิด

### 3. การเตรียมข้อมูล

ผู้วิจัยได้ทำการแบ่งข้อมูลเป็น 3 ส่วนซึ่งประกอบไปด้วย

1. ข้อมูลสำหรับนำมาสร้างแบบจำลองการทำนาย โดยมีทั้งหมด 3,988 รูป ซึ่งประกอบไปด้วย เมล็ดถูกแมลงทำลาย 490 รูป เมล็ดดำ 702 รูป ขึ้นเมล็ดแตก 546 รูป เมล็ดขึ้นรา 661 รูป เมล็ดไม่สมบูรณ์ 679 รูป และ เมล็ดปกติ 910 รูป
2. ข้อมูลสำหรับนำมาสร้างแบบจำลองการทำนาย ที่ใช้เทคนิคการเพิ่มข้อมูลรูปภาพเพิ่มเติมโดยการกลับภาพแล้ว โดยมีทั้งหมด 7,976 รูป ซึ่งได้เพิ่มข้อมูลทุกเมล็ดเป็น 2 เท่า โดยจะมีจำนวนของแต่ละเมล็ดคือ เมล็ดถูกแมลงทำลาย 980 รูป เมล็ดดำ 1,404 รูป ขึ้นเมล็ดแตก 1,092 รูป เมล็ดขึ้นรา 1,322 รูป เมล็ดไม่สมบูรณ์ 1,358 รูป และเมล็ดปกติ 1,820 รูป
3. ข้อมูลที่เก็บไว้สำหรับนำมาทดสอบกับแบบจำลองการทำนาย โดยมีทั้งหมด 1,708 รูป ซึ่งประกอบไปด้วย เมล็ดปกติ 390 รูป เมล็ดดำ 300 รูป เมล็ดขึ้นรา 283 รูป เมล็ดไม่สมบูรณ์ 290 รูป ขึ้นเมล็ดแตก 235 รูป และเมล็ดถูกแมลงทำลาย 210 รูป

#### 4. การสร้างแบบจำลอง

ผู้วิจัยได้สร้างแบบจำลองการทำนายทั้งหมด 5 แบบจำลอง ซึ่งคือแบบจำลองที่ใช้การเรียนรู้เชิงลึกโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) มีทั้งหมด 4 แบบจำลองซึ่งเป็นแบบจำลองแบบ Pre-Train ทั้งหมด ได้แก่

1. สถาปัตยกรรมแบบ ResNet50
2. สถาปัตยกรรมแบบ ResNet101
3. สถาปัตยกรรมแบบ ResNet50 โดยการใช้การปรับแต่งเพื่อเพิ่มข้อมูลของรูปภาพ
4. สถาปัตยกรรมแบบ ResNet101 โดยการใช้การปรับแต่งเพื่อเพิ่มข้อมูลของรูปภาพ

ซึ่งชั้นของผลลัพธ์ได้แบ่งเป็น 6 Class ตามชนิดของเมล็ดกาแฟ ปรับขนาดรูปภาพเป็นขนาด 224 × 224 พิกเซล จากเดิมที่ชุดข้อมูลรูปภาพมีหลายขนาด ซึ่งขึ้นอยู่กับแต่ละรูปที่ทำการเก็บข้อมูลมาจากแหล่งข้อมูล โดยใช้ Max Pooling ในการย่อรูปภาพ ใช้ค่า Weight จากค่าที่มีการเรียนรู้มาก่อนหน้านี้แล้วจากชุดข้อมูลของ Image-Net และใช้ Activation Function ของชั้น Output เป็น Softmax Function ซึ่งในการสร้างแบบจำลองและวัดผลนั้นได้มีการแบ่งชุดข้อมูลเพื่อทำการ Validation ไว้ 30 เปอร์เซ็นต์ในแต่ละรอบของการเทรน ซึ่งกำหนดไว้ทั้งหมด 30 รอบ และได้กำหนด Batch Size ไว้เป็นจำนวน 32 ดังตารางที่ 2

ตารางที่ 2 พารามิเตอร์ที่ใช้ในการสร้างแบบจำลองที่ใช้การเรียนรู้เชิงลึกโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ

Parameter	Value
Pooling	Max Pooling
Weight	ImageNet
Activation for Output Layer	Softmax
Batch Size	32

อีกแบบจำลองนอกจากการใช้การเรียนรู้เชิงลึกแล้ว ผู้วิจัยได้ใช้แบบจำลองของ SGDClassifier โดยการใช้การปรับแต่งเพื่อเพิ่มข้อมูลของรูปภาพ โดยเป็นการเรียนรู้ด้วยเครื่องแบบดั้งเดิม โดยตั้งค่าพารามิเตอร์ของ Histogram of Oriented Gradients ไว้ดังตารางที่ 3 โดยในส่วนของ SGDClassifier นั้นได้ใช้ค่าของพารามิเตอร์เป็นค่าตั้งต้นของไลบรารี Scikit-Learn ทั้งหมด

## ตารางที่ 3 พารามิเตอร์ที่ใช้ในการทำ Histogram of Oriented Gradients

Parameter	Value
Orientations	8
Cells per Block	(3,3)
Pixels per Cell	(8,8)

## 5. การวัดผลของแบบจำลอง

การวัดผลของแบบจำลองใช้ค่าประมาณของ Precision, Recall, F1-Score และ Accuracy ในการวัดผลกับทั้ง 5 แบบจำลอง โดยมีการคำนวณค่า Weight Average ของค่า Precision, Recall และ F1-Score ด้วย

## ผลการวิจัยและอภิปรายผลการวิจัย

## 1. สถาปัตยกรรมแบบ ResNet50

ตารางที่ 4 แสดงการวัดผลของแบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบสังวัตนาการโดยใช้สถาปัตยกรรมแบบ ResNet50 ด้วยค่าประมาณ Precision, Recall, F1 และ Accuracy ที่วัดผลจากชุดข้อมูลทดสอบโดยแสดงในตารางที่ 4 ซึ่งจากผลลัพธ์ของชั้นเมลิตแตก เมลิตขึ้นรา และเมลิตถูกแมลงทำลายนั้นมีค่าประมาณบางที่ค่าน้อยมากอย่างเห็นได้ชัด โดยเฉพาะชั้น เมลิตแตกและเมลิตขึ้นรา ที่ได้ค่าประมาณทุกค่าเกือบต่ำกว่า 0.50 ทุกค่า ซึ่งอาจจะเป็นเพราะข้อมูลในการเรียนรู้มีน้อยในการนำไปสร้างแบบจำลอง หรืออาจจะเพราะคุณลักษณะของข้อมูลไม่มีคุณลักษณะเด่นเหมือนกับเมลิตอื่น

## 2. สถาปัตยกรรมแบบ ResNet101

ตารางที่ 5 แสดงการวัดผลของแบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบสังวัตนาการโดยใช้สถาปัตยกรรมแบบ ResNet101 ด้วยค่าประมาณ Precision, Recall, F1 และ Accuracy ที่วัดผลจากชุดข้อมูลทดสอบ ซึ่งจากผลลัพธ์นั้นชั้นเมลิตแตก เมลิตขึ้นรา และเมลิตถูกแมลงทำลายนั้นมีค่าประมาณบางที่ค่าน้อยมากอย่างเห็นได้ชัด โดยเฉพาะชั้นเมลิตแตกและเมลิตขึ้นรา ที่ได้ค่าประมาณทุกค่าเกือบต่ำกว่า 0.50 ทุกค่า ซึ่งลักษณะคล้ายกับแบบจำลองของ ResNet50



ตารางที่ 4 คะแนนการวัดผลจากแบบจำลองของ  
สถาปัตยกรรมแบบ ResNet50 ด้วยชุดข้อมูลทดสอบ

Type	Precision	Recall	F1-Score	Accuracy
Bitten	0.64	0.92	0.76	
Black	0.93	0.99	0.96	
Broken	0.38	0.45	0.41	
Moldy	0.91	0.86	0.89	
Incomplete	0.53	0.29	0.38	
Green	0.89	0.87	0.88	
				0.74
<b>Weighted avg</b>	0.74	0.74	0.73	

ตารางที่ 5 คะแนนการวัดผลจากแบบจำลองของ  
สถาปัตยกรรมแบบ ResNet101 ด้วยชุดข้อมูลทดสอบ

Type	Precision	Recall	F1-Score	Accuracy
Bitten	0.74	0.83	0.78	
Black	0.98	0.96	0.97	
Broken	0.41	0.49	0.45	
Moldy	0.84	0.93	0.88	
Incomplete	0.57	0.24	0.34	
Green	0.79	0.92	0.85	
				0.75
<b>Weighted avg</b>	0.73	0.75	0.73	

### 3. สถาปัตยกรรมแบบ ResNet50 โดยใช้การปรับแต่งเพื่อเพิ่มข้อมูลของรูปภาพ

ตารางที่ 6 แสดงการวัดผลของแบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ โดยใช้สถาปัตยกรรมแบบ ResNet50 โดยใช้การปรับแต่งเพื่อเพิ่มข้อมูลของรูปภาพ ด้วยค่าประมาณ Precision, Recall, F1 และ Accuracy ที่วัดผลจากชุดข้อมูลทดสอบ ซึ่งจากผลลัพธ์นั้นทั้งชิ้นเมสิดแตกและเมสิดไม่สมบูรณ์นั้นได้ค่าค่อนข้างต่ำกว่าเมสิดอื่นอย่างเห็นได้ชัด แม้ว่าการสร้างแบบจำลองมีการเพิ่มข้อมูลของแต่ละเมสิดแล้ว แต่เมสิดอื่นมีค่าประมาณหลายค่าในแต่ละเมสิดดีขึ้นจากเดิมเมื่อเทียบกับสถาปัตยกรรมแบบ ResNet50 ที่ไม่ได้ใช้การปรับแต่งเพื่อเพิ่มข้อมูลของรูปภาพ

#### 4. สถาปัตยกรรมแบบ ResNet101 โดยใช้ในการปรับแต่งเพื่อเพิ่มข้อมูลของรูปภาพ

ตารางที่ 7 แสดงการวัดผลของแบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบสังวัตนาการโดยใช้สถาปัตยกรรมแบบ ResNet101 โดยใช้ในการปรับแต่งเพื่อเพิ่มข้อมูลของรูปภาพ ด้วยค่าประมาณ Precision, Recall, F1 และ Accuracy ที่วัดผลจากชุดข้อมูลทดสอบ ซึ่งจากผลลัพธ์นั้นได้ค่าประมาณที่คล้ายกับแบบจำลองอื่นก่อนหน้า คือขึ้นเมล็ดแตก และเมล็ดไม่สมบูรณ์ได้ค่าประมาณที่น้อยอย่างเห็นได้ชัดแม้มีการเพิ่มข้อมูลในการสร้างแบบจำลองแล้ว ส่วนเมล็ดที่เหลือนั้นก็ยังมีค่าประมาณหลายค่าที่มีค่าสูงมากขึ้นเมื่อเทียบกับ สถาปัตยกรรมแบบ ResNet101 ที่ไม่ได้ใช้ในการปรับแต่งเพื่อเพิ่มข้อมูลของรูปภาพ

ตารางที่ 6 คะแนนการวัดผลจากแบบจำลองของ  
สถาปัตยกรรมแบบ ResNet50 โดยใช้ในการปรับแต่งเพื่อเพิ่ม  
ข้อมูลของรูปภาพด้วยชุดข้อมูลทดสอบ

Type	Precision	Recall	F1-Score	Accuracy
Bitten	0.82	0.81	0.81	
Black	0.97	0.99	0.98	
Broken	0.42	0.48	0.45	
Moldy	0.87	0.93	0.90	
Incomplete	0.51	0.42	0.46	
Green	0.89	0.89	0.89	
				0.77
<b>Weighted avg</b>	0.76	0.77	0.76	

ตารางที่ 7 คะแนนการวัดผลจากแบบจำลองของ  
สถาปัตยกรรมแบบ ResNet101 โดยใช้ในการปรับแต่งเพื่อเพิ่ม  
ข้อมูลของรูปภาพด้วยชุดข้อมูลทดสอบ

Type	Precision	Recall	F1-Score	Accuracy
Bitten	0.81	0.82	0.82	
Black	0.98	0.98	0.98	
Broken	0.36	0.59	0.44	
Moldy	0.96	0.84	0.89	
Incomplete	0.50	0.39	0.44	
Green	0.93	0.80	0.86	
				0.74
<b>Weighted avg</b>	0.78	0.74	0.75	

## 5. SGDClassifier โดยการใช้การปรับแต่งเพื่อเพิ่มข้อมูลของรูปภาพ

ตารางที่ 8 แสดงการวัดผลของแบบจำลอง SGDClassifier โดยการใช้การปรับแต่งเพื่อเพิ่มข้อมูลของรูปภาพ โดยวัดผลด้วยค่าประมาณ Precision, Recall, F1 และ Accuracy ที่วัดผลจากชุดข้อมูลทดสอบที่ได้ทำการแบ่งไว้แล้ว ซึ่งจากผลลัพธ์นั้นค่าประมาณทุกค่าของทุกเมตริกได้ค่อนข้างต่ำอย่างเห็นได้ชัด ยกเว้นเมตริกค่ากับเมตริกขึ้นราที่ยังให้ค่าประมาณแต่ละค่าอยู่ในเกณฑ์ที่ดี โดยหากเปรียบเทียบกับผลการวัดผลจากข้อมูลที่ใช้เรียนรู้แบบจำลองนั้นจะสังเกตเห็นว่าแบบจำลองมีความ Overfit อย่างมาก และผลลัพธ์นั้นแยกว่าอย่างเห็นได้ชัด หากนำไปเปรียบเทียบกับแบบจำลองที่ใช้การเรียนรู้เชิงลึกด้วยเครือข่ายประสาทเทียมแบบสังวัตนาการที่ได้สร้างไว้ก่อนหน้านี้

ตารางที่ 8 คะแนนการวัดผลจากแบบจำลอง SGDClassifier โดยการใช้การปรับแต่งเพื่อเพิ่มข้อมูลของรูปภาพด้วยชุดข้อมูลทดสอบ

Type	Precision	Recall	F1-Score	Accuracy
Bitten	0.54	0.51	0.53	
Black	0.83	0.96	0.89	
Broken	0.24	0.29	0.26	
Moldy	0.82	0.75	0.78	
Incomplete	0.40	0.33	0.36	
Green	0.68	0.67	0.68	
				0.61
Weighted avg	0.61	0.61	0.60	

### สรุปผลการวิจัย

จากผลลัพธ์ของค่าประมาณ Precision, Recall, F1 และ Accuracy ของแบบจำลองทั้ง 5 แบบจำลองที่ผู้วิจัยได้สร้างมานั้น จะสังเกตเห็นว่าชั้นเมตริกแตกและเมตริกไม่สมบูรณ์นั้นให้ผลลัพธ์ค่อนข้างต่ำกว่าเมตริกอื่นอย่างมากในทุกแบบจำลองที่ได้ทำการ

วัดผลมา ซึ่งผู้วิจัยคาดว่าน่าจะเป็นเพราะคุณลักษณะของตัวข้อมูลรูปภาพที่นำมาใช้สร้างแบบจำลอง ไม่มีคุณลักษณะที่โดดเด่นที่ชัดเจน ซึ่งตัวชั้นเมล็ดแตกค่อนข้างมีลักษณะคล้ายคลึงกับเมล็ดไม่สมบูรณ์ ทำให้การทำนายได้ผลลัพธ์ไม่ดีเท่าที่ควร โดยมีการทำนายผิดกันเองระหว่าง 2 เมล็ดนี้ และเห็นได้ชัดว่าแบบจำลอง SGDClassifier โดยการใช้การปรับแต่งเพื่อเพิ่มข้อมูลรูปภาพนั้นให้ผลลัพธ์ที่น้อยกว่าแบบจำลองอื่นที่ใช้การเรียนรู้เชิงลึกอย่างมีนัยสำคัญ ซึ่งนอกเหนือจากนั้นแบบจำลองอื่นที่ใช้การเรียนรู้เชิงลึกโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการจากสถาปัตยกรรมของ ResNet นั้นไม่ว่าจะเป็น ResNet50 หรือ ResNet101 ซึ่งใช้การปรับแต่งเพื่อเพิ่มข้อมูลรูปภาพหรือไม่นั้น ก็ให้ผลลัพธ์ที่ดีที่สุดในการจำแนกเมล็ดกาแฟแต่ละเมล็ดแตกต่างกันออกไป ไม่ได้มีแบบจำลองใดโดดเด่นกว่าแบบจำลองอื่นเป็นพิเศษ เพียงแต่แบบจำลองที่ใช้การปรับแต่งเพื่อเพิ่มข้อมูลรูปภาพมีแนวโน้มของ Overfit น้อยกว่าแบบจำลองที่ไม่ได้มีการใช้การปรับแต่งเพื่อเพิ่มข้อมูลรูปภาพ แม้ว่าแบบจำลอง ResNet101 ให้ค่า Accuracy ที่สูงกว่าแบบจำลอง ResNet101 ที่ใช้การปรับแต่งเพื่อเพิ่มข้อมูลรูปภาพ แต่ค่าประมาณอื่นของ ResNet101 ที่ใช้การปรับแต่งเพื่อเพิ่มข้อมูลรูปภาพนั้นก็ยังมีแนวโน้มของค่าประมาณหลายค่าที่ยิ่งขึ้นโดยสังเกตได้จากค่า F1-Score ที่มีค่าสูงขึ้นจากเดิม เราจึงไม่ควรวัดผลจากค่าประมาณ Accuracy เพียงค่าเดียวเพราะไม่สามารถสะท้อนประสิทธิภาพทั้งหมดของแบบจำลองได้ และแบบจำลองที่ให้ค่า Accuracy สูงที่สุดและค่าประมาณอื่นอยู่ในเกณฑ์ที่ดีคือแบบจำลองที่ใช้ ResNet50 โดยการใช้การปรับแต่งเพื่อเพิ่มข้อมูลรูปภาพ ซึ่งจากผลลัพธ์นั้นสามารถอธิบายได้ว่าจำนวนชั้นของสถาปัตยกรรมที่มากขึ้นอาจจะไม่มีความจำเป็นสำหรับโจทย์ในการคัดแยกประเภทของเมล็ดกาแฟที่ตัวรูปภาพได้ทำการลบแสงเงาออกแล้ว และหากใช้สถาปัตยกรรมที่มีชั้นของโครงข่ายมากเกินไปอาจจะทำให้มีความ Overfit ของแบบจำลองเพิ่มมากขึ้น ดังนั้นหากต้องการที่นำแบบจำลองใดไปใช้งานจริง ผู้วิจัยจะเลือกแบบจำลองของ ResNet50 ที่ใช้การปรับแต่งเพื่อเพิ่มข้อมูลรูปภาพแล้วเพื่อความเสถียรที่มากที่สุดของผลลัพธ์

### เอกสารอ้างอิง

- [1] การปฏิบัติทางการเกษตรที่ดีสำหรับกาแฟ. (2010). มาตรฐานสินค้าเกษตร มกษ. 5903-2553.
- [2] กระทรวงเกษตรและสหกรณ์, ส. (2018). มาตรฐานสินค้าเกษตร มกษ. 5701-2561  
[https://www.acfs.go.th/standard/download/Arabica\\_coffee\\_bean\\_2561.pdf](https://www.acfs.go.th/standard/download/Arabica_coffee_bean_2561.pdf).
- [3] Huang, N. F., Chou, D. L., & Lee, C. A. (2019). Real-Time Classification of Green Coffee Beans by Using a Convolutional Neural Network.
- [4] Wallelign, S., Polceanu, M., Jemal, T., & Buche, C. (2019). Coffee Grading with Convolutional Neural Networks using Small Datasets with High Variance. Journal of WSCG, 27(2).
- [5] Pinto, C., Furukawa, J., Fukai, H., & Tamura, S. (2017). Classification of Green coffee bean images base on defect types using convolutional neural network (CNN).
- [6] Hong Son, N., & Thai-Nghe, N. (2019). Deep Learning for Rice Quality Classification. Paper presented at the 2019 International Conference on Advanced Computing and Applications (ACOMP).