

การจำแนกสถานการณ์ไฟป่าโดยใช้การเรียนรู้เชิงลึก

FOREST WILDFIRE CLASSIFICATION USING DEEP LEARNING



การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูลและการวิเคราะห์
ศูนย์วิเคราะห์ข้อมูลอัจฉริยะพระจอมเกล้าลาดกระบัง คณะวิทยาศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2568

KMITL-2025-SC-M-017-024

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

FOREST WILDFIRE CLASSIFICATION USING DEEP LEARNING



PUWANAI TANKUE

AN INDEPENDENT STUDY SUBMITTED IN PARTIAL FULFILLMENT OF THE
REQUIREMENT FOR THE DEGREE OF MASTER OF SCIENCE IN
DATA SCIENCE AND ANALYTICS

KMITL-DIGITAL ANALYTICS AND INTELLIGENCE CENTER SCHOOL OF SCIENCE KING
MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

2025

KMITL-2025-SC-M-017-024

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2025

SCHOOL OF SCIENCE

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Independent Study Title	Forest Wildfire Classification Using Deep Learning
Student Name	Puwanai Tankue
Student ID	63605072
Degree	Master of Science (Data Science and Analytics) KMITL-Digital Analytics and Intelligence Center
Year	2025
Independent Study Advisor	Asst.Prof.Dr. Warangkhan Kimpan

Abstract

This research aims to develop a model for classifying wildfire situations from images, with the objective of providing decision-making support for wildfire control planning. Additionally, it seeks to propose guidelines for decision-making in wildfire prevention and management. The model development utilizes Artificial Neural Network techniques, analyzing a dataset consisting of three image groups: non-fire images, fire images that are not wildfires, and wildfire images.

The research findings indicate that the Artificial Neural Network model effectively predicts wildfires. The best-performing model in this study is ResNet152V2, which achieved an accuracy of 92.75%. Furthermore, Precision, Recall, and F1-Score are within a satisfactory range. A web application has also been developed to facilitate users in obtaining wildfire detection information more conveniently.

Keywords : deep learning, neural network, wildfires, images

กิตติกรรมประกาศ

การค้นคว้าอิสระฉบับนี้สำเร็จอย่างสมบูรณ์ได้ โดยได้รับความอนุเคราะห์จาก ผศ.ดร.วรางคณา กิมปาน อาจารย์ที่ปรึกษา ผู้ที่ให้คำปรึกษาในการพัฒนาตรวจสอบและแก้ไข ข้อบกพร่องอันเป็นประโยชน์อย่างยิ่งต่อการค้นคว้าอิสระฉบับนี้ ผู้วิจัยขอกราบขอบพระคุณและขอ จารึกพระคุณนี้ไว้ในความทรงจำอย่างมีฐิติว่าความสำเร็จในครั้งนี้นี้เกิดขึ้นได้ด้วยความกรุณาจากท่าน อาจารย์

ท้ายที่สุดนี้หวังว่าการค้นคว้าอิสระฉบับนี้จะมีประโยชน์แก่ผู้ที่สนใจจะศึกษาในขั้นต่อไป และขอขอบคุณประโยชน์อันเกิดจากการค้นคว้าอิสระฉบับนี้ให้แด่บิดา มารดา ที่ให้กำเนิดและเลี้ยงดู ให้การศึกษา ตลอดจนครูบาอาจารย์และผู้ที่มีพระคุณทุกท่านที่มีส่วนในการวางรากฐานการศึกษา ให้แก่ผู้วิจัย

ภูวนัย ทันเกื้อ



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ

	หน้า
บทคัดย่อ	ก
Abstract	ข
กิตติกรรมประกาศ	ค
สารบัญ	ง
สารบัญตาราง	ฉ
สารบัญรูป	ช
บทที่ 1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของงานวิจัย	2
1.3 ขอบเขตงานวิจัย	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ	3
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	4
2.1 ความรู้เกี่ยวกับการเรียนรู้เชิงลึก	4
2.2 การประเมินประสิทธิภาพ	19
2.3 เครื่องมือที่ใช้ในงานวิจัย	22
2.4 งานวิจัยที่เกี่ยวข้อง	24
บทที่ 3 วิธีการดำเนินงานวิจัย	27
3.1 ข้อมูลที่ใช้ในงานวิจัย (Dataset Collection)	27
3.2 การเตรียมข้อมูล (Dataset Pre-Processing)	29
3.3 ขั้นตอนการฝึกฝนและทดสอบโมเดล (Training & Testing Model)	30
3.4 ขั้นตอนการพัฒนาเว็บแอปพลิเคชัน (Web Application Development)	30

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ (ต่อ)

	หน้า
บทที่ 4 ผลการวิจัยและการอภิปรายผล	32
4.1 ผลลัพธ์การทำนายโดยใช้ ResNet152V2	33
4.2 ผลลัพธ์การทำนายโดยใช้ ResNet101	35
4.3 ผลลัพธ์การทำนายโดยใช้ ResNet152	37
4.4 ผลลัพธ์การทำนายโดยใช้ DenseNet169	39
4.5 ผลลัพธ์การทำนายโดยใช้ DenseNet121	41
4.6 ผลลัพธ์การทำนายโดยใช้ DenseNet201	43
4.7 ผลลัพธ์การทำนายโดยใช้ MobileNetV2	45
4.8 ผลลัพธ์การทำนายโดยใช้ MobileNetV3Small	47
4.9 ผลลัพธ์การทำนายโดยใช้ MobileNetV3Large	49
4.10 ผลลัพธ์การทำนายโดยใช้ EfficientNetV2S	51
4.11 ผลลัพธ์การทำนายโดยใช้ EfficientNetV2L	53
4.12 ผลลัพธ์การทำนายโดยใช้ EfficientNetV2M	55
4.13 วิธีการใช้งานบนเว็บแอปพลิเคชันสามารถอธิบายได้ดังนี้	57
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ	63
5.1 สรุปผลการวิจัย	63
5.2 ข้อจำกัด	64
5.3 ข้อเสนอแนะ	64
เอกสารอ้างอิง	65
ภาคผนวก	67
ชุดตัวอย่างข้อมูลที่ใช้ในงานวิจัย (Dataset)	68
ประวัติผู้เขียน	72

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

ตารางที่	หน้า
3.1 Hyperparameter	30
4.1 สรุปผลการดำเนินงานวิจัย	32
4.2 สรุปผลโมเดลที่นำไปพัฒนาเป็นเว็บแอปพลิเคชัน	57
4.3 สรุปผลการทำนายของชุดข้อมูลเพิ่มเติมสำหรับเว็บแอปพลิเคชัน	60
4.4 สรุปผลลัพธ์การทำนายเว็บแอปพลิเคชันของแต่ละโมเดล	62



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป

รูปที่	หน้า
2.1 เทคนิคการเรียนรู้ของเครื่องจักร	5
2.2 สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบคอนโวลูชัน	8
2.3 ลักษณะของ Filter	9
2.4 ลักษณะของ Stride	9
2.5 ลักษณะของ Stride	10
2.6 ลักษณะของ Padding	11
2.7 ลักษณะของ Max Pooling	12
2.8 สถาปัตยกรรมการทำงานของ ResNet	13
2.9 สถาปัตยกรรมการทำงานของ DenseNet	14
2.10 สถาปัตยกรรมการทำงานของ MobileNet	16
2.11 สถาปัตยกรรมการทำงานของ EfficientNet	17
3.1 แผนผังการทำงานของงานวิจัย	27
3.2 ข้อมูลที่ใช้ในงานวิจัย	28
3.3 ชุดตัวอย่างข้อมูลที่ใช้ในงานวิจัย	28
3.4 วิธีการปรับแก้ขนาดของภาพ	29
3.5 วิธีการทำ Data Augmentation	29
4.1 ผลลัพธ์การทำนายของโมเดล ResNet152V2	33
4.2 ตาราง Confusion Matrix ของโมเดล ResNet152V2	33
4.3 กราฟสรุปผลของโมเดล ResNet152V2	34
4.4 ผลลัพธ์การทำนายของโมเดล ResNet101	35
4.5 ตาราง Confusion Matrix ของโมเดล ResNet101	35
4.6 กราฟสรุปผลของโมเดล ResNet101	36
4.7 ผลลัพธ์การทำนายของโมเดล ResNet152	37
4.8 ตาราง Confusion Matrix ของโมเดล ResNet152	37
4.9 กราฟสรุปผลของโมเดล ResNet152	38
4.10 ผลลัพธ์การทำนายของโมเดล DenseNet169	39
4.11 ตาราง Confusion Matrix ของโมเดล DenseNet169	39
4.12 กราฟสรุปผลของโมเดล DenseNet169	40
4.13 ผลลัพธ์การทำนายของโมเดล DenseNet121	41

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.14 ตาราง Confusion Matrix ของโมเดล DenseNet121	41
4.15 กราฟสรุปผลของโมเดล DenseNet121	42
4.16 ผลลัพธ์การทำนายของโมเดล DenseNet201	43
4.17 ตาราง Confusion Matrix ของโมเดล DenseNet201	43
4.18 กราฟสรุปผลของโมเดล DenseNet201	44
4.19 ผลลัพธ์การทำนายของโมเดล MobileNetV2	45
4.20 ตาราง Confusion Matrix ของโมเดล MobileNetV2	45
4.21 กราฟสรุปผลของโมเดล MobileNetV2	46
4.22 ผลลัพธ์การทำนายของโมเดล MobileNetV3Small	47
4.23 ตาราง Confusion Matrix ของโมเดล MobileNetV3Small	47
4.24 กราฟสรุปผลของโมเดล MobileNetV3Small	48
4.25 ผลลัพธ์การทำนายของโมเดล MobileNetV3Large	49
4.26 ตาราง Confusion Matrix ของโมเดล MobileNetV3Large	49
4.27 กราฟสรุปผลของโมเดล MobileNetV3Large	50
4.28 ผลลัพธ์การทำนายของโมเดล EfficientNetV2S	51
4.29 ตาราง Confusion Matrix ของโมเดล EfficientNetV2S	51
4.30 กราฟสรุปผลของโมเดล EfficientNetV2S	52
4.31 ผลลัพธ์การทำนายของโมเดล EfficientNetV2L	53
4.32 ตาราง Confusion Matrix ของโมเดล EfficientNetV2L	53
4.33 กราฟสรุปผลของโมเดล EfficientNetV2L	54
4.34 ผลลัพธ์การทำนายของโมเดล EfficientNetV2M	55
4.35 ตาราง Confusion Matrix ของโมเดล EfficientNetV2M	55
4.36 กราฟสรุปผลของโมเดล EfficientNetV2M	56
4.37 เลือกโมเดลที่ต้องการใช้ทำนายของเว็บแอปพลิเคชัน	57
4.38 การอัปโหลดรูปภาพของเว็บแอปพลิเคชัน	57
4.39 ผลลัพธ์เว็บแอปพลิเคชันในการทำนายไฟฟ้า	58
4.40 ผลลัพธ์เว็บแอปพลิเคชันของกลุ่มไม่มีไฟไหม้	58
4.41 ผลลัพธ์เว็บแอปพลิเคชันของกลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟฟ้า	59
4.42 ผลลัพธ์เว็บแอปพลิเคชันของกลุ่มที่เป็นไฟฟ้า	59

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญญรูป (ต่อ)

รูปที่	หน้า
ก.1 กลุ่มที่ไม่มีไฟไหม้	69
ก.2 กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า	70
ก.3 กลุ่มที่เป็นไฟป่า	71



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ไฟป่าเป็นภัยธรรมชาติที่ส่งผลกระทบต่อระบบนิเวศและสิ่งแวดล้อมในหลายพื้นที่ทั่วโลก โดยเฉพาะในเขตป่าฝนเขตร้อนที่มีสภาพอากาศแห้งแล้ง การเกิดไฟป่ามักมีปัจจัยหลายประการ ไม่ว่าจะเป็นสภาพอากาศที่ร้อนจัด การกระทำของมนุษย์ในการเผาป่า หรือการเกิดฟ้าผ่า ผลกระทบจากไฟป่ามีทั้งทางตรงและทางอ้อม เช่น การทำลายทรัพยากรธรรมชาติ ความเสียหายทางเศรษฐกิจ และการเพิ่มขึ้นของมลพิษในอากาศ ซึ่งส่งผลกระทบต่อสุขภาพของประชาชน งานวิจัยนี้จึงมีความสำคัญในการศึกษาปัจจัยที่ทำให้เกิดไฟป่า การประเมินผลกระทบจากไฟป่า และการพัฒนากลยุทธ์ในการป้องกันและฟื้นฟูสิ่งแวดล้อมหลังจากไฟป่าลุกลาม

สำหรับประเทศไทยเพื่อให้เหมาะสมกับสภาพปัญหาและขอบเขตการจัดการไฟป่า จึงกำหนดคำนิยามของไฟป่าว่า “ไฟที่เกิดจากสาเหตุใดก็ตาม แล้วลุกลามไปได้โดยอิสระปราศจากการควบคุม ทั้งนี้ไม่ว่าไฟนั้นจะเกิดขึ้นในป่าธรรมชาติหรือสวนป่า” [1]

การแบ่งชนิดของไฟป่าที่ได้รับการยอมรับและใช้กันมาช้านานนั้น ถือเอาการไหม้เชื้อเพลิงในระดับต่างๆ ในแนวตั้ง ตั้งแต่ระดับพื้นดินขึ้นไปจนถึงระดับยอดไม้เป็นเกณฑ์การแบ่งชนิดไฟป่าตามเกณฑ์ดังกล่าวทำให้สามารถแบ่งไฟป่าออกเป็น 3 ชนิด คือ ไฟใต้ดิน ไฟผิวดิน และไฟเรือนยอด

ไฟป่าอาจเกิดขึ้นตามธรรมชาติหรือเกิดจากมนุษย์ ซึ่งสาเหตุของไฟป่าที่เกิดขึ้นเองตามธรรมชาติเกิดขึ้นได้จากหลายสาเหตุ เช่น ฟ้าผ่า ภูเขาไฟระเบิด กิ่งไม้เสียดสีกัน ก้อนหินกระทบกัน แสงแดดตกกระทบผลึกหิน การลุกไหม้ ในตัวเองของสิ่งมีชีวิต ส่วนสาเหตุที่เกิดจากมนุษย์ส่วนใหญ่เกิดขึ้นทั้งด้วยความตั้งใจ และความรู้เท่าไม่ถึงการณ์ซึ่งมีสาเหตุของการเกิดไฟป่า เช่น เก็บหาของป่า เผาไร่ แกล้งจุด ความประมาท ล่าสัตว์ เลี้ยงปศุสัตว์ และความคึกคะนอง

ไฟป่าในประเทศไทยมักเกิดขึ้นทุกปีในหน้าแล้ง ไฟป่ามักจะเกิดตั้งแต่เดือนพฤศจิกายนถึงเดือนกรกฎาคมในปีถัดไป ไฟป่าเกิดมากที่สุดในเดือนกุมภาพันธ์และช่วงเวลาที่เกิดไฟป่ามากที่สุดคือ 10.00 ถึง 16.00 นาฬิกา ไฟป่ามักเกิดในป่าเบญจพรรณ ป่าเต็งรัง ป่าสน พุ่มหญ้าในไร่ร้าง และสวนป่าต่างๆ ไฟป่าในประเทศไทยมักเผาไหม้ออกเป็นหย่อมๆ ไม่เผาไหม้ติดต่อกันเป็นผืนใหญ่เหมือนในต่างประเทศ ไฟป่าในประเทศไทยส่วนใหญ่เป็นชนิดไฟผิวดิน ไม่ค่อยรุนแรงมาก เพราะอยู่ในเขตร้อน มีมรสุมพัดผ่าน มีความชื้นสัมพัทธ์สูง และเชื้อเพลิงส่วนใหญ่ มีสารน้ำมันน้อย

การพัฒนาของเทคโนโลยีทำให้โลกเปลี่ยนแปลงไปอย่างรวดเร็ว โดยเฉพาะอย่างยิ่งเทคโนโลยีเข้ามามีบทบาทกับอุตสาหกรรมการผลิต หรือธุรกิจเพิ่มมากขึ้น จึงทำให้ต้องอาศัยเทคโนโลยีที่ทันสมัยอย่างข้อมูลขนาดใหญ่ (Big Data) และปัญญาประดิษฐ์ (Artificial Intelligence:

AI) เข้ามาช่วยอำนวยความสะดวก ซึ่งข้อมูลขนาดใหญ่ คือระบบที่มีการรวบรวมข้อมูลจำนวนมาก เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ การใช้งานเพื่อการศึกษาเท่านั้น เมื่อเผยแพร่ให้คนอื่นไปใช้โดยไม่ได้รับอนุญาตถือว่าผิดกฎหมาย ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดลอกเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

มากมายมหาศาล ตัวอย่างเช่น ไฟล์เอกสาร ไฟล์ภาพ วิดีโอ เป็นต้น เพื่อนำเอาข้อมูลเหล่านี้ไปวิเคราะห์ เรียกว่า Big Data Analytics และการจะนำข้อมูลเหล่านี้มาวิเคราะห์จนเกิดเป็นความรู้ ความเข้าใจ และนำความรู้หรือข้อเท็จจริงที่ได้มาพัฒนาต่อยอด หรือใช้ให้เกิดประโยชน์จำเป็นต้องอาศัยเทคโนโลยีที่เรียกว่า AI ในการวิเคราะห์ ซึ่งก่อนจะมี AI ได้ต้องอาศัยส่วนสมองอย่างการเรียนรู้ของเครื่อง (Machine Learning: ML) ที่จะทำการเรียนรู้จากข้อมูลที่ถูกรวบรวมมาจากข้อมูลขนาดใหญ่ และส่งผลออกมาเป็นชุดข้อมูลหรือโมเดล โดยอาศัยอัลกอริทึมในการประมวลผล

ในงานวิจัยนี้ จึงนำเสนอแนวทางการใช้เทคโนโลยี Convolutional Neural Network (CNN) ซึ่งเหมาะสำหรับงานประมวลผลภาพ เพราะสามารถดึงคุณลักษณะสำคัญจากภาพได้โดยอัตโนมัติ เช่น ขอบ รูปทรง และลวดลาย โดยไม่ต้องสร้างฟีเจอร์เอง ทำให้แม่นยำและมีประสิทธิภาพมากขึ้นในการรู้จำภาพหรือวัตถุ เป็นอัลกอริทึมที่ใช้ในการสร้างโมเดลเพื่อจำแนกวัตถุที่มีความผิดปกติจากภาพถ่าย เพื่อประเมินสถานการณ์ไฟฟ้าเบื้องต้น และสามารถทำการแก้ไขปัญหาในพื้นที่ที่เกิดไฟฟ้าได้อย่างทันท่วงที ซึ่งจะช่วยในการป้องกันและลดความเสียหายที่อาจเกิดขึ้นจากไฟฟ้าได้อย่างมีประสิทธิภาพ

1.2 วัตถุประสงค์ของงานวิจัย

1. ได้อัลกอริทึมในการสร้างโมเดลจำแนกไฟไหม้ที่มีความผิดปกติจากภาพถ่าย โดยแบ่งเป็น 3 ประเภท คือ กลุ่มที่ไม่มีไฟไหม้ กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟฟ้า และกลุ่มที่เป็นไฟฟ้า
2. เพื่อนำเสนอแนวทางในการนำโมเดลจำแนกไฟไหม้ไปใช้งานเป็นแอปพลิเคชันตรวจจับไฟฟ้าจากรูปภาพ

1.3 ขอบเขตงานวิจัย

1. งานวิจัยนี้ได้เลือกใช้เทคนิคของกลุ่ม Convolutional Neural Network (CNN) และใช้ร่วมกับ Transfer Learning เป็นตัวช่วยในการวิเคราะห์ ประกอบด้วย
 - 1) กลุ่มของ ResNet ประกอบด้วย ResNet101, ResNet152 และ ResNet152V2
 - 2) กลุ่มของ DenseNet ประกอบด้วย DenseNet121, DenseNet169 และ DenseNet201
 - 3) กลุ่มของ MobileNet ประกอบด้วย MobileNetV2, MobileNetV3Small และ MobileNetV3Large
 - 4) กลุ่มของ EfficientNet ประกอบด้วย EfficientNetV2S, EfficientNetV2M และ EfficientNetV2L
2. งานวิจัยนี้ได้เลือกใช้ชุดข้อมูลไฟฟ้า Fire Detection

(<https://universe.roboflow.com/fire-dataset-tp9jt>) และ The Wildfire Dataset (<https://www.kaggle.com/datasets/elmadafri/the-wildfire-dataset>) มาทำการ

วิเคราะห์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. งานวิจัยนี้ได้เลือกใช้เครื่องมือการเขียนโปรแกรมโดยใช้ภาษา Python และ React.js

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1. ได้อัลกอริทึมสามารถจำแนกไฟป่าได้
2. ได้มีแอปพลิเคชันตั้งต้นในการนำไปใช้เกี่ยวกับงานจำแนกไฟป่าจากรูปภาพ



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในการศึกษาและประยุกต์ใช้เทคโนโลยีการเรียนรู้เชิงลึกในการจำแนกข้อมูลไฟไหม้จากภาพถ่าย ผู้วิจัยได้ศึกษาและทบทวนเอกสาร วรรณกรรม และงานวิจัย ที่เกี่ยวข้องโดยมีรายละเอียดของประเด็นต่างๆ ดังนี้

2.1 ความรู้เกี่ยวกับการเรียนรู้เชิงลึก

2.1.1 ปัญญาประดิษฐ์ (Artificial Intelligence) หรือเอไอ (AI)

หมายถึงความฉลาดเทียมที่สร้างขึ้นให้กับสิ่งที่ไม่มีชีวิต ปัญญาประดิษฐ์เป็นสาขาหนึ่งในด้านวิทยาการคอมพิวเตอร์ และวิศวกรรมเป็นหลัก แต่ยังรวมถึงศาสตร์ในด้านอื่นๆ อย่างจิตวิทยา ปรัชญา หรือชีววิทยา ซึ่งสาขาปัญญาประดิษฐ์เป็นการเรียนรู้เกี่ยวกับกระบวนการคิด การกระทำ การให้เหตุผล การปรับตัวหรือการอนุมาน และการทำงานของสมอง แม้ว่าดั้งเดิมนั้นเป็นสาขาหลักในวิทยาการคอมพิวเตอร์ แต่แนวคิดหลายๆ อย่างในศาสตร์นี้ได้มาจากการปรับปรุงเพิ่มเติมจากศาสตร์อื่นๆ เช่น

- 1) การเรียนรู้ของเครื่อง มีเทคนิคการเรียนรู้ที่เรียกว่า การเรียนรู้ต้นไม้ตัดสินใจ ซึ่งประยุกต์เอาเทคนิคการอุปนัยของจอห์น สจวร์ต มิลล์ นักปรัชญาชื่อดังของอังกฤษมาใช้
- 2) เครือข่ายประสาทเทียม นำเอาแนวคิดของการทำงานของสมองของมนุษย์ มาใช้ในการแก้ปัญหาการแบ่งประเภทของข้อมูล และแก้ปัญหาอื่นๆ ทางสถิติ เช่น การวิเคราะห์ความถดถอยหรือ การปรับเส้นโค้ง เป็นต้น

อย่างไรก็ตาม เนื่องจากปัจจุบันวงการปัญญาประดิษฐ์ มีการพัฒนาส่วนใหญ่โดยนักวิทยาศาสตร์คอมพิวเตอร์ อีกทั้งวิชาปัญญาประดิษฐ์ ก็ต้องเรียนที่ภาควิชาคอมพิวเตอร์ของคณะวิทยาศาสตร์หรือคณะวิศวกรรมศาสตร์จึงถือว่าศาสตร์นี้เป็นสาขาของวิทยาการคอมพิวเตอร์ [2]

2.1.2 การเรียนรู้ของเครื่อง (Machine learning)

เป็นส่วนหนึ่งของปัญญาประดิษฐ์ และเป็นสาขาวิชาที่พัฒนาและการศึกษาแบบจำลองเชิงสถิติที่สามารถเรียนรู้และพัฒนาตัวเองจากข้อมูล ซึ่งมักแบ่งเป็นชุดข้อมูลฝึกฝน ตรวจสอบ และทดสอบ (Training, Validation, Test Data Set) แล้ววางนัยทั่วไปหรือคาดการณ์จากข้อมูลใหม่ที่ยังไม่เคยเห็น และทำภารกิจ (Task) ต่างๆ โดยไม่ต้องระบุคำสั่งอย่างชัดเจน

มีการประยุกต์ใช้การเรียนรู้ของเครื่องในหลากหลายสาขา ไม่ว่าจะเป็นการประมวลภาษาธรรมชาติ คอมพิวเตอร์วิทัศน์ การรู้จำคำพูด การกรองอีเมล (Email Filtering) การเกษตร และการแพทย์ ในการประยุกต์ใช้ทางธุรกิจ การเรียนรู้ของเครื่องเป็นที่รู้จักในอีกชื่อว่าการวิเคราะห์เชิง


เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้เพื่อใช้ในการศึกษาเท่านั้น เมื่อผู้ผู้ใดเห็นประโยชน์ในการนำเอกสารนี้ไปเผยแพร่หรือใช้ทางธุรกิจ การเรียนรู้ของเครื่องเป็นที่รู้จักในอีกชื่อว่าการวิเคราะห์เชิง

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ทำนาย (Predictive Analytics) แม้ว่าการเรียนรู้ของเครื่องไม่ได้มีพื้นฐานเชิงสถิติไปทุกรูปแบบ แต่วิธีวิทยาในสาขานี้มาจากสาขาวิชาสถิติเชิงคำนวณ (Computational Statistics) เป็นสำคัญ

พื้นฐานทางคณิตศาสตร์ของการเรียนรู้ของเครื่องประกอบด้วยวิธีการการหาค่าเหมาะที่สุดเชิงคณิตศาสตร์ อีกสาขาวิชาที่เกี่ยวข้องกันคือการทำเหมืองข้อมูล และการวิเคราะห์ข้อมูลเชิงสำรวจ (Exploratory Data Analysis) ผ่านการเรียนรู้แบบไม่มีผู้สอน

ทอม เอ็ม. มิทเชลล์ (Tom M. Mitchell) ได้ให้นิยามแก่ขั้นตอนวิธีที่สาขาการเรียนรู้ของเครื่องศึกษาว่า "กล่าวได้ว่าโปรแกรมคอมพิวเตอร์เรียนรู้จากประสบการณ์ E เพื่อทำงานประเภทหนึ่ง T ได้โดยมีประสิทธิภาพ P เมื่อสามารถทำงาน T ที่วัดผลด้วย P แล้วพัฒนาขึ้นจากประสบการณ์ E" นิยามนี้เป็นการจำกัดการเรียนรู้ของเครื่องในแง่การดำเนินการ มากกว่าในแง่ความรู้สึกนึกคิดคล้ายข้อเสนอของแอลัน ทัวริง ในงานเขียนทรงอิทธิพล Computing Machinery and Intelligence ที่เปลี่ยนคำถามว่า "เครื่องจักรคิดได้หรือไม่" เป็นคำถามว่า "เครื่องจักรจะทำงานที่พวกเราในฐานะสิ่งที่มีความคิดความอ่าน ทำได้หรือไม่" ลักษณะการเรียนรู้ของเครื่องจักร [3] แสดงได้ดังรูปที่ 2.1



รูปที่ 2.1 เทคนิคการเรียนรู้ของเครื่องจักร

(ที่มา: <https://th.wikipedia.org/wiki/การเรียนรู้ของเครื่อง#/media/>

ไฟล์:Machine_Learning_Technique..JPG)

การเรียนรู้ของเครื่อง สามารถแบ่งโดยกว้างๆ ได้เป็น 3 ประเภท ตามประเภทของ "ข้อมูลฝึก" หรือ "ข้อมูลขาเข้า" ได้ดังนี้

- 1) การเรียนรู้แบบมีผู้สอน (Supervised Learning) – ข้อมูลตัวอย่างและผลลัพธ์ที่ "ผู้สอน" ต้องการถูกป้อนเข้าสู่คอมพิวเตอร์ เป้าหมายคือการสร้างกฎทั่วไปที่สามารถเชื่อมโยงข้อมูลขาเข้ากับขาออกได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- 2) การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) - ไม่มีการทำฉลากใดๆ และให้คอมพิวเตอร์หาโครงสร้างของข้อมูลขาเข้าเอง
- 3) การเรียนรู้แบบเสริมกำลัง (Reinforcement Learning) - คอมพิวเตอร์มีปฏิสัมพันธ์กับสิ่งแวดล้อมที่เปลี่ยนไปตลอดเวลาโดยคอมพิวเตอร์จะต้องทำงานบางอย่าง (เช่น ขับรถ) โดยที่ไม่มี"ผู้สอน"คอยบอกอย่างจริงจังว่าวิธีการที่ทำอยู่นั้นเข้าใกล้เป้าหมายแล้วหรือไม่ ตัวอย่างเช่น การเรียนรู้เพื่อเล่นเกม

นอกจากนี้ การเรียนรู้ของเครื่องยังสามารถแบ่งประเภทของ "งาน" ได้ตาม "ข้อมูลขาออก" จากระบบที่เครื่องจักรได้เรียนรู้แล้ว เป็นหลายประเภทดังนี้

- 1) การแบ่งประเภทข้อมูล (Classification) - ข้อมูลขาเข้าถูกแบ่งออกเป็นหลายประเภท (Class) และผู้เรียนจะต้องสร้างโมเดลที่สามารถกำหนดประเภทให้กับข้อมูลใหม่ที่ไม่เคยเห็นมาก่อนได้ โดยปกติแล้วจะทำโดยวิธีการเรียนรู้แบบมีผู้สอน ตัวอย่างของการแบ่งประเภทข้อมูลได้แก่การกรองอีเมลขยะ โดยอีเมลจะถูกแบ่งเป็นประเภท "ขยะ" และ "ไม่ใช่ขยะ"
- 2) การวิเคราะห์การถดถอย (Regression) - ใช้หลักการเดียวกับการแบ่งประเภทข้อมูล แต่ข้อมูลขาออกเป็นลักษณะต่อเนื่องมากกว่าเป็นประเภทแยกกัน
- 3) การแบ่งกลุ่มข้อมูล (Clustering) - เป้าหมายคือการแบ่งข้อมูลขาเข้าเป็นกลุ่มๆ โดยอัลกอริทึมจะไม่ทราบกลุ่มดังกล่าวล่วงหน้า (ไม่เหมือนกับการแบ่งประเภทข้อมูล) โดยปกติแล้วมักเป็นการเรียนรู้แบบไม่มีผู้สอน
- 4) การประเมินความหนาแน่น (Density Estimation) - เป็นการหาการกระจายของข้อมูลในมิติบางมิติ
- 5) การลดขนาดของมิติ (Dimensionality Reduction) - เป็นการเชื่อมโยงข้อมูลหลายมิติไปสู่ปรภูมิที่มีมิติต่ำกว่า

2.1.3 การเรียนรู้เชิงลึก (Deep Learning)

เป็นส่วนหนึ่งของวิธีการการเรียนรู้ของเครื่องบนพื้นฐานของโครงข่ายประสาทเทียมและการเรียนรู้ค่าแทนลักษณะ การเรียนรู้สามารถเป็นได้ทั้งแบบการเรียนรู้แบบมีผู้สอน การเรียนรู้แบบกึ่งมีผู้สอน และการเรียนรู้แบบไม่มีผู้สอน คำว่า "ลึก" ในความหมายมาจากการที่มีชั้นของโครงข่ายหลายชั้น ที่มีประสิทธิภาพมากขึ้น การเรียนที่สะดวกขึ้น และการเข้าใจในโครงสร้างที่ชัดเจนขึ้น

พื้นฐานของการเรียนรู้เชิงลึกคือ อัลกอริทึมที่พยายามจะสร้างแบบจำลองเพื่อแทนความหมายของข้อมูลในระดับสูงโดยการสร้างสถาปัตยกรรมข้อมูลขึ้นมาที่ประกอบไปด้วยโครงข่ายย่อยๆ หลายอัน และแต่ละอันนั้นได้มาจากการแปลงที่ไม่เป็นเชิงเส้น การเรียนรู้เชิงลึก อาจมองได้ว่า


เป็นวิธีการหนึ่งของการเรียนรู้ของเครื่องที่พยายามเรียนรู้วิธีการแทนข้อมูลอย่างมีประสิทธิภาพ เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ในทางอื่นไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตัวอย่างเช่น รูปภาพภาพหนึ่ง สามารถแทนได้เป็นเวกเตอร์ของความสว่างต่อจุดพิกเซล หรือมองในระดับสูงขึ้นไปเป็นเซตของขอบของวัตถุต่างๆ หรือมองว่าเป็นพื้นที่ของรูปร่างใดๆ ก็ได้ การแทนความหมายดังกล่าวจะทำให้การเรียนรู้ที่จะทำงานต่างๆ ทำได้ง่ายขึ้น ไม่ว่าจะเป็นการรู้จำใบหน้าหรือการรู้จำการแสดงออกทางสีหน้า การเรียนรู้เชิงลึกถือว่าเป็นวิธีการที่มีศักยภาพสูงในการจัดการกับค่าแทนลักษณะสำหรับการเรียนรู้แบบไม่มีผู้สอนหรือการเรียนรู้แบบกึ่งมีผู้สอน

นักวิจัยในสาขานี้พยายามจะหาวิธีการที่ดีขึ้นในการแทนข้อมูลแล้วสร้างแบบจำลองเพื่อเรียนรู้จากตัวแทนของข้อมูลเหล่านี้ในระดับใหญ่ บางวิธีการก็ได้แรงบันดาลใจมาจากสาขาประสาทวิทยาขั้นสูง โดยเฉพาะเรื่องกระบวนการตีความหมายในกระบวนการประมวลผลข้อมูลในสมอง ตัวอย่างของกระบวนการที่การเรียนรู้เชิงลึกนำไปใช้ได้แก่ การเข้ารหัสประสาท อันเป็นกระบวนการหาความสัมพันธ์ระหว่างตัวกระตุ้นกับการตอบสนองของเซลล์ประสาทในสมอง นักวิจัยด้านการเรียนรู้ของเครื่องได้เสนอสถาปัตยกรรมการเรียนรู้หลายแบบบนหลักการของการเรียนรู้เชิงลึกนี้ ได้แก่ โครงข่ายประสาทเทียมแบบลึก (Deep Artificial Neural Networks) โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Networks) โครงข่ายความเชื่อแบบลึก (Deep Belief Networks) และโครงข่ายประสาทแบบเวียนซ้ำ (Recurrent Neural Network) ซึ่งมีการนำมาใช้งานอย่างแพร่หลายในทางคอมพิวเตอร์วิทัศน์ การรู้จำเสียงพูด การประมวลผลภาษาธรรมชาติ การรู้จำเสียง และชีวสารสนเทศศาสตร์ [4]

2.1.4 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network)

เป็นโครงข่ายประสาทเทียมหนึ่งในกลุ่ม Bio-inspired โดยที่ CNN จะจำลองการมองเห็นของมนุษย์ที่มองพื้นที่เป็นย่อยๆ และนำกลุ่มของพื้นที่ย่อยๆ มาผสมกันการมองเห็นที่ย่อยของมนุษย์จะมีการแยกคุณลักษณะ (Feature) ของพื้นที่ย่อยนั้น เช่น ลายเส้นและการตัดกันของสี ซึ่งการที่มนุษย์รู้ว่าพื้นที่ตรงนี้เป็นเส้นตรงหรือสีตัดกัน เพราะมนุษย์ดูทั้งจุดที่สนใจและบริเวณรอบๆ ประกอบกัน แสดงดังรูปที่ 2.2



รูปที่ 2.2 สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบคอนโวลูชัน

(ที่มา: <https://saturncloud.io/images/blog/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way.webp>)

การแยกคุณลักษณะ (Feature Extraction) แนวคิดของ CNN นั้นค่อนข้างเป็นแนวคิดที่ดีมาก แต่สิ่งที่ซับซ้อนคือระบบการคำนวณที่สอดคล้องกับ Concept และต้องมีคณิตศาสตร์มารองรับ โดยการคำนวณตามแนวคิดนี้ใช้หลักการเดียวกันกับ คอนโวลูชันเชิงพื้นที่ (Spatial Convolution) ในการทำงานด้าน Image Processing การคำนวณนี้จะเริ่มจากการกำหนดค่าใน ตัวกรอง (Filter) หรือ เคอร์เนล (Kernel) ที่ช่วยดึงคุณลักษณะที่ใช้ในการรู้จำวัตถุออก โดยปกติตัวกรองเคอร์เนลอันหนึ่งจะดึงคุณลักษณะที่สนใจออกมาได้หนึ่งอย่าง จึงจำเป็นต้องตัวกรองหลายตัวกรองด้วย เพื่อหาคุณลักษณะทางพื้นที่หลายอย่างประกอบกัน

1) ลักษณะของ Filter

สำหรับ Filter ของภาพดิจิทัลนั้น โดยปกติแล้วจะเป็นตารางสองมิติที่มีขนาดตามพื้นที่ย่อยๆ ที่เราอยากพิจารณา ตำแหน่งตรงกลางที่มีกรอบสี่ฟ้าคือ Anchor ที่เอาไว้ทาบบนพิกเซลของภาพข้อมูลเข้า ตัวกรองจะถูกทาบลงในพิกเซลแรกของภาพข้อมูลเข้า จากนั้นจะถูกเลื่อนไปทาบบนพิกเซลอื่นในภาพทีละพิกเซลจนครบทุกพิกเซลในภาพ อาจจะไม่ทาบตัวกรองบนพิกเซลที่อยู่ใกล้กรอบภาพ เพราะตัวกรองจะล้นออกไปนอกภาพ เมื่อเลื่อนตัวกรองไปเรื่อยๆ จนครบทุกพิกเซลที่สามารถเลื่อนได้ในภาพ สิ่งที่ได้นั้นจะเป็นสิ่งที่เรียกว่า ผังคุณลักษณะ (Feature Map) ดังรูปที่ 2.3

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1	1	1	0	0
0	1	1	1	0
0	0	1x1	1x0	1x1
0	0	1x0	1x1	0x0
0	1	1x1	0x0	0x1

4	3	4
2	4	3
2	3	4

รูปที่ 2.3 ลักษณะของ Filter

(ที่มา: <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2>)

2) ลักษณะของ Stride

Stride เป็นตัวกำหนดว่าจะเลื่อนตัวกรอง (Filter) ไปด้วย Step เท่าไร (ตัวอย่างด้านล่างกำหนด Stride เท่ากับ 1) ดังรูปที่ 2.4

Stride 1

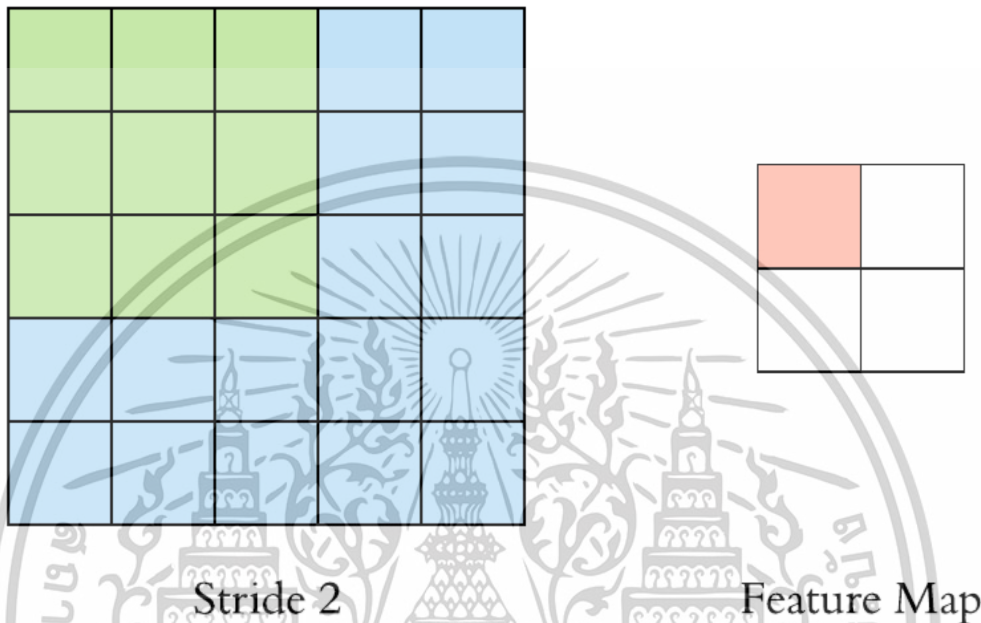
Feature Map

รูปที่ 2.4 ลักษณะของ Stride

(ที่มา: <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2>)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สามารถกำหนดค่าของ Stride ให้มากขึ้นก็ได้ ถ้าหากต้องการให้การคำนวณหาคุณลักษณะมีพื้นที่ทับซ้อนกันน้อยขึ้น แต่อย่างไรก็ตามการกำหนดค่าของ Stride ที่มากขึ้นจะทำให้ได้ฟังก์ชันลักษณะที่มีขนาดเล็กลง ดังรูปที่ 2.5




รูปที่ 2.5 ลักษณะของ Stride

(ที่มา: <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2>)

3) ลักษณะของ Padding

จากรูปที่ 2.6 พื้นที่สีเทาขอบๆ Input พื้นที่เหล่านี้เป็นพื้นที่ที่มักเติมเข้าไป โดยอาจจะเป็นเติม 0 หรือค่าต่างๆ เข้าไป เพื่อให้เวลาในการทำ CNN นั้น Feature Map ที่ได้ยังคงมีขนาดเท่ากับ Input

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.6 ลักษณะของ Padding

(ที่มา: <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2>)


ในบางปัญหา Input ที่อยู่ตามขอบภาพอาจมีความสำคัญที่ส่งผลต่อการตัดสินใจ บางอย่างจึงจำเป็นต้องเก็บคุณลักษณะตามขอบของรูปภาพไว้ด้วย

4) ลักษณะของ Max Pooling

Pooling คือความสามารถในการย่อรูปแบบหนึ่ง ซึ่งมีสองประเภทหลักที่นิยมกันคือ Max Pooling และ Mean Pooling

Max Pooling เป็นตัวกรองแบบหนึ่งที่ทำค่าสูงสุดในบริเวณที่ตัวกรองทาอยู่มาเป็นผลลัพธ์ โดยจะเตรียมตัวกรองในลักษณะเดียวกับการทำ Feature Extraction ของ CNN มาทาบนข้อมูลแล้วเลือกค่าที่สูงที่สุดบนตัวกรองนั้นมาเป็นผลลัพธ์ใหม่ และจะเลื่อนตัวกรองไปตาม Stride ที่กำหนดไว้ โดยขนาดตัวกรองของการทำ Max Pooling จะนิยมเรียกกันว่า Pool Size ดังรูปที่ 2.7

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.7 ลักษณะของ Max Pooling

(ที่มา: <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2>)


การตัดพิกเซลจะได้เฉพาะเรื่องการเปลี่ยนขนาดภาพ แต่ที่ต้องการคือการเก็บคุณลักษณะเด่นที่ตัวกรอง CNN ที่ทำไว้ใช้ต่อไป ถ้าตัดออกไป โดยไม่มีการคัดสรร อาจจะได้ค่าคุณลักษณะที่เหลืออยู่ในผลลัพธ์ที่ไม่สะท้อนถึงลักษณะที่สำคัญในภาพ แต่ถ้าใช้ Max Pooling ค่าคุณลักษณะที่เด่นที่สุดจะถูกเก็บไว้คำนวณต่อ [5]

2.1.5 ResNet (Residual Network)

โครงข่ายประสาทเทียม (Neural Network) ที่ถูกออกแบบมาเพื่อแก้ปัญหาการฝึกสอนโมเดลลึก (Deep Learning) ที่มีหลายชั้น โดยใช้แนวคิดของ Residual Learning หรือการเรียนรู้แบบเหลือมล้ำ ซึ่งถูกเสนอครั้งแรกในงานวิจัยของ Microsoft Research ในปี 2015 โดยมีชื่อว่า Deep Residual Learning for Image Recognition (ResNet)

หลักการสำคัญของ ResNet คือ การใช้ Residual Block ซึ่งประกอบไปด้วยการเชื่อมต่อแบบข้ามชั้น (Skip Connections) เพื่อให้ข้อมูลจากชั้นก่อนหน้าสามารถข้ามไปยังชั้นที่ลึกขึ้นได้โดยตรง วิธีนี้ช่วยให้การฝึกสอนโมเดลที่มีหลายชั้น สามารถทำได้ดีขึ้น และช่วยแก้ปัญหาที่เรียกว่า Vanishing Gradient Problem (ปัญหาการหายไปของเกรเดียนต์) ที่มักเกิดขึ้นเมื่อโมเดลมีชั้นจำนวนมาก [6] ดังรูปที่ 2.8

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.8 สถาปัตยกรรมการทำงานของ ResNet

(ที่มา:

https://en.wikipedia.org/wiki/Residual_neural_network#/media/File:ResBlock.png)

คุณสมบัติหลักของ ResNet มีดังนี้

- 1) Residual Connections (Skip Connections) คือ การเชื่อมต่อที่ทำให้ข้อมูลสามารถข้ามไปยังชั้นถัดไปโดยตรง ซึ่งช่วยให้การเรียนรู้ในชั้นลึกๆ ง่ายขึ้น
- 2) Deep Architecture สามารถสร้างโมเดลที่ลึกขึ้นโดยไม่ต้องกลัวว่าการเรียนรู้จะหยุดชะงัก
- 3) Improved Accuracy คือ โมเดลที่ใช้ ResNet มักจะสามารถทำงานได้ดีขึ้นในงานที่ต้องใช้โครงข่ายลึก เช่น การจำแนกรูปภาพ

ซึ่งในงานวิจัยนี้ได้เลือกใช้ ResNet101, ResNet152 และ ResNet152V2 โดยแสดงรายละเอียดและความแตกต่างของแต่ละโมเดลดังตารางที่ 2.1

ตารางที่ 2.1 เปรียบเทียบความแตกต่างของ Resnet ในงานวิจัย

คุณสมบัติ	ResNet101	ResNet152	ResNet152V2
จำนวนเลเยอร์	101	152	152
พารามิเตอร์โดยประมาณ	44.5M	60.2M	60.4M
ประเภท Block	Bottleneck	Bottleneck	Bottleneck (Pre-activation)
การไหลของ Gradient	ดี	อาจลดลงบ้างในโมเดลชั้นลึก	ดีกว่า เพราะ Pre-activation
ประสิทธิภาพการฝึก	ปานกลาง	ช้า	เสถียรกว่าในโมเดลชั้นลึก
ความแม่นยำ	ดี	ดีกว่าเล็กน้อย	ดีที่สุดในสามโมเดลนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


2.1.6 DenseNet (Densely Connected Convolutional Networks)

โครงข่ายประสาทเทียม (Neural Network) ที่มีการเชื่อมต่อน้อยอย่างหนาแน่น (Dense Connections) โดยทุกๆ ชั้นในโมเดลจะเชื่อมต่อกับทุกๆ ชั้นก่อนหน้าในโครงข่าย ทำให้ข้อมูลจากทุกชั้นในโครงข่ายถูกใช้ในการคำนวณของชั้นถัดไปอย่างเต็มที่ [7]

หลักการของ DenseNet มีดังนี้

- 1) DenseNet แต่ละชั้น จะรับข้อมูลจากทุกชั้นที่อยู่ก่อนหน้านั้น รวมถึงการส่งข้อมูลไปยังทุกชั้นที่อยู่หลังจากนั้นเช่นกัน ทำให้เกิดการเชื่อมต่อที่หนาแน่นระหว่างชั้น
- 2) Dense Block ประกอบด้วยหลายๆ ชั้นที่เชื่อมต่อกัน โดยในแต่ละชั้นจะรับข้อมูลจากทุกชั้นที่อยู่ก่อนหน้า (เช่น Input ของชั้นที่ i จะเป็นผลรวมของ Output จากชั้น 1 ถึง $i-1$)
- 3) Transition Layer เพื่อปรับขนาดของข้อมูลหลังจากที่ผ่าน Dense Block จะใช้ Transition Layer ซึ่งประกอบด้วยคอนโวลูชัน Convolution และ Pooling และการลดขนาด (Compression) เพื่อลดขนาดของข้อมูลและคงความสำคัญของลักษณะเด่นในข้อมูล

หลักการทำงานของ DenseNet จะแสดงได้ดังรูปที่ 2.9



รูปที่ 2.9 สถาปัตยกรรมการทำงานของ DenseNet

(ที่มา: https://miro.medium.com/v2/resize:fit:1400/format:webp/1*wWdQ7-Tz6U2KImRQttdsnA.png)

ข้อดีของ DenseNet มีดังนี้

- 1) ข้อมูลสามารถไหลผ่านชั้นต่างๆ ได้ดีขึ้น เนื่องจากทุกชั้นเชื่อมต่อกับทุกชั้นก่อนหน้า และลดปัญหาการหายไปของเกรเดียนต์ (Vanishing Gradient Problem)
- 2) ใช้การเรียนรู้ที่มีประสิทธิภาพ DenseNet มีพารามิเตอร์ที่น้อยกว่าในหลายๆ กรณี แต่ยังคงสามารถให้ผลลัพธ์ที่ดีขึ้นในหลายๆ งาน เช่น การจำแนกรูปภาพ (Image Classification) การตรวจจับวัตถุ (Object Detection) และงานอื่นๆ ที่เกี่ยวข้องกับการประมวลผลภาพ
- 3) เพิ่มประสิทธิภาพการใช้ฟิเจอร์ การที่แต่ละชั้นรับข้อมูลจากทุกๆ ชั้นที่อยู่ก่อนหน้าช่วยให้ DenseNet สามารถใช้ฟิเจอร์ที่เรียนรู้มาได้อย่างมีประสิทธิภาพมากขึ้น

ซึ่งในงานวิจัยนี้ได้เลือกใช้ DenseNet121, DenseNet169 และ DenseNet201 โดยแสดง

รายละเอียดและความแตกต่างของแต่ละโมเดลดังตารางที่ 2.2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 2.2 เปรียบเทียบความแตกต่างของ DenseNet ในงานวิจัย

คุณสมบัติ	DenseNet121	DenseNet169	DenseNet201
จำนวนเลเยอร์	121	169	201
จำนวนพารามิเตอร์	8.0 ล้าน	14.2 ล้าน	20.0 ล้าน
จำนวน Dense Blocks	4	4	4
จำนวน Layers ในแต่ละ Block	[6, 12, 24, 16]	[6, 12, 32, 32]	[6, 12, 48, 32]
Growth Rate	32	32	32
การใช้หน่วยความจำ	ต่ำที่สุด	ปานกลาง	สูงที่สุด
ความแม่นยำโดยทั่วไป	ดีมาก	ดีกว่าเล็กน้อย	ดีที่สุดในสามโมเดลนี้

2.1.7 MobileNet

โครงข่ายประสาทเทียม (Neural Network) ที่ถูกออกแบบมาเพื่อการประมวลผลที่มีประสิทธิภาพสูงในอุปกรณ์ที่มีข้อจำกัดด้านการคำนวณ เช่น สมาร์ทโฟน หรืออุปกรณ์พกพา โดยไม่สูญเสียประสิทธิภาพในการจำแนกภาพ (Image Classification) หรือการประมวลผลภาพที่สำคัญ [8]


หลักการของ MobileNet มีดังนี้

MobileNet ใช้ Depthwise Separable Convolution ซึ่งเป็นเทคนิคที่ช่วยลดจำนวนพารามิเตอร์และการคำนวณในโครงข่ายประสาทเทียม โดยมีการแยกการคอนโวลูชันออกเป็นสองขั้นตอน ได้แก่

1) Depthwise Convolution การคอนโวลูชันในแต่ละช่อง (Channel) โดยแยกจากกัน ซึ่งช่วยลดการคำนวณและจำนวนพารามิเตอร์ที่ใช้

2) Pointwise Convolution การคอนโวลูชัน 1×1 เพื่อรวมข้อมูลจากช่องต่างๆ เข้าด้วยกัน ด้วยการนำ Depthwise Separable Convolutions ดังนั้น MobileNet จึงสามารถลดจำนวนพารามิเตอร์และการคำนวณได้มาก เมื่อเทียบกับโครงข่ายคอนโวลูชันแบบปกติ (Standard Convolutional Networks) จึงเหมาะสมสำหรับการใช้งานในอุปกรณ์ที่มีข้อจำกัดด้านทรัพยากร เช่น สมาร์ทโฟนและอุปกรณ์พกพา

หลักการทำงานของ MobileNet จะแสดงได้ดังรูปที่ 2.10



รูปที่ 2.10 สถาปัตยกรรมการทำงานของ MobileNet

(ที่มา: https://wikidocs.net/images/page/164799/Mobile_Fig_01.png)

ข้อดีของ MobileNet มีดังนี้

- 1) ประสิทธิภาพสูง ถึงแม้จะมีขนาดโมเดลที่เล็กกว่า แต่ MobileNet ยังคงสามารถทำงานได้ดีในงานจำแนกภาพ (Image Classification) และงานประมวลผลภาพ
- 2) ขนาดโมเดลเล็ก ด้วยการใช้เทคนิค Depthwise Separable Convolution ทำให้โมเดลมีขนาดเล็กลง และใช้หน่วยความจำ (Memory) และการคำนวณที่น้อยลง
- 3) การประมวลผลที่เร็วขึ้น โมเดล MobileNet ถูกออกแบบมาให้มีความเร็วในการประมวลผลสูง แม้จะทำงานบนอุปกรณ์ที่มีข้อจำกัดด้านการคำนวณ
- 4) เหมาะสำหรับอุปกรณ์พกพา ด้วยคุณสมบัติที่ประหยัดพลังงานและคำนวณน้อย MobileNet เหมาะสมกับการใช้งานในอุปกรณ์ที่มีข้อจำกัด เช่น สมาร์ทโฟน แท็บเล็ต และอุปกรณ์ IoT

ซึ่งในงานวิจัยนี้ได้เลือกใช้ MobileNetV2, MobileNetV3Small และ MobileNetV3Large โดยแสดงรายละเอียดและความแตกต่างของแต่ละโมเดลดังตารางที่ 2.3

ตารางที่ 2.3 เปรียบเทียบความแตกต่างของ MobileNet ในงานวิจัย

คุณสมบัติ	MobileNetV2	MobileNetV3Small	MobileNetV3Large
ขนาดโมเดล (พารามิเตอร์)	3.4M	2.5M	5.4M
ขนาด FLOPs (1.0x input)	300M	65M	219M

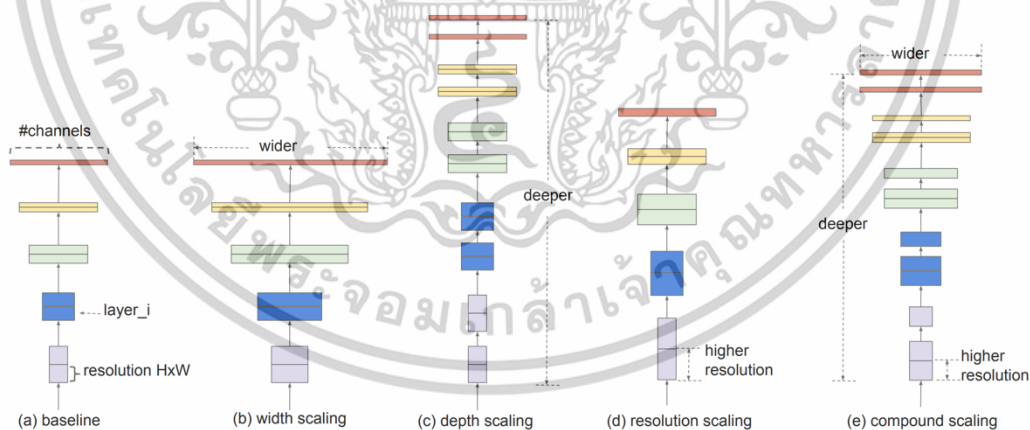
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 2.3 (ต่อ) เปรียบเทียบความแตกต่างของ MobileNet ในงานวิจัย

คุณสมบัติ	MobileNetV2	MobileNetV3Small	MobileNetV3Large
โครงสร้างหลัก	Inverted Residual + Linear Bottleneck	Inverted Residual + SE + NAS	Inverted Residual + SE + NAS
Activation	ReLU6	h-swish (Hard-Swish)	h-swish
Squeeze-and-Excitation (SE)	ไม่มี	มีบางจุด	มีหลายจุด
ความเร็วในการ inference	เร็ว	เร็วมาก เน้นอุปกรณ์ IoT	เร็ว แม่นยำกว่า V2

2.1.8 EfficientNet

โครงข่ายประสาทเทียม (Neural Network) ที่ถูกออกแบบมาเพื่อเพิ่มประสิทธิภาพในการจำแนกภาพ (Image Classification) โดยใช้การปรับขนาด (Scaling) ที่มีประสิทธิภาพระหว่าง ความลึก (Depth) ความกว้าง (Width) และ ความละเอียด (Resolution) ของโมเดล การออกแบบนี้ทำให้ EfficientNet มีประสิทธิภาพสูงทั้งในแง่ของความแม่นยำและความเร็วในการประมวลผล ในขณะที่ใช้พารามิเตอร์น้อยและการคำนวณที่น้อยกว่าโครงข่ายอื่นๆ [9] ดังรูปที่ 2.11



รูปที่ 2.11 สถาปัตยกรรมการทำงานของ EfficientNet

(ที่มา: https://production-media.paperswithcode.com/methods/Screen_Shot_2020-06-06_at_10.45.54_PM.png)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หลักการของ EfficientNet มีดังนี้

1) Compound Scaling ซึ่งเป็นการปรับขนาดของโมเดลโดยการปรับสามปัจจัยหลักพร้อมกัน ได้แก่

- Depth (ความลึก) การเพิ่มจำนวนชั้นในโมเดล
 - Width (ความกว้าง) การเพิ่มจำนวนยูนิตหรือพีเจอร์ริในแต่ละชั้น
 - Resolution (ความละเอียด) การเพิ่มขนาดของภาพที่ป้อนเข้าไปในโมเดล
- เทคนิคนี้ทำให้สามารถปรับขนาดโมเดลได้อย่างเหมาะสมและมีประสิทธิภาพ โดยไม่ต้องเพิ่มค่าใช้จ่ายในการคำนวณมากเกินไป

2) EfficientNet Architecture โมเดล EfficientNet ได้รับการพัฒนาโดยใช้ Neural Architecture Search (NAS) เพื่อค้นหาโครงสร้างที่ดีที่สุดที่สามารถให้ความสมดุลระหว่างความแม่นยำและการใช้พลังงาน (Computational Cost) โดยไม่ต้องใช้สถาปัตยกรรมที่ซับซ้อนเกินไป

ข้อดีของ EfficientNet มีดังนี้

1) มีประสิทธิภาพสูง EfficientNet สามารถให้ผลลัพธ์ที่ดีกว่าในหลายๆ งานโดยใช้พารามิเตอร์ที่น้อยกว่า และการคำนวณที่น้อยกว่าเมื่อเทียบกับโครงข่ายอื่นๆ เช่น ResNet หรือ DenseNet

2) การปรับขนาดที่มีประสิทธิภาพ เทคนิค Compound Scaling ทำให้ EfficientNet สามารถปรับขนาดของโมเดลได้อย่างเหมาะสม ซึ่งช่วยให้โมเดลสามารถทำงานได้ดีทั้งในงานที่ต้องการความแม่นยำสูงและในอุปกรณ์ที่มีข้อจำกัดด้านทรัพยากร

3) การใช้ทรัพยากรที่ต่ำ ด้วยการที่ EfficientNet ใช้ทรัพยากรในการคำนวณและหน่วยความจำน้อย โมเดลนี้จึงเหมาะกับการใช้งานในอุปกรณ์ที่มีข้อจำกัดด้านการประมวลผล เช่น สมาร์ทโฟนและอุปกรณ์พกพา

ซึ่งในงานวิจัยนี้ได้เลือกใช้ EfficientNetV2S, EfficientNetV2M และ EfficientNetV2L โดยแสดงรายละเอียดและความแตกต่างของแต่ละโมเดลดังตารางที่ 2.4

ตารางที่ 2.4 เปรียบเทียบความแตกต่างของ EfficientNet ในงานวิจัย

คุณสมบัติ	EfficientNetV2S	EfficientNetV2M	EfficientNetV2L
จำนวนพารามิเตอร์	22M	54M	120M
FLOPs (224x224 input)	8.4B	24B	55B
Top-1 Accuracy (ImageNet)	84.6%	85.7%	86.5%
ความเร็วในการฝึก	เร็วมาก	ปานกลาง	ช้าที่สุดในกลุ่มนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปตีพิมพ์หรือใช้เพื่อการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 2.4 (ต่อ) เปรียบเทียบความแตกต่างของ EfficientNet ในงานวิจัย

คุณสมบัติ	EfficientNetV2S	EfficientNetV2M	EfficientNetV2L
Conv Block หลัก	Fused-MBConv + MBConv	Fused-MBConv + MBConv	Fused-MBConv + MBConv
Squeeze-and- Excitation (SE)	มีทุกเวอร์ชัน	มี	มี
Activation	Swish	Swish	Swish

2.2 การประเมินประสิทธิภาพ

งานวิจัยนี้ได้เลือก Confusion Matrix ที่ใช้ในการประเมินประสิทธิภาพของโมเดลการเรียนรู้ของเครื่อง (Machine Learning Model) ซึ่ง Confusion Matrix คือตารางที่ใช้ประเมินประสิทธิภาพของ Classification Machine Learning รูปแบบต่างๆ ร่วมกับชุดข้อมูลทดสอบที่ทราบค่าหรือผลลัพธ์ที่แท้จริงแล้ว ด้วยการประเมินค่าจริง (Actual Value) เทียบกับค่าที่ได้จากผลลัพธ์ของ โมเดลการเรียนรู้ของเครื่อง (Machine Learning Model) หรือค่าที่คาดการณ์ไว้ (Predicted Value) แล้วสรุปค่าออกมาในรูปแบบของตารางเมทริกซ์ที่ประกอบด้วยค่า True negative (TN), False positive (FP), False negative (FN) และ True positive (TP) [10] ซึ่งแต่ละค่ามีความหมายดังนี้

- 1) True Positive (TP) คือจำนวนข้อมูลที่ถูกจำแนกได้อย่างถูกต้องในกลุ่มของประเภทที่ต้องการ (Positive Class) หรือกลุ่มที่สนใจ ในกรณีนี้คือข้อมูลที่ถูกทำนายว่าเป็น Positive หรือเป็นแบบนี้จริง และข้อมูลจริงก็เป็นแบบนี้จริงๆ หรือก็คือการทำนายถูกต้องว่าสิ่งที่เราประเมินไว้จะเกิดขึ้น
- 2) True Negative (TN) คือจำนวนข้อมูลที่ถูกจำแนกถูกต้องในกลุ่มของประเภทที่ไม่ใช่เป้าหมาย (Negative Class) หรือกลุ่มที่ไม่สนใจ ในกรณีนี้คือข้อมูลที่ถูกทำนายว่าเป็น Negative และข้อมูลจริงก็เป็น Negative นั่นคือการทำนายถูกต้องว่าไม่เป็นสิ่งที่ได้ประเมินไว้
- 3) False Positive (FP) คือจำนวนข้อมูลที่ถูกทำนายผิดในกลุ่มของประเภทที่สนใจ ในกรณีนี้คือข้อมูลที่ถูกทำนายว่าเป็น Positive แต่ข้อมูลจริงกลับเป็น Negative นั่นคือการทำนายผิดว่าเป็นสิ่งที่เราทำการประเมินไว้ หรือ False
- 4) False Negative (FN) คือจำนวนข้อมูลที่ถูกจำแนกผิดในกลุ่มของประเภทที่ไม่สนใจ ในกรณีนี้คือข้อมูลที่ถูกทำนายว่าเป็น Negative แต่ข้อมูลจริงกลับเป็น Positive นั่นคือการทำนายผิดว่าไม่เป็นสิ่งที่ได้ประเมินไว้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การประเมินประสิทธิภาพของโมเดลการเรียนรู้ของเครื่อง (Machine Learning Model) ด้วย Confusion Matrix

เป็นการนำค่าที่อยู่ในตาราง Confusion Matrix ไปใช้ประเมินประสิทธิภาพของ โมเดลการเรียนรู้ของเครื่อง (Machine Learning Model) ผ่านการคำนวณค่าพารามิเตอร์ที่ใช้ประเมิน 4 ค่า ได้แก่ Accuracy (ความถูกต้อง) Precision (ความแม่นยำในการทำนายในกลุ่มเป้าหมาย) ความสามารถในการตรวจจับเหตุการณ์ที่สนใจ (Recall) และค่า F1-Score โดยการคำนวณมีสมการที่ใช้ดังต่อไปนี้

2.2.1 Accuracy (ความถูกต้อง)

Accuracy คือ อัตราส่วนของจำนวนการทำนายที่ถูกต้องทั้งหมด (ทั้ง Positive และ Negative) ที่โมเดลทำนายออกมาเทียบกับจำนวนตัวอย่างทั้งหมดในชุดข้อมูล คำนวณดังสมการที่ (2.1)

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.1)$$

ข้อดี คือ เป็นเมตริกที่เข้าใจง่ายและใช้งานได้ง่ายในกรณีที่ข้อมูลมีการกระจาย (Balanced) อย่างเป็นอย่างดี

ข้อเสีย คือ ในกรณีที่ข้อมูลมีการกระจายที่ไม่สมดุล (Imbalanced Data) เช่น มีตัวอย่างของคลาสหนึ่งเยอะกว่ามาก การใช้ Accuracy อาจทำให้เข้าใจผิดได้ เช่น โมเดลที่ทำนายทุกตัวอย่างเป็นคลาสที่มีจำนวนมากที่สุดก็อาจจะได้ Accuracy สูง

2.2.2 Precision (ความแม่นยำในการทำนายในกลุ่มเป้าหมาย)

Precision คือ ค่าความแม่นยำในการทำนายในกลุ่มเป้าหมายหรือพิจารณาเฉพาะที่เป็น True Positive (TP) โดยสามารถคำนวณได้จากสมการที่ (2.2)

$$Precision = \frac{TP}{TP + FP} \quad (2.2)$$

ข้อดี คือ ใช้ในกรณีที่ต้องการให้โมเดลทำนาย Positive ได้ถูกต้องมากที่สุด เช่น การตรวจจับอีเมลสแปมที่ต้องการหลีกเลี่ยงการทำนายเป็นสแปมผิดพลาด

ข้อเสีย คือ Precision อาจจะต่ำถ้าโมเดลทำนาย Positive มากเกินไป แต่ไม่ถูกต้อง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.2.3 Recall (ความสามารถในการตรวจจับเหตุการณ์ที่สนใจ)

Recall หรือ Sensitivity คือความสามารถของโมเดลในการ Predict หรือระบุสิ่งที่สนใจ ซึ่งคือสัดส่วนของ True Positives (TP) กับข้อมูลที่จริงๆ เป็น Positive ทั้งหมด โดยสามารถคำนวณได้จากสมการที่ (2.3)

$$Recall = \frac{TP}{TP + FN} \quad (2.3)$$

ข้อดี คือ ใช้ในกรณีที่ต้องการให้โมเดลตรวจจับ Positive ทุกตัวอย่างให้ได้ เช่น การตรวจจับมะเร็งที่ต้องการหาแม่แรงทุกตัวแม้ว่าอาจจะมีการทำนายผิดพลาดบ้าง

ข้อเสีย คือ Recall อาจสูงเกินไปถ้าโมเดลทำนายเป็น Positive มากเกินไป เช่น การทำนายเป็นสแปมทุกอีเมล

2.2.4 F1-Score

F1-Score คือค่าความสมดุลระหว่างความแม่นยำในการทำนายในกลุ่มเป้าหมาย (Precision) และความสามารถในการตรวจจับเหตุการณ์ที่สนใจ (Recall) โดยสามารถคำนวณได้จากสมการที่ (2.4)

$$F1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (2.4)$$

ข้อดี คือ F1-Score ใช้เมื่อไม่สามารถให้ความสำคัญกับ Precision หรือ Recall เพียงหนึ่งด้าน โดยเฉพาะในกรณีที่ข้อมูลมีความไม่สมดุล

ข้อเสีย คือ อาจจะซับซ้อนกว่าการใช้ค่า Accuracy ในบางกรณี

สำหรับความสัมพันธ์ระหว่างเมตริกสามารถอธิบายได้ ดังนี้

1) Precision และ Recall มักจะมีความสัมพันธ์ตรงกันข้ามกล่าวคือ ถ้าเพิ่ม Precision ทำนายเป็น Positive น้อยลง จะทำให้ Recall อาจลดลงและพลาดตัวอย่างที่เป็น Positive

2) F1-Score เป็นการหาค่าเฉลี่ยเชิงสมดุลของทั้งสองเมตริก (Precision และ Recall) จึงเหมาะสมในกรณีที่ต้องการสมดุลระหว่างการทำนายที่ถูกต้องและไม่ถูกต้อง

2.3 เครื่องมือที่ใช้ในงานวิจัย

2.3.1 ภาษา Python Programming Language

เป็นภาษาระดับสูงมุ่งเน้นให้ผู้โปรแกรมสามารถอ่านชุดคำสั่งได้โดยง่าย และการประยุกต์ใช้แนวคิดการเขียนโปรแกรมเชิงวัตถุ ช่วยให้นักเขียนโปรแกรมสามารถเขียนโปรแกรมที่เป็นระเบียบ อ่านง่าย มีขนาดเล็ก และง่ายต่อการใช้งาน มาพร้อมกับไลบรารีมาตรฐานจำนวนมาก เช่น โครงสร้างข้อมูลแบบซับซ้อน และ ไลบรารีสำหรับคณิตศาสตร์

ลักษณะเด่นของภาษา Python ได้แก่

- 1) อ่านง่ายและเข้าใจง่าย Python ถูกออกแบบมาให้มีไวยากรณ์ (Syntax) ที่อ่านง่ายและเข้าใจง่าย ทำให้ผู้เริ่มต้นสามารถเรียนรู้ได้อย่างรวดเร็ว
- 2) การเขียนโปรแกรมที่กระชับ Python ใช้จำนวนบรรทัดน้อยในการทำงานเดียวกัน เมื่อเทียบกับภาษาอื่นๆ เช่น C++ หรือ Java
- 3) รองรับการเขียนโปรแกรมหลายรูปแบบ Python รองรับการเขียนโปรแกรมทั้งในรูปแบบ Procedural, Object-Oriented, และ Functional Programming
- 4) มีไลบรารีมากมายที่สามารถใช้ในการพัฒนาแอปพลิเคชันต่างๆ โดยไม่จำเป็นต้องเขียนโค้ดเองทั้งหมด เช่น NumPy, pandas, TensorFlow, Keras, Flask, Django และอื่นๆ
- 5) รองรับการทำงานข้ามแพลตฟอร์ม Python สามารถทำงานได้บนหลายระบบปฏิบัติการ เช่น Windows, macOS, Linux, และ Unix

การใช้งานของ Python มีดังนี้

- 1) Web Development Python ใช้ในการพัฒนาเว็บแอปพลิเคชัน โดยไลบรารีอย่าง Django หรือ Flask ช่วยให้การพัฒนาเว็บทำได้ง่ายและรวดเร็ว
- 2) Data Science & Machine Learning Python เป็นภาษาหลักในการทำงานด้านวิทยาศาสตร์ข้อมูล (Data Science) และการเรียนรู้ของเครื่อง (Machine Learning) โดยมีไลบรารีที่ได้รับความนิยมอย่าง NumPy, pandas, Matplotlib, Scikit-learn, TensorFlow และ Keras
- 3) Automation (Scripting) Python มักถูกใช้ในการเขียนสคริปต์เพื่อทำงานอัตโนมัติ เช่น การดาวน์โหลดไฟล์ การประมวลผลข้อมูล หรือการทำงานซ้ำๆ ที่ต้องการความรวดเร็ว
- 4) Software Development ใช้ในการพัฒนาโปรแกรมที่มีฟังก์ชันหลากหลาย เช่น โปรแกรมเดสก์ทอป เกม หรือแอปพลิเคชันที่ใช้งานบนเซิร์ฟเวอร์

2.3.2 Jupyter Notebook

เป็นเครื่องมือ opensource ที่ใช้ในการสร้างเอกสารที่มีคำอธิบายและ Code ที่สามารถ Execute ได้เพื่อทำการทดลองซ้ำและสามารถดูผลการทดลองได้ทั้งกับข้อมูลชุดเดิมหรือข้อมูลชุดใหม่ โดย Jupyter Notebook สามารถเขียน Source Code เป็น Block สั้นๆ และ เขียนอธิบายแต่ละ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ส่วนด้วย Markdown ได้ซึ่ง Jupyter Notebook ได้สร้างระบบ Kernel ที่ให้นักพัฒนาเขียน configuration เพื่อใช้งานกับภาษาหรือระบบได้หลากหลาย

คุณสมบัติหลักของ Jupyter Notebook มีดังนี้

1) อินเทอร์เฟซแบบเว็บ Jupyter Notebook ทำงานในรูปแบบเว็บเบราว์เซอร์ ซึ่งทำให้สามารถทำงานจากเครื่องคอมพิวเตอร์เครื่องใดก็ได้ที่ติดตั้ง Jupyter โดยไม่ต้องติดตั้งซอฟต์แวร์เพิ่มเติม

2) สามารถผสมโค้ดกับข้อความได้ สามารถเขียนโค้ดและอธิบายผลลัพธ์พร้อมกับข้อความ (Markdown) ในเซลล์เดียวกัน ทำให้การนำเสนอข้อมูลทำได้ง่ายและสะดวก

3) รองรับกราฟและภาพ สามารถแทรกรูปภาพ กราฟ และตารางได้โดยตรงในเอกสาร ทำให้เหมาะสำหรับการแสดงผลข้อมูลและผลลัพธ์จากการคำนวณ

4) รองรับหลายภาษา Jupyter รองรับหลายภาษาเช่น Python, R, Julia และอื่นๆ ผ่านการติดตั้ง Kernel ที่เหมาะสม

5) การประมวลผลแบบโต้ตอบ สามารถรันโค้ดทีละบรรทัดหรือเซลล์ในเอกสารและดูผลลัพธ์ได้ทันที ซึ่งทำให้เหมาะสำหรับการทดสอบและทดลองโค้ด

6) การบันทึกและแชร์ได้ง่าย สามารถบันทึกไฟล์ Jupyter Notebook ในรูปแบบ .ipynb และสามารถแชร์ไฟล์นี้ให้กับผู้อื่น หรือแม้แต่แปลงไฟล์นี้เป็นเอกสาร HTML หรือ PDF

2.3.3 FastAPI

เว็บเฟรมเวิร์ก (Web Framework) สำหรับการพัฒนา API ด้วยภาษา Python ที่มีความเร็วสูง ใช้งานง่าย และทันสมัย โดยออกแบบมาเพื่อรองรับการพัฒนา RESTful API และ Asynchronous Programming (รองรับ async/await) ได้อย่างมีประสิทธิภาพ

จุดเด่นของ FastAPI มีดังนี้

1) เร็ว เพราะทำงานบน ASGI (Asynchronous Server Gateway Interface) และใช้ Starlette เป็นฐาน

2) ใช้ Python Type Hints เต็มรูปแบบ ช่วยให้เกิด Auto-completion ในเครื่องมืออย่าง VS Code และช่วยให้ตรวจสอบข้อมูลที่รับเข้ามา (Validation) ได้อัตโนมัติ

3) Swagger UI อัตโนมัติ เมื่อเขียน API เสร็จ จะมีหน้าเอกสารแบบ Interactive ให้ทันทีที่ /docs (Swagger) และ /redoc

4) รองรับ async/await เขียนโค้ดแบบ Asynchronous ได้ง่าย เหมาะกับระบบที่ต้องรองรับผู้ใช้จำนวนมากหรือ I/O

5) Validation อัตโนมัติด้วย Pydantic โดยใช้โมเดลจาก Pydantic สำหรับจัดการข้อมูลเข้าออก เช่น JSON Payload

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.3.4 React.js

เป็น JavaScript Library ที่ใช้ในการสร้าง User Interface (UI) โดยเฉพาะสำหรับ เว็บแอปพลิเคชันแบบ Single Page Application (SPA) พัฒนาโดย Facebook และถูกใช้อย่างแพร่หลายในวงการเว็บ

คุณสมบัติเด่นของ React.js มีดังนี้

- 1) Component-Based Architecture React แบ่ง UI ออกเป็นชิ้นส่วนเล็กๆ เรียกว่า Component แต่ละ Component เป็นอิสระและสามารถนำกลับมาใช้ซ้ำได้
- 2) Declarative UI บอก React ว่าหน้าตาควรเป็นอย่างไร ไม่ต้องบอกวิธีทำงานแบบละเอียด ช่วยให้โค้ดอ่านง่ายและลดข้อผิดพลาด
- 3) Virtual DOM React ใช้ Virtual DOM เพื่อเพิ่มประสิทธิภาพในการอัปเดต UI โดยจะเปรียบเทียบก่อนว่าจะอัปเดตส่วนใดของ DOM จริง
- 4) Unidirectional Data Flow ข้อมูลไหลจากบนลงล่าง จาก Parent ไป Child ทำให้การจัดการ State ง่ายและมีความคาดเดาได้
- 5) ใช้งานร่วมกับเครื่องมือและไลบรารีอื่นได้ง่าย เช่น Redux, React Router, Axios และ TailwindCSS

2.4 งานวิจัยที่เกี่ยวข้อง

ในปี ค.ศ.2022 Sridhar P [11] ได้นำเสนอเทคนิคของ DenseNet ซึ่งสามารถสร้างการเชื่อมต่อแบบหนาแน่นได้ดีขึ้นในเลเยอร์ต่างๆ โดยใช้ Dense Blocks ทำให้เลเยอร์ทั้งหมดเชื่อมต่อกันทางกายภาพและมีขนาดพีเจอร์แมปที่ตรงกัน โดยเน้นที่การทำให้เครือข่ายการเรียนรู้เชิงลึกสามารถเจาะลึกลงไปได้อีก จึงส่งผลให้ฝึกอบรมได้อย่างมีประสิทธิภาพมากขึ้น งานวิจัยนี้ได้นำมาใช้กับชุดข้อมูลที่มีการผสมของกลุ่มรูปภาพที่มีไฟและกลุ่มรูปภาพที่ไม่มีไฟ เพื่อนำไปใช้ในการตรวจจับไฟป่าและการหลีกเลี่ยงสัญญาณเตือนภัยผิดพลาด และยังได้ดูแนวคิดของแผนผังการทำงาน ซึ่งประกอบด้วย เริ่มเก็บข้อมูล เตรียมข้อมูล การทำ Data Augmentation การแบ่งข้อมูล การฝึกฝนโมเดล ทดสอบโมเดล รวมไปถึงจนถึงการทำนายผลลัพธ์ของโมเดล

ในปี ค.ศ.2022 Hoor Ul Ain Tahir [12] ได้นำเสนอโมเดลการเรียนรู้เชิงลึกที่ใช้ YOLOv5 สำหรับการตรวจจับไฟป่า ซึ่งวิธีนี้จะตรวจจับไฟป่าในสภาพแวดล้อมแบบเรียลไทม์ด้วยความแม่นยำสูงโดยการประเมินเฟรมต่อเฟรมวิดีโอเพื่อตรวจจับความผิดปกติแบบเรียลไทม์ และส่งคำเตือนไปยังหน่วยงานที่เกี่ยวข้อง ในแง่ของประสิทธิภาพการตรวจจับ เทคนิคของงานนี้มีประสิทธิภาพเหนือกว่าระบบตรวจจับไฟที่มีอยู่เดิม โดยใช้ชุดข้อมูลภาพทางอากาศของ FireNet และ FLAME ได้ประเมินประสิทธิภาพด้วย F1-Score อยู่ที่ 94.44%

ในปี ค.ศ.2023 Shubhangi N. Ghatge [13] ได้นำเสนออัลกอริทึมการเรียนรู้ซึ่งประกอบด้วย K-Nearest Neighbors (K-NN), Logistic Regression และ Random Forest ทั้งสาม

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

อัลกอริทึมนี้จะถูกนำไปใช้ในการฝึกและทดสอบชุดภาพและข้อมูลขนาดใหญ่ โดยจะมีการศึกษาเปรียบเทียบอัลกอริทึมต่างๆ และจะเลือกอัลกอริทึมที่ดีที่สุดมาใช้กับระบบงาน ซึ่งงานวิจัยนี้จะมีอินเทอร์เฟซเว็บแบบพรอนท์เอนด์ให้ผู้ใช้ทุกคน เช่น เจ้าหน้าที่ตรวจสอบป่าไม้/หน่วยงานคุ้มครองสิ่งแวดล้อม เป็นต้น โดยระบบนี้สามารถอัปโหลดรูปภาพถ่ายดาวเทียมจากกระยะไกล และข้อมูลสำหรับภูมิภาคทางภูมิศาสตร์ใดภูมิภาคหนึ่ง เช่น อุณหภูมิ/ความเร็วลม/ความกดอากาศ เป็นต้น เพื่อตรวจจับหรือคาดการณ์ความเป็นไปได้ที่จะเกิดไฟป่าในภูมิภาคที่เกี่ยวข้อง ผลลัพธ์ทั้งหมดนี้เกิดขึ้นในรูปแบบจำลองของแอปพลิเคชันเว็บ Flask ที่ใช้งานง่าย เครื่องมือนี้ช่วยให้ผู้ใช้สามารถอัปโหลดภาพถ่ายดาวเทียมและเรียกใช้การคาดการณ์แบบจำลอง ตลอดจนดูผลลัพธ์ ทำให้ทุกคนสามารถเข้าถึงความสามารถขั้นสูงสำหรับการตรวจจับไฟป่าได้

ในปี ค.ศ.2023 Rahmi Arda Aral [14] ได้นำเสนอภายใต้เทคโนโลยีของ Convolutional Neural Network (CNN) ซึ่งประกอบไปด้วย ResNet50, ResNet101, EfficientNetB1, VGG16 และ DenseNet121 สำหรับภารกิจการตรวจจับไฟป่า ในการทดลองได้นำอากาศยานบินไร้คนขับ Unmanned Aerial Vehicle (UAV) รวบรวมภาพไฟป่าในลักษณะของอินฟราเรดมาสร้างเป็นชุดข้อมูล โดยในการตั้งค่าของ Hyperparameter สำหรับการทดลอง จะใช้ภาพอินพุตที่มีความละเอียด $256 \times 256 \times 3$ และใช้ Adam เป็นตัวเพิ่มประสิทธิภาพ (Optimizer) ด้วยอัตราการเรียนรู้ (Learning Rate) ที่ 0.0001 ในระหว่างขั้นตอนการฝึกของทุกโมเดลที่กล่าวมาข้างต้น โดยผลการทดลองแสดงให้เห็นอย่างชัดเจนว่าแนวทางนี้มีประสิทธิภาพเพียงพอในชุดข้อมูลที่สร้างขึ้นของภาพอินฟราเรด โมเดล ResNet101 ให้ผลลัพธ์สูงสุดในตัวชี้วัดการประเมินผลทั้งหมด โดยมีความแม่นยำในการทดสอบ 99.20%

ในปี ค.ศ.2023 Xinjie Deng [15] ได้นำเสนออัลกอริทึมการเรียนรู้เชิงลึก (Deep Learning) ที่มีขนาดเล็กโดยใช้ MobileNetV2 และเพื่อตรวจจับไฟป่าโดยใช้ชุดข้อมูล FLAME ซึ่งเป็นภาพถ่ายจากอากาศยานบินไร้คนขับ (UAV) โดยนำมาทดลองกับ MobileNetV2 แบบพื้นฐานก่อน และหลังจากนั้นได้นำไปทำการทดลองเพิ่มโดยใช้ Convolutional Block Attention Module (CBAM) และการทำ Parallel Attention เข้ามาเพิ่มประสิทธิภาพของ MobileNetV2 จากพื้นฐานที่มีอยู่ จากการทดลองหลายครั้ง พบว่าโมเดลนี้มีอัตราความแม่นยำที่ 86.14% และคะแนน F1-Score 87.19% ซึ่งดีกว่าวิธีการใช้ MobileNetV2 แบบพื้นฐานในการตรวจจับและจำแนกไฟป่า

ในปี ค.ศ.2024 D Elizaroshan [16] ได้นำเสนอวิธีการตรวจจับไฟป่าในป่าโดยใช้ PyTorch และแอปพลิเคชัน Flask สำหรับการตรวจสอบแบบเรียลไทม์ เน้นที่ความแม่นยำและความเร็วในการตรวจจับ โดยการรวบรวมข้อมูลและการประมวลผลล่วงหน้าของชุดข้อมูลภาพถ่ายดาวเทียมเป็นหลัก ในขณะที่เดียวกันก็เน้นที่การฝึกโมเดลที่ผ่านการเพิ่มข้อมูล การทดลองนี้ได้ใช้เทคนิค DenseNet201 ซึ่งได้พิสูจน์ให้เห็นถึงความสามารถในการกำหนดรูปแบบ และสะท้อนความแตกต่างแบบไดนามิกสูงระหว่างภาพแนวตั้งและแนวนอน โดยเฉพาะอย่างยิ่งเมื่อองค์ประกอบหลักของภาพถ่ายดาวเทียมที่

พิจารณาเป็นแบบกระจายและไม่ชัดเจน งานนี้ได้ทำการรวมเข้าไว้ในเว็บแอปพลิเคชัน Flask เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ที่ใช้งานง่าย และให้ผลลัพธ์ของการตรวจจับไฟฟ้าทันทีเมื่ออัปโหลดภาพ นอกจากนี้ แนวทางนี้ยังแสดงให้เห็นว่าสามารถให้ค่าเมตริกที่ดีกว่า จึงทำให้เป็นโซลูชันที่มีประสิทธิภาพมากขึ้น ซึ่งพิสูจน์ได้จากผลการทดลอง การศึกษานี้ได้ให้แนวทางการนำข้อมูลด้านเทคโนโลยีสิ่งแวดล้อมให้ออกมาเป็นเครื่องมือที่ใช้งานง่าย สามารถนำไปใช้ได้จริง ซึ่งอาจมีความเกี่ยวข้องที่เป็นไปได้กับหน่วยงานด้านสิ่งแวดล้อมสำหรับแนวทางที่ยั่งยืนต่อสิ่งแวดล้อมในการจัดการไฟฟ้า โดยผลลัพธ์ทั้งหมดนี้เกิดขึ้นในแบบจำลองที่ใช้ร่วมกับแอปพลิเคชันเว็บ Flask เครื่องมือนี้ช่วยให้ผู้ใช้สามารถอัปโหลดภาพถ่ายดาวเทียมและการทำนายผลลัพธ์ของแบบจำลอง ทำให้ทุกคนสามารถเข้าถึงความสามารถขั้นสูงสำหรับการตรวจจับไฟฟ้าได้

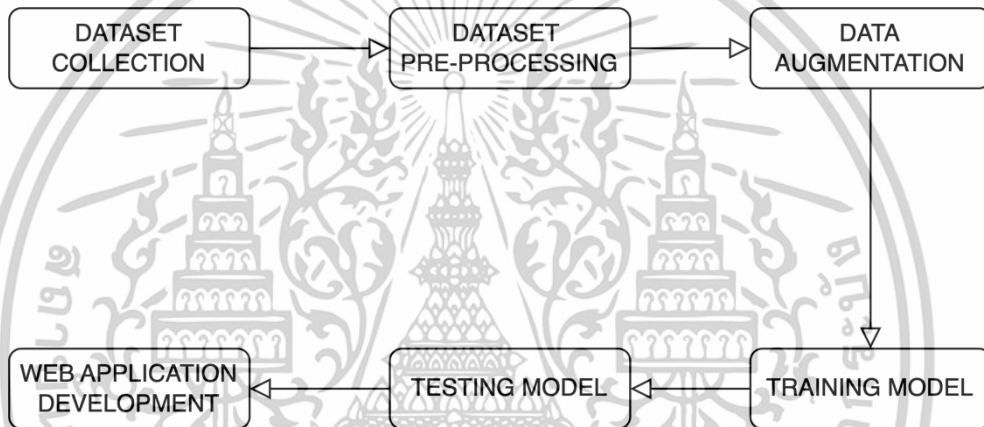


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 3

วิธีการดำเนินงานวิจัย

การวิจัยครั้งนี้มีวัตถุประสงค์ เพื่อศึกษาการใช้ Deep Learning ในการตรวจจับไฟฟ้า โดยนำความรู้เรื่อง Image Classification มาประยุกต์ใช้งาน ปัญหาที่เกิดขึ้นคือการให้ข้อมูลเพื่อเรียนรู้และแยกแยะไฟฟ้าออกจากสิ่งแวดล้อมรอบข้าง เช่น ต้นไม้ รถยนต์ บุคคล เป็นต้น ที่มีรูปร่างและสีที่มีความหลากหลาย ซึ่งจะทำให้เกิดข้อผิดพลาดในการตรวจจับไฟฟ้าหรือไฟไหม้ปกติทั่วไปได้ ซึ่งจะมีขั้นตอนวิจัยแสดงดังรูปภาพที่ 3.1



รูปที่ 3.1 แผนผังการทำงานของงานวิจัย


3.1 ข้อมูลที่ใช้ในงานวิจัย (Dataset Collection)

ในงานวิจัยนี้ได้เลือกการศึกษาค้นคว้าความหลากหลายการตรวจจับของวัตถุ ผู้วิจัยได้ดาวน์โหลดชุดข้อมูลมาจาก Roboflow Universe และ Kaggle ซึ่งเป็นชุดข้อมูลรูปภาพที่มีรูปถ่ายหลากหลายรูปแบบ รวมทั้งสิ้น 2,345 รูปภาพ ซึ่งจะนำมาวิจัยออกเป็น 3 กลุ่ม ดังนี้


- 1) กลุ่มที่ไม่มีไฟไหม้จำนวน 778 รูปภาพ
- 2) กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟฟ้าจำนวน 769 รูปภาพ
- 3) กลุ่มที่เป็นไฟฟ้าจำนวน 798 รูปภาพ

แสดงดังรูปที่ 3.2 และชุดตัวอย่างข้อมูลที่ใช้ในงานวิจัยแสดงดังรูปที่ 3.3

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.2 ข้อมูลที่ใช้ในงานวิจัย



รูปที่ 3.3 ชุดตัวอย่างข้อมูลที่ใช้ในงานวิจัย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2 การเตรียมข้อมูล (Dataset Pre-Processing)

3.2.1 ปรับแก้ขนาดของภาพ


ต้องทำการตรึงพิกัดให้ภาพและทำการปรับแก้ขนาดภาพให้มีขนาดเท่ากับ 224×224 เนื่องจากเป็นข้อมูลที่น่าไปใช้ในการเทรนโมเดล (Training Data) ซึ่งการเทรนโมเดลในส่วนของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) เนื่องจากภาพต้นฉบับมีขนาดของรูปภาพที่หลากหลาย และโมเดลไม่สามารถรับกับขนาดต้นฉบับได้ จึงจำเป็นต้องปรับแก้ขนาดให้เหลือเท่ากับ 224×224 เท่ากันทุกรูปภาพ โดยขั้นตอนนี้ผู้วิจัยได้กำหนดการปรับแก้ขนาดของภาพ ก่อนเข้าสู่ขั้นตอนการฝึกฝนโดยใช้ TensorFlow แสดงดังรูปที่ 3.4

```
resize_and_rescale = tf.keras.Sequential([
    layers.Resizing(224, 224),
])
```

รูปที่ 3.4 วิธีการปรับแก้ขนาดของภาพ

3.2.2 Data Augmentation

วิธีการนี้จะทำให้การเรียนรู้ของโมเดลมีประสิทธิภาพมากขึ้นเนื่องจาก วิธีการนี้จะทำการย่อ/ขยาย หมุน ซ้าย/ขวา Flip ซ้าย/ขวา/บน/ล่าง Crop มุม ปรับสีเข้ม/จืด ปรับแสง สว่าง/มืด ปรับ Contrast ปรับ Perspective เพิ่ม/ลด Noise เบลอภาพ เป็นต้น เพื่อให้โมเดลได้เห็นรูปภาพในหลายมิติและสามารถแก้ปัญหา Overfit ของการเทรน Convolutional Neural Network วิธีการทำ Data Augmentation แสดงดังรูปที่ 3.5



รูปที่ 3.5 วิธีการทำ Data Augmentation

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นับญาติให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.3 ขั้นตอนการฝึกฝนและทดสอบโมเดล (Training & Testing Model)

เมื่อได้เตรียมข้อมูลเสร็จสิ้นก็จะเข้าสู่ขั้นตอนการฝึกฝน โดยได้ทำการนำข้อมูลที่เตรียมเสร็จแล้วมาแบ่งออกเป็น ชุดฝึกฝน 80% และชุดทดสอบ 20% และได้มีการตั้งค่า Hyperparameter ของโมเดล เพื่อให้เหมาะสมกับงานวิจัย แสดงดังตารางที่ 3.1

ตารางที่ 3.1 Hyperparameter

Hyperparameter	Metric
Input Shape	224x224x3
Activation Hidden Layer	relu
Activation Output Layer	softmax
Optimizer	Adam
Learning Rate	0.0001
Loss Function	Cross entropy
Epochs	50
Model Checkpoint	Save Local
Early Stopping	5 patience

ซึ่งตารางดังกล่าวจะเป็น Hyperparameter ตั้งต้นของโมเดล ซึ่งงานวิจัยนี้จะนำไปใช้ทดลองกับโมเดลทั้งหมด 4 กลุ่ม 12 ประเภท ได้แก่

- 1) กลุ่มของ ResNet เลือกใช้โมเดล ดังนี้ ResNet101, ResNet152 และ ResNet152V2
- 2) กลุ่มของ DenseNet เลือกใช้โมเดล ดังนี้ DenseNet121, DenseNet169 และ DenseNet201
- 3) กลุ่มของ MobileNet เลือกใช้โมเดล ดังนี้ MobileNetV2, MobileNetV3Small และ MobileNetV3Large
- 4) กลุ่มของ EfficientNet เลือกใช้โมเดล ดังนี้ EfficientNetV2S, EfficientNetV2M และ EfficientNetV2L

3.4 ขั้นตอนการพัฒนาเว็บแอปพลิเคชัน (Web Application Development)

หลังจากทดสอบแล้ว จะนำโมเดลผลลัพธ์ที่ดีที่สุดของแต่ละกลุ่ม มาสร้างเป็นเว็บแอปพลิเคชันเพื่อให้สะดวกต่อการใช้งาน จะแบ่งเป็น Backend และ Frontend ดังนี้

3.4.1 การพัฒนาฝั่ง Backend

- 1) ทำการบันทึกโมเดลที่ดีที่สุดของแต่ละกลุ่มออกมาเป็นไฟล์ Hierarchical Data Format version 5 (HDF5 หรือ .h5) เป็นไฟล์ที่ถูกออกแบบมาเพื่อเก็บข้อมูลปริมาณมากที่มี

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โครงสร้างซับซ้อน โดยเฉพาะในงานด้านวิทยาศาสตร์ วิศวกรรม และการเรียนรู้ของเครื่อง

- 2) สร้างโปรเจ็คด้วย FastAPI Framework
- 3) พัฒนาฟังก์ชันการอัปโหลดรูปภาพเข้าสู่ระบบ
- 4) พัฒนาฟังก์ชันการปรับแก้ขนาดของรูปภาพจากต้นฉบับให้เป็นขนาด 224 x 224 ก่อนที่จะนำไปทำนายในโมเดล
- 5) พัฒนาฟังก์ชันเรียกใช้โมเดลที่ถูกบันทึกไว้เป็นไฟล์ HDF5 เพื่อใช้ในการทำนายต่อไป
- 6) พัฒนาฟังก์ชันการทำนายโดยนำรูปที่ถูกปรับแก้ขนาดมาแล้วส่งเข้าไปในโมเดลที่ถูกรเรียกใช้ แล้วให้ทำนายค่ากลับมา คือ รูปภาพที่ถูกส่งเข้ามาอยู่ใน กลุ่มที่ไม่มีไฟไหม้ กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า หรือกลุ่มที่เป็นไฟป่า พร้อมกับโมเดลที่ใช้ทำนายและเวลาที่ใช้ประมวลผลของการทำนาย
- 7) พัฒนาการเรียกใช้ API โดยนำฟังก์ชันที่กล่าวไปข้างต้นมาเชื่อมต่อกัน

3.4.2 การพัฒนาฝั่ง Frontend

- 1) สร้างโปรเจ็คด้วย React.js Framework
- 2) พัฒนาส่วนการเลือกโมเดลที่ต้องการทำนาย
- 3) พัฒนาส่วนการอัปโหลดรูปภาพเข้าสู่ระบบ
- 4) พัฒนาส่วนการเชื่อมต่อไปยังระบบ Backend เมื่อมีการเลือกโมเดลที่ต้องการทำนาย และทำการอัปโหลดรูปภาพ
- 5) พัฒนาส่วนการรับผลการทำนายจากระบบ Backend เพื่อนำมาแสดงผลบนหน้าเว็บแอปพลิเคชัน

สรุปเว็บแอปพลิเคชัน จะสามารถเลือกโมเดลที่ต้องการใช้ทำนาย และอัปโหลดรูปภาพเข้าสู่ระบบ เพื่อทำนายผลลัพธ์ออกมาว่ารูปภาพนี้อยู่ในกลุ่มที่ไม่มีไฟไหม้ กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า หรือกลุ่มที่เป็นไฟป่า พร้อมกับโมเดลที่ใช้ทำนายและเวลาที่ใช้ประมวลผลของการทำนาย

ผลการวิจัยและการอภิปรายผล

จากการวิเคราะห์ศึกษาและประยุกต์ใช้เทคโนโลยีการเรียนรู้เชิงลึกตามกระบวนการ เทคนิค และขั้นตอนต่างๆ ที่ใช้โปรแกรมที่กล่าวมาในงานวิจัยบทที่ 3 ระเบียบวิธีวิจัย ได้นำเทคนิคและกระบวนการต่างๆ มาปรับใช้ในงานวิจัยในหัวข้อการประยุกต์ใช้เทคโนโลยีการเรียนรู้เชิงลึกในการจำแนกข้อมูลจากภาพถ่ายเพื่อการจำแนกไฟไหม้ที่ไม่ใช่ไฟฟ้าและไฟไหม้ของไฟฟ้า โดยนำไปทดสอบกับกลุ่มชุดข้อมูลเดียวกันเพื่อป้องกันการ Bias และจะนำเรื่องของเวลาในการฝึกฝนเข้ามารวมด้วย เพื่อจะได้ดูความเหมาะสมต่อการนำไปใช้งานต่อไป เช่น Mobile Application ควรจะนำโมเดลที่มีขนาดเล็กแต่มีประสิทธิภาพสูงไปใช้งาน โดยมีการนำเสนอผลดังตารางที่ 4.1 ต่อไปนี้

ตารางที่ 4.1 สรุปผลการดำเนินงานวิจัย

Group	Model	Loss	Accuracy %	Precision %	Recall %	F1-Score %	Time
ResNet	ResNet152V2	0.19	92.75	92.81	92.75	92.75	3h 4min 57s
	ResNet101	1.02	46.27	54.06	46.27	40.00	2h 33min 51s
	ResNet152	1.08	43.28	38.96	43.28	32.69	3h 39min 41s
DenseNet	DenseNet169	0.23	91.47	91.62	91.47	91.51	2h 27min 57s
	DenseNet121	0.25	91.26	91.34	91.26	91.26	2h 50min 40s
	DenseNet201	0.25	91.04	91.49	91.04	91.06	5h 41min 38s
MobileNet	MobileNetV2	0.24	91.26	91.48	91.26	91.27	33min 17s
	MobileNetV3Small	1.04	46.70	32.60	46.70	36.40	1h 18min 24s
	MobileNetV3Large	1.05	43.92	74.28	43.92	34.51	1h 25min 6s
EfficientNet	EfficientNetV2S	1.08	49.25	55.78	49.25	46.12	2h 32min 28s
	EfficientNetV2L	1.02	48.61	51.49	48.61	41.26	6h 26min 55s
	EfficientNetV2M	1.10	34.33	29.03	34.33	17.91	2h 25min 16s

จากผลลัพธ์ดังตาราง 4.1 จะแสดงให้เห็นว่าผลลัพธ์การทำนายของกลุ่ม ResNet คือ ResNet152V2 มีค่าผลลัพธ์โดยเฉลี่ย 92% และใช้เวลาฝึกฝนประมาณ 3 ชั่วโมง 4 นาที ซึ่งเป็นโมเดลที่มีขนาดค่อนข้างใหญ่ ต่อมาผลลัพธ์การทำนายกลุ่ม DenseNet คือ DenseNet169 มีค่าผลลัพธ์โดยเฉลี่ย 91% และใช้เวลาฝึกฝนประมาณ 2 ชั่วโมง 27 นาที ซึ่งเป็นโมเดลที่มีขนาดกลาง ใช้เวลาลดลงจากโมเดล ResNet152V2 ต่อมาผลลัพธ์การทำนายกลุ่ม MobileNet คือ MobileNetV2 มีค่าผลลัพธ์โดยเฉลี่ย 91% และใช้เวลาฝึกฝนประมาณ 33 นาที โดยโมเดลนี้มีขนาดเล็กแต่ประสิทธิภาพสูง เหมาะสำหรับไปทำ Mobile หรือ Web Application และกลุ่มสุดท้าย กลุ่ม EfficientNet คือ EfficientNetV2S มีค่าผลลัพธ์โดยเฉลี่ย 50% และใช้เวลาฝึกฝนประมาณ 2 ชั่วโมง

32 นาที ซึ่งโมเดลกลุ่มนี้มีค่าผลลัพธ์ที่ค่อนข้างต่ำจึงอาจจะไม่เหมาะกับงานวิจัยนี้ เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ดังนั้นผู้วิจัยได้เลือกรูปภาพของแต่ละกลุ่มของ กลุ่มที่ไม่มีไฟไหม้ กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า และกลุ่มที่เป็นไฟป่า มาจำนวนกลุ่มละ 5 รูปภาพ และทำนายผลลัพธ์เปรียบเทียบความแตกต่างของแต่ละโมเดลจึงแสดงผลลัพธ์ได้ดังนี้

4.1 ผลลัพธ์การทำนายโดยใช้ ResNet152V2



รูปที่ 4.1 ผลลัพธ์การทำนายของโมเดล ResNet152V2

จากรูปที่ 4.1 โมเดลนี้มีผลลัพธ์ที่ทำนายผิดคือกลุ่มที่เป็นไฟป่ารูปภาพเดียวจากทั้งหมด 15 รูปภาพ




รูปที่ 4.2 ตาราง Confusion Matrix ของโมเดล ResNet152V2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.2 จะแสดงผลลัพธ์การทำนายดังนี้

- กลุ่มที่ไม่มีไฟไหม้ ทำนายถูก 152 รูปภาพ คิดเป็น 94.41% จาก 161 รูปภาพ
- กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า ทำนายถูก 146 รูปภาพ คิดเป็น 90.12% จาก 162 รูปภาพ
- กลุ่มที่เป็นไฟป่า ทำนายถูก 137 รูปภาพ คิดเป็น 93.84% จาก 146 รูปภาพ



รูปที่ 4.3 กราฟสรุปผลของโมเดล ResNet152V2

จากรูปที่ 4.3 กราฟสรุปผลของโมเดล ResNet152V2 ผลลัพธ์ออกมาอยู่ในเกณฑ์ที่ดีมาก ซึ่งเป็นโมเดลที่ดีที่สุดในกลุ่มของ ResNet

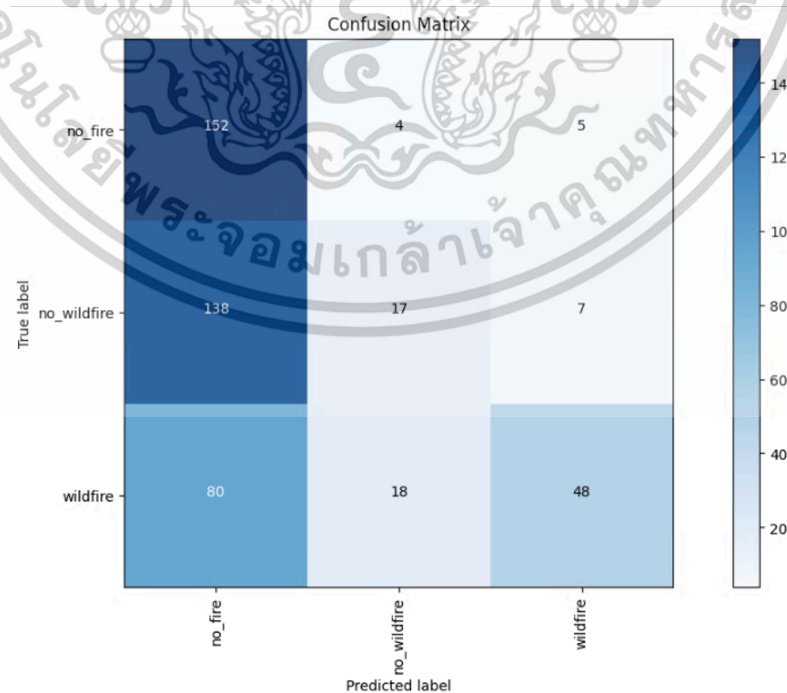
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.2 ผลลัพธ์การทำนายโดยใช้ ResNet101



รูปที่ 4.4 ผลลัพธ์การทำนายของโมเดล ResNet101

จากรูปที่ 4.4 โมเดลนี้มีผลลัพธ์ที่ทำนายผิดทั้งหมด 8 รูปภาพ จากทั้งหมด 15 รูปภาพ ส่วนใหญ่จะทำนายผิดในกลุ่มของกลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า

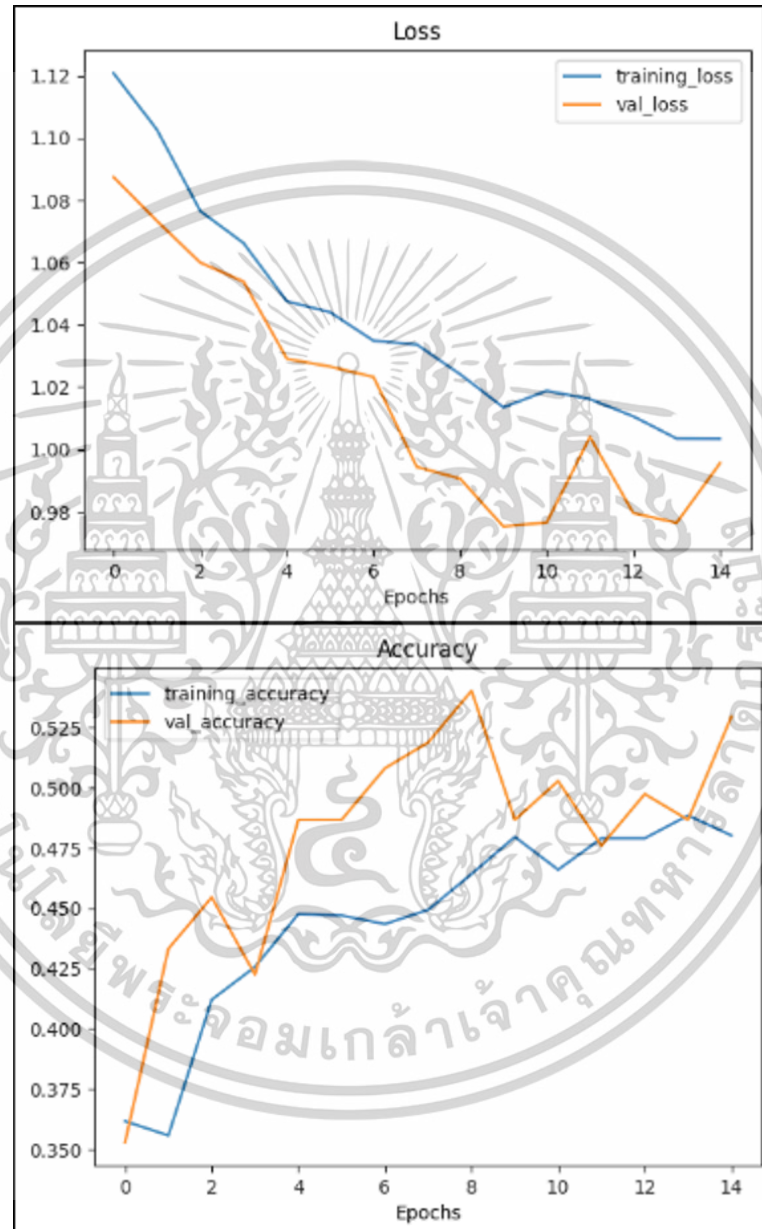


รูปที่ 4.5 ตาราง Confusion Matrix ของโมเดล ResNet101

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นำไปเผยแพร่โดยไม่ได้รับอนุญาตเห็นาไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.5 จะแสดงผลลัพธ์การทำนายดังนี้

- กลุ่มที่ไม่มีไฟไหม้ ทำนายถูก 152 รูปภาพ คิดเป็น 94.41% จาก 161 รูปภาพ
- กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า ทำนายถูก 17 รูปภาพ คิดเป็น 10.49% จาก 162 รูปภาพ
- กลุ่มที่เป็นไฟป่า ทำนายถูก 48 รูปภาพ คิดเป็น 32.88% จาก 146 รูปภาพ



รูปที่ 4.6 กราฟสรุปผลของโมเดล ResNet101

จากรูปที่ 4.6 กราฟสรุปผลของโมเดล ResNet101 ผลลัพธ์ออกมาอยู่ในเกณฑ์ที่ไม่ค่อยดี


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3 ผลลัพธ์การทำนายโดยใช้ ResNet152



รูปที่ 4.7 ผลลัพธ์การทำนายของโมเดล ResNet152

จากรูปที่ 4.7 โมเดลนี้มีผลลัพธ์ที่ทำนายผิดทั้งหมด 8 รูปภาพ จากทั้งหมด 15 รูปภาพ ส่วนใหญ่จะทำนายผิดในกลุ่มของกลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า

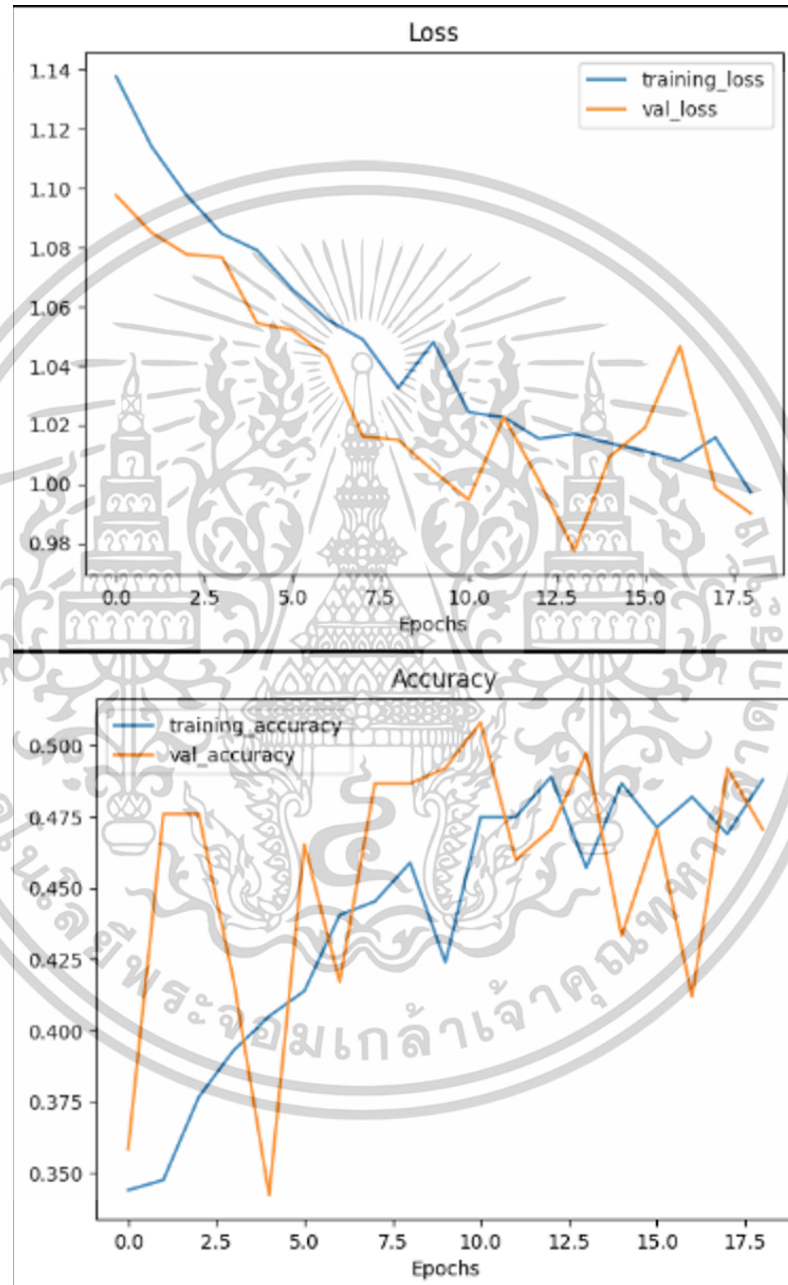


รูปที่ 4.8 ตาราง Confusion Matrix ของโมเดล ResNet152

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.8 จะแสดงผลลัพธ์การทำนายดังนี้

- กลุ่มที่ไม่มีไฟไหม้ ทำนายถูก 159 รูปภาพ คิดเป็น 98.76% จาก 161 รูปภาพ
- กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า ทำนายถูก 0 รูปภาพ คิดเป็น 0% จาก 162 รูปภาพ
- กลุ่มที่เป็นไฟป่า ทำนายถูก 44 รูปภาพ คิดเป็น 30.14% จาก 146 รูปภาพ



รูปที่ 4.9 กราฟสรุปผลของโมเดล ResNet152

จากรูปที่ 4.9 กราฟสรุปผลของโมเดล ResNet152 ผลลัพธ์ออกมาอยู่ในเกณฑ์ที่ไม่ค่อยดี

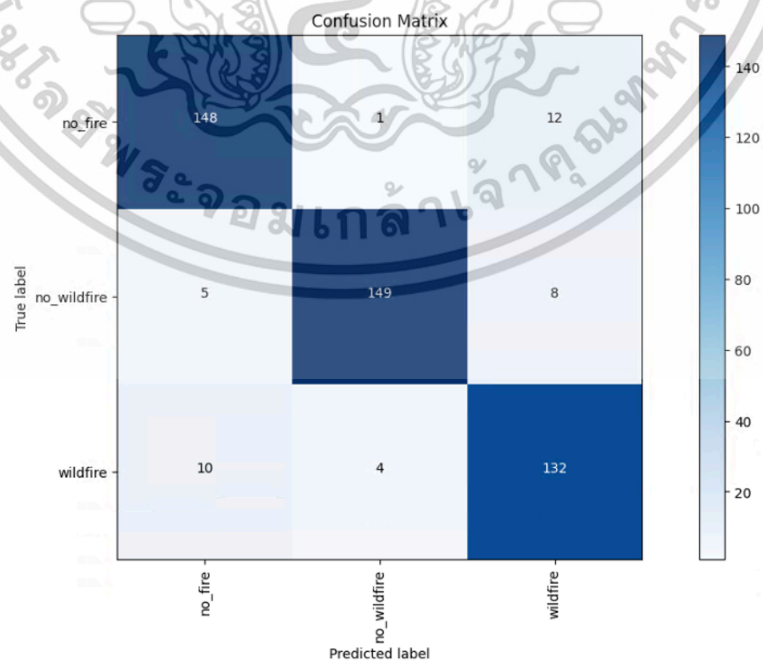
ซึ่งในกลุ่มของ ResNet จะมีแค่ ResNet152V2 แค่มอเดลเดียวที่มีเกณฑ์ที่ดี เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.4 ผลลัพธ์การทำนายโดยใช้ DenseNet169



รูปที่ 4.10 ผลลัพธ์การทำนายของโมเดล DenseNet169

จากรูปที่ 4.10 โมเดลนี้มีผลลัพธ์ที่ทำนายผิดทั้งหมด 2 รูปภาพ จากทั้งหมด 15 รูปภาพ จะทำนายผิดในกลุ่มของกลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่ากับกลุ่มที่เป็นไฟป่า

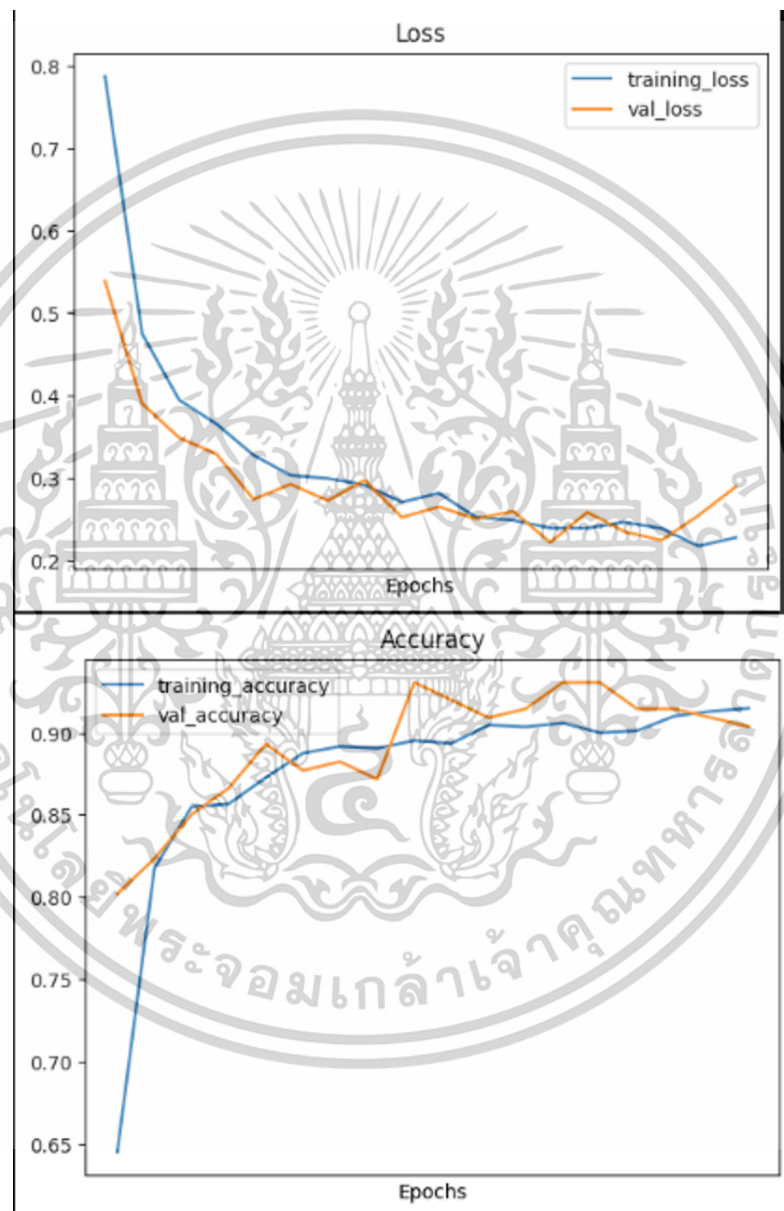


รูปที่ 4.11 ตาราง Confusion Matrix ของโมเดล DenseNet169

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.11 จะแสดงผลลัพธ์การทำนายดังนี้

- กลุ่มที่ไม่มีไฟไหม้ ทำนายถูก 148 รูปภาพ คิดเป็น 91.93% จาก 161 รูปภาพ
- กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า ทำนายถูก 149 รูปภาพ คิดเป็น 91.98% จาก 162 รูปภาพ
- กลุ่มที่เป็นไฟป่า ทำนายถูก 132 รูปภาพ คิดเป็น 90.41% จาก 146 รูปภาพ



รูปที่ 4.12 กราฟสรุปผลของโมเดล DenseNet169

จากรูปที่ 4.12 กราฟสรุปผลของโมเดล DenseNet169 ผลลัพธ์ออกมาอยู่ในเกณฑ์ที่ดีมาก

ซึ่งเป็นโมเดลดีที่สุดในกลุ่มของ DenseNet

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

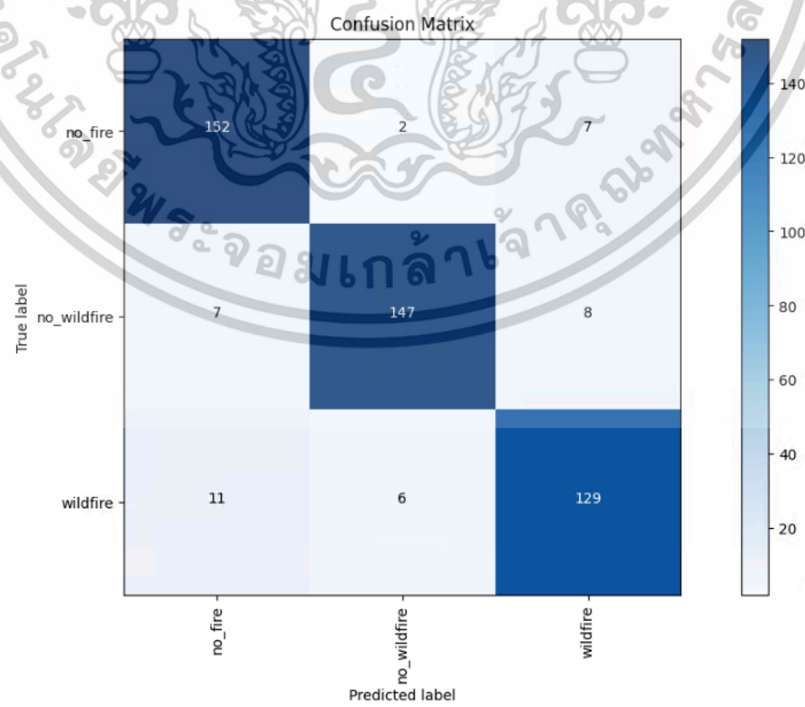
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.5 ผลลัพธ์การทำนายโดยใช้ DenseNet121



รูปที่ 4.13 ผลลัพธ์การทำนายของโมเดล DenseNet121

จากรูปที่ 4.13 โมเดลนี้มีผลลัพธ์ที่ทำนายผิดทั้งหมด 2 รูปภาพ จากทั้งหมด 15 รูปภาพ จะทำนายผิดในกลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่ากับกลุ่มที่เป็นไฟป่า

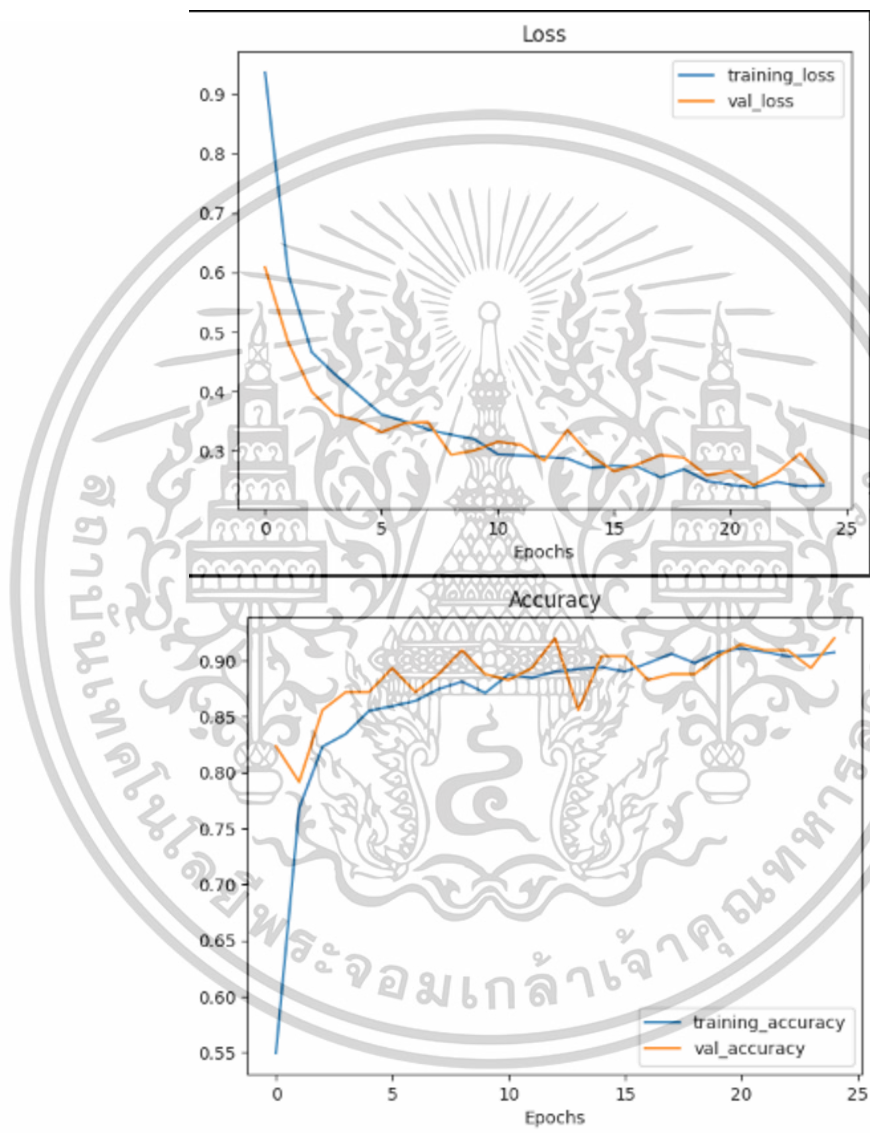


รูปที่ 4.14 ตาราง Confusion Matrix ของโมเดล DenseNet121

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.14 จะแสดงผลการทำงานของทำนายดังนี้

- กลุ่มที่ไม่มีไฟไหม้ ทำนายถูก 152 รูปภาพ คิดเป็น 94.41% จาก 161 รูปภาพ
- กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า ทำนายถูก 147 รูปภาพ คิดเป็น 90.74% จาก 162 รูปภาพ
- กลุ่มที่เป็นไฟป่า ทำนายถูก 129 รูปภาพ คิดเป็น 88.36% จาก 146 รูปภาพ



รูปที่ 4.15 กราฟสรุปผลของโมเดล DenseNet121

จากรูปที่ 4.15 กราฟสรุปผลของโมเดล DenseNet121 ผลลัพธ์ออกมาอยู่ในเกณฑ์ที่ดีมาก ซึ่งโมเดล DenseNet121 ผลลัพธ์การทำนายจะคล้ายกับ DenseNet169 ซึ่งการวัดผลโดยรวม DenseNet121 มากกว่า DenseNet169 ไม่ถึง 1%


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.6 ผลลัพธ์การทำนายโดยใช้ DenseNet201



รูปที่ 4.16 ผลลัพธ์การทำนายของโมเดล DenseNet201

จากรูปที่ 4.16 โมเดลนี้มีผลลัพธ์ที่ทำนายผิดทั้งหมด 2 รูปภาพ จากทั้งหมด 15 รูปภาพ จะทำนายผิดในกลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่ากับกลุ่มที่เป็นไฟป่า




รูปที่ 4.17 ตาราง Confusion Matrix ของโมเดล DenseNet201

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.17 จะแสดงผลลัพธ์การทำนายดังนี้

- กลุ่มที่ไม่มีไฟไหม้ ทำนายถูก 155 รูปภาพ คิดเป็น 96.27% จาก 161 รูปภาพ
- กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า ทำนายถูก 147 รูปภาพ คิดเป็น 90.74% จาก 162 รูปภาพ
- กลุ่มที่เป็นไฟป่า ทำนายถูก 125 รูปภาพ คิดเป็น 85.62% จาก 146 รูปภาพ



รูปที่ 4.18 กราฟสรุปผลของโมเดล DenseNet201


จากรูปที่ 4.18 กราฟมีผลลัพธ์ออกมาอยู่ในเกณฑ์ที่ดีมากซึ่ง DenseNet121 ผลลัพธ์การทำนายจะคล้ายกับ DenseNet121 และ DenseNet169 ดังนั้นกลุ่มของ DenseNet จะเห็นได้ว่าผลลัพธ์ออกมาอยู่ในเกณฑ์ที่ดีมากทั้งหมดแต่จะใช้เวลาในการฝึกฝนค่อนข้างนานเพราะเป็นโมเดลขนาดใหญ่ เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.7 ผลลัพธ์การทำนายโดยใช้ MobileNetV2



รูปที่ 4.19 ผลลัพธ์การทำนายของโมเดล MobileNetV2

จากรูปที่ 4.19 โมเดลนี้มีผลลัพธ์ที่ทำนายผิดทั้งหมด 2 รูปภาพ จากทั้งหมด 15 รูปภาพ จะทำนายผิดในกลุ่มที่ไม่มีไฟไหม้กับกลุ่มที่เป็นไฟป่า




รูปที่ 4.20 ตาราง Confusion Matrix ของโมเดล MobileNetV2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนำไปเผยแพร่โดยไม่ได้รับอนุญาตให้เจ้าของเอกสารทุกครั้งที่มีการนำไปใช้ ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.20 จะแสดงผลลัพธ์การทำนายดังนี้

- กลุ่มที่ไม่มีไฟไหม้ ทำนายถูก 153 รูปภาพ คิดเป็น 95.03% จาก 161 รูปภาพ
- กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า ทำนายถูก 146 รูปภาพ คิดเป็น 90.12% จาก 162 รูปภาพ
- กลุ่มที่เป็นไฟป่า ทำนายถูก 129 รูปภาพ คิดเป็น 91.49% จาก 146 รูปภาพ



รูปที่ 4.21 กราฟสรุปผลของโมเดล MobileNetV2

จากรูปที่ 4.21 กราฟสรุปผลของโมเดล MobileNetV2 ผลลัพธ์ออกมาอยู่ในเกณฑ์ที่ดีมาก ซึ่งเป็นโมเดลดีที่สุดในกลุ่มของ MobileNet

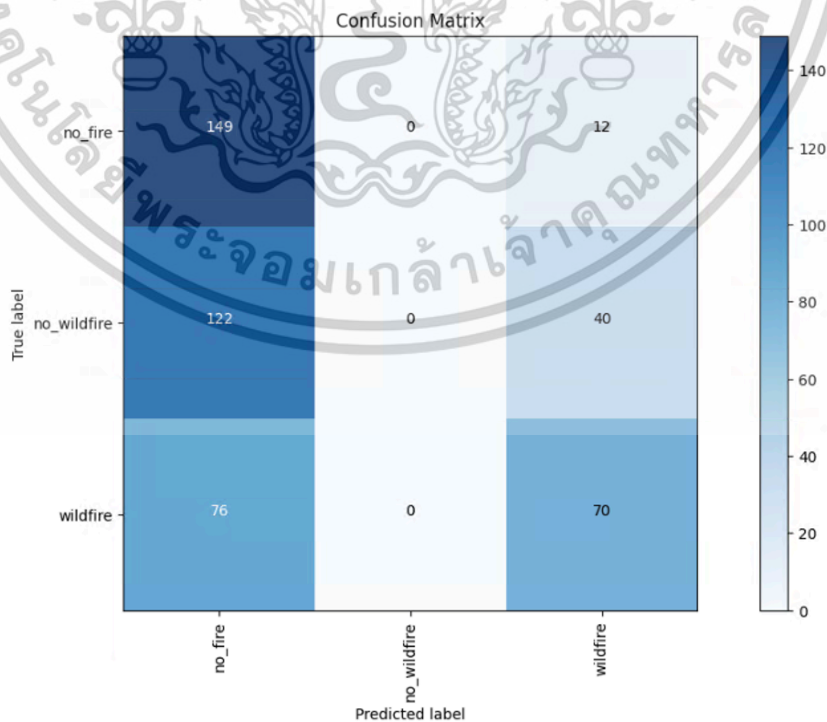
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.8 ผลลัพธ์การทำนายโดยใช้ MobileNetV3Small



รูปที่ 4.22 ผลลัพธ์การทำนายของโมเดล MobileNetV3Small

จากรูปที่ 4.22 โมเดลนี้มีผลลัพธ์ที่ทำนายผิดทั้งหมด 8 รูปภาพ จากทั้งหมด 15 รูปภาพ ส่วนใหญ่จะทำนายผิดในกลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า

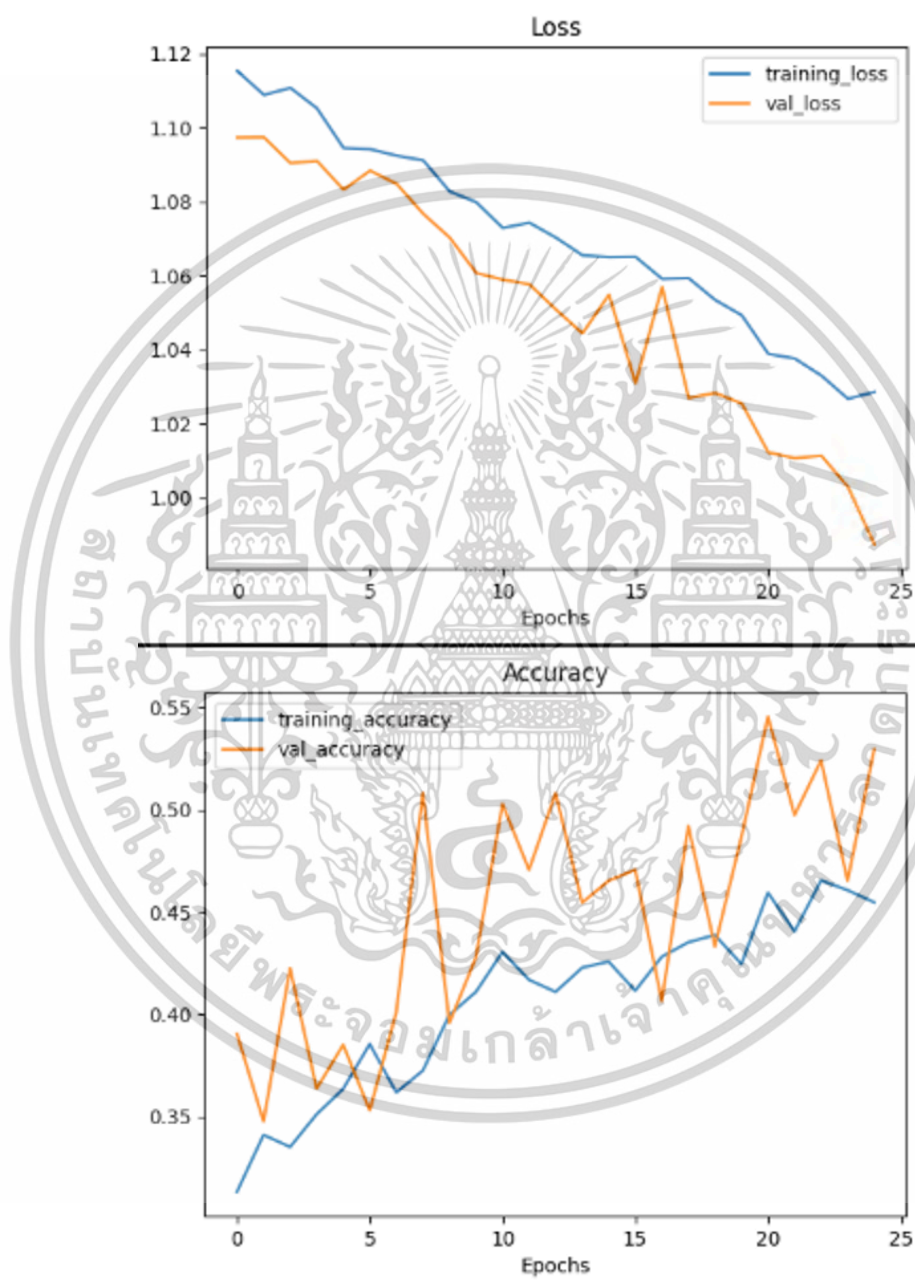


รูปที่ 4.23 ตาราง Confusion Matrix ของโมเดล MobileNetV3Small

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อผู้ดูแลเนื้อหาเบี่ยงเบนประเด็นด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.23 จะแสดงผลลัพธ์การทำนายดังนี้

- กลุ่มที่ไม่มีไฟไหม้ ทำนายถูก 149 รูปภาพ คิดเป็น 92.55% จาก 161 รูปภาพ
- กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟฟ้า ทำนายถูก 0 รูปภาพ คิดเป็น 0% จาก 162 รูปภาพ
- กลุ่มที่เป็นไฟฟ้า ทำนายถูก 70 รูปภาพ คิดเป็น 47.95% จาก 146 รูปภาพ



รูปที่ 4.24 กราฟสรุปผลของโมเดล MobileNetV3Small

จากรูปที่ 4.24 กราฟสรุปผลของโมเดล MobileNetV3Small ผลลัพธ์ออกมาอยู่ในเกณฑ์ที่

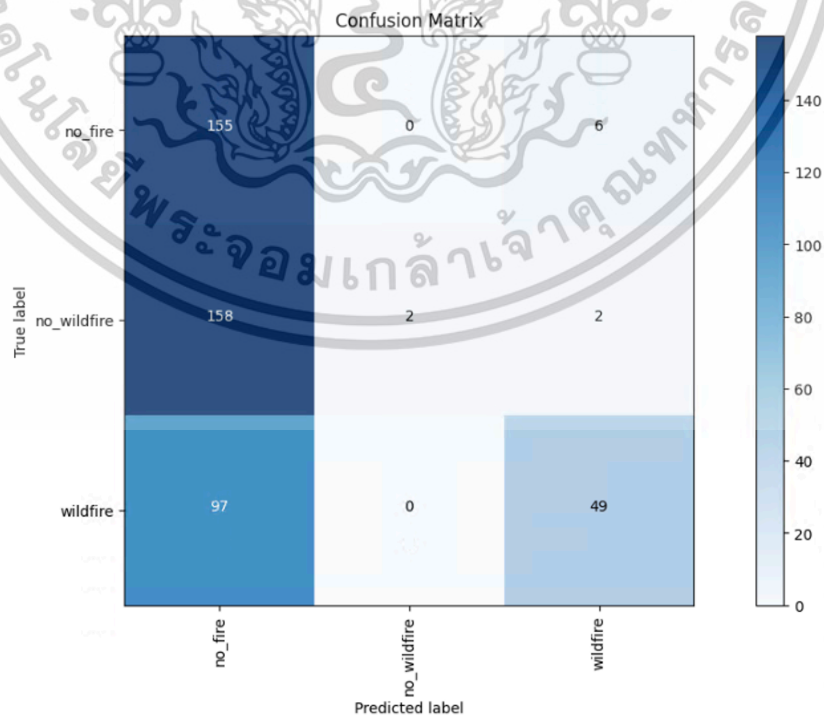
ไม่ค่อยดี เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.9 ผลลัพธ์การทำนายโดยใช้ MobileNetV3Large



รูปที่ 4.25 ผลลัพธ์การทำนายของโมเดล MobileNetV3Large

จากรูปที่ 4.25 โมเดลนี้มีผลลัพธ์ที่ทำนายผิดทั้งหมด 8 รูปภาพ จากทั้งหมด 15 รูปภาพ ส่วนใหญ่จะทำนายผิดในกลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า เหมือนกับ MobileNetV3Small

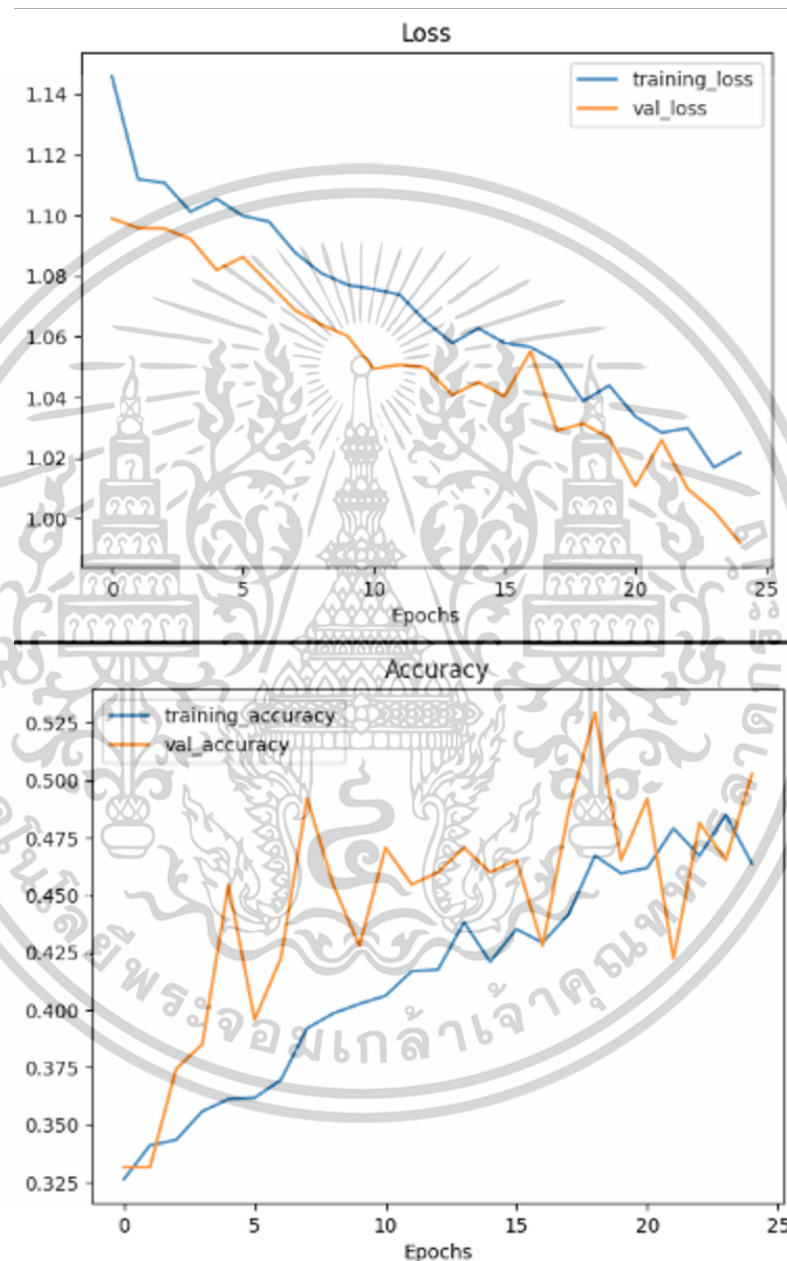


รูปที่ 4.26 ตาราง Confusion Matrix ของโมเดล MobileNetV3Large

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้เพื่อใช้ในการศึกษาเท่านั้น มิใช่เพื่อเผยแพร่ไปยังเว็บไซต์สาธารณะด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.26 จะแสดงผลลัพธ์การทำนายดังนี้

- กลุ่มที่ไม่มีไฟไหม้ ทำนายถูก 155 รูปภาพ คิดเป็น 96.27% จาก 161 รูปภาพ
- กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า ทำนายถูก 2 รูปภาพ คิดเป็น 1.23% จาก 162 รูปภาพ
- กลุ่มที่เป็นไฟป่า ทำนายถูก 0 รูปภาพ คิดเป็น 0% จาก 146 รูปภาพ



รูปที่ 4.27 กราฟสรุปผลของโมเดล MobileNetV3Large

จากรูปที่ 4.27 กราฟสรุปผลของโมเดล MobileNetV3Small ผลลัพธ์ออกมาอยู่ในเกณฑ์ที่


ไม่ค่อยดี ซึ่งในกลุ่มของ MobileNet จะมีแค่ MobileNetV2 แค่มอเดลเดียวที่มีเกณฑ์ที่ดี เอกสารนี้เป็นเอกสารที่สทงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.10 ผลลัพธ์การทำนายโดยใช้ EfficientNetV2S



รูปที่ 4.28 ผลลัพธ์การทำนายของโมเดล EfficientNetV2S

จากรูปที่ 4.28 โมเดลนี้มีผลลัพธ์ที่ทำนายผิดทั้งหมด 7 รูปภาพ จากทั้งหมด 15 รูปภาพ ส่วนใหญ่จะทำนายผิดในกลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่าและกลุ่มที่เป็นไฟป่า




รูปที่ 4.29 ตาราง Confusion Matrix ของโมเดล EfficientNetV2S

เอกสารนี้เป็นเอกสารที่ส่งมอบไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.29 จะแสดงผลลัพธ์การทำนายดังนี้

- กลุ่มที่ไม่มีไฟไหม้ ทำนายถูก 140 รูปภาพ คิดเป็น 86.96% จาก 161 รูปภาพ
- กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า ทำนายถูก 50 รูปภาพ คิดเป็น 30.86% จาก 162 รูปภาพ
- กลุ่มที่เป็นไฟป่า ทำนายถูก 41 รูปภาพ คิดเป็น 28.08% จาก 146 รูปภาพ



รูปที่ 4.30 กราฟสรุปผลของโมเดล EfficientNetV2S

จากรูปที่ 4.30 กราฟสรุปผลของโมเดล EfficientNetV2S ผลลัพธ์ออกมาอยู่ในเกณฑ์ที่ไม่ค่อยดี ถึงแม้ผลลัพธ์จะออกมาไม่ค่อยดีแต่เป็นโมเดลที่ดีที่สุดในกลุ่มของ EfficientNet

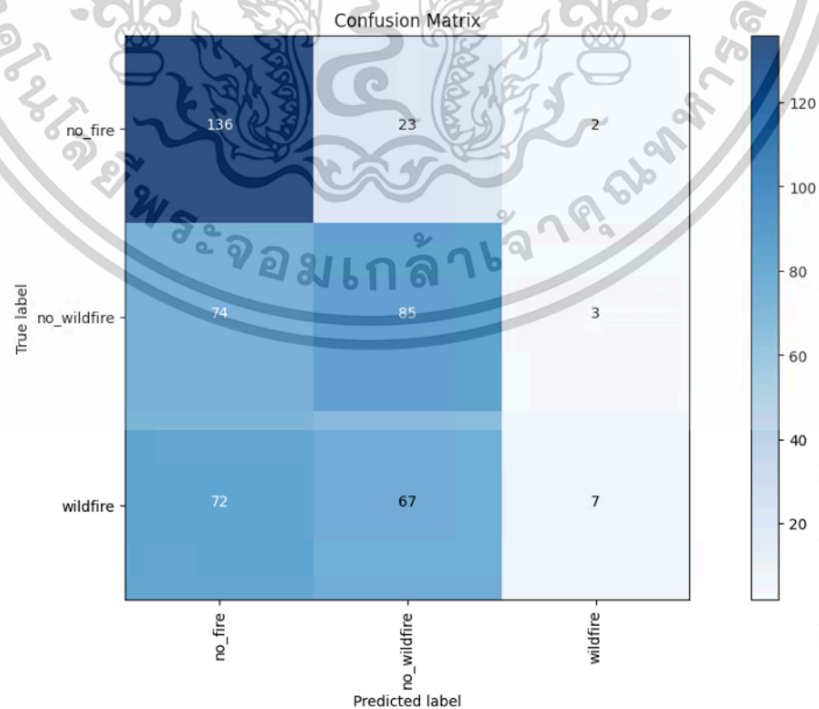
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.11 ผลลัพธ์การทำนายโดยใช้ EfficientNetV2L



รูปที่ 4.31 ผลลัพธ์การทำนายของโมเดล EfficientNetV2L

จากรูปที่ 4.31 โมเดลนี้มีผลลัพธ์ที่ทำนายผิดทั้งหมด 9 รูปภาพ จากทั้งหมด 15 รูปภาพ ส่วนใหญ่จะทำนายผิดในกลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่าและกลุ่มที่เป็นไฟป่า

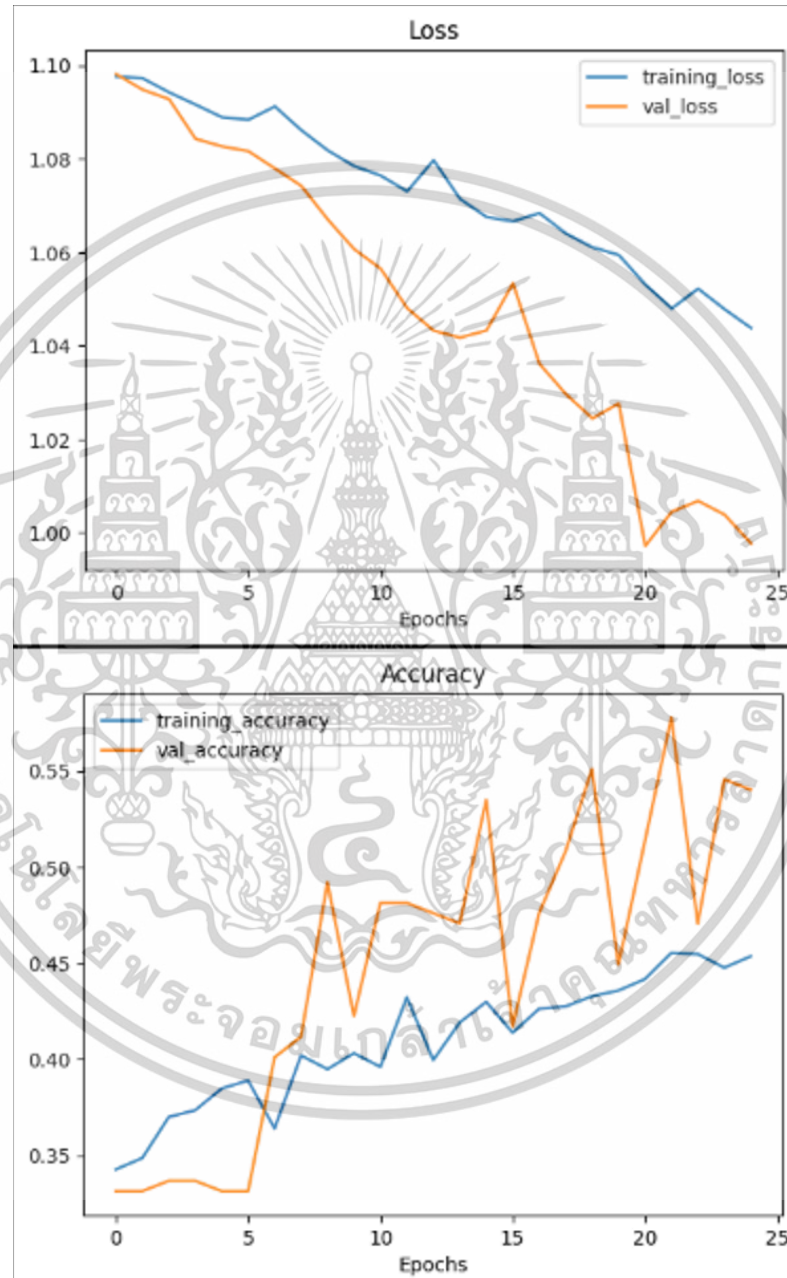


รูปที่ 4.32 ตาราง Confusion Matrix ของโมเดล EfficientNetV2L

เอกสารนี้เป็นเอกสารที่ส่งมอบไว้สำหรับบริการใช้งานเพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.32 จะแสดงผลลัพธ์การทำงานดังนี้

- กลุ่มที่ไม่มีไฟไหม้ ทำนายถูก 136 รูปภาพ คิดเป็น 84.47% จาก 161 รูปภาพ
- กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า ทำนายถูก 85 รูปภาพ คิดเป็น 52.47% จาก 162 รูปภาพ
- กลุ่มที่เป็นไฟป่า ทำนายถูก 7 รูปภาพ คิดเป็น 4.79% จาก 146 รูปภาพ



รูปที่ 4.33 กราฟสรุปผลของโมเดล EfficientNetV2L

จากรูปที่ 4.33 กราฟสรุปผลของโมเดล EfficientNetV2L ผลลัพธ์ออกมาอยู่ในเกณฑ์ที่ไม่ดี


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.12 ผลลัพธ์การทำนายโดยใช้ EfficientNetV2M



รูปที่ 4.34 ผลลัพธ์การทำนายของโมเดล EfficientNetV2M

จากรูปที่ 4.34 โมเดลนี้มีผลลัพธ์ที่ทำนายผิดพลาดทั้งหมด 10 รูปภาพ จากทั้งหมด 15 รูปภาพ ส่วนใหญ่จะทำนายผิดในกลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่าและกลุ่มที่เป็นไฟป่า

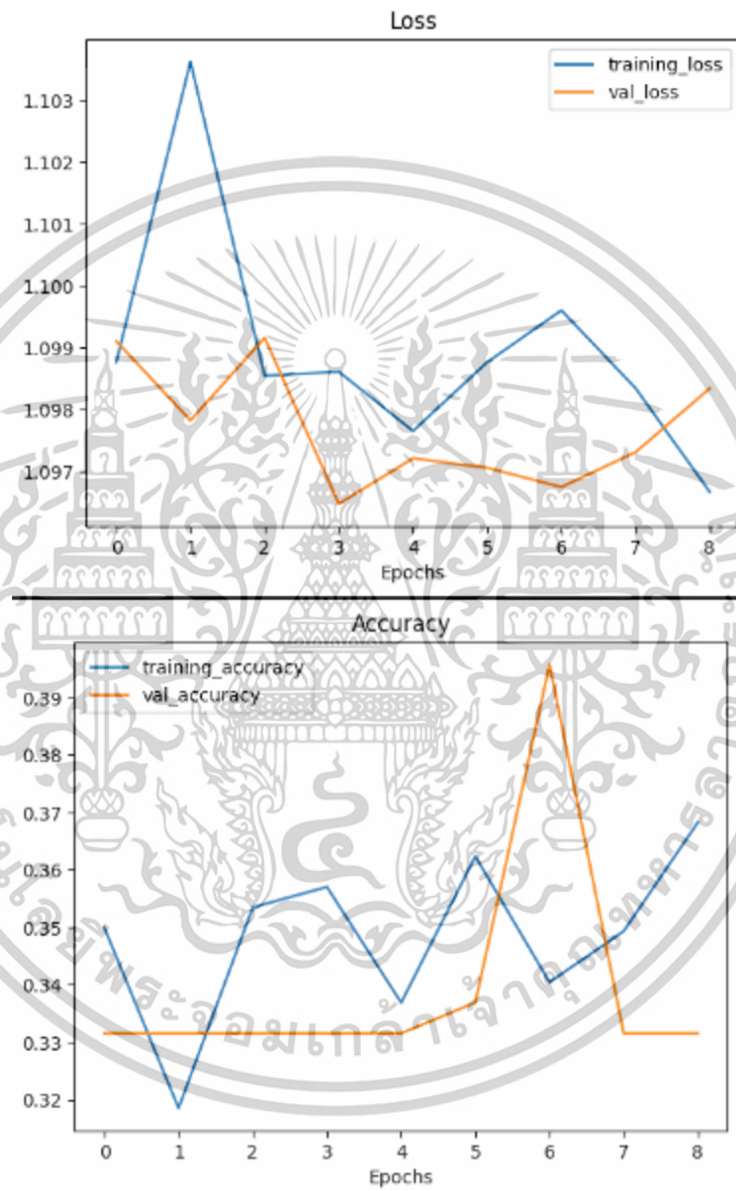


รูปที่ 4.35 ตาราง Confusion Matrix ของโมเดล EfficientNetV2M

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.35 จะแสดงผลลัพธ์การทำนายดังนี้

- กลุ่มที่ไม่มีไฟไหม้ ทำนายถูก 160 รูปภาพ คิดเป็น 99.38% จาก 161 รูปภาพ
- กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า ทำนายถูก 1 รูปภาพ คิดเป็น 0.62% จาก 162 รูปภาพ
- กลุ่มที่เป็นไฟป่า ทำนายถูก 0 รูปภาพ คิดเป็น 0% จาก 146 รูปภาพ



รูปที่ 4.36 กราฟสรุปผลของโมเดล EfficientNetV2M

จากรูปที่ 4.36 กราฟสรุปผลของโมเดล EfficientNetV2L ผลลัพธ์ออกมาอยู่ในเกณฑ์ที่ไม่ดี ซึ่งในกลุ่มของ EfficientNet เกณฑ์ที่ไม่ดีทั้งหมด ดังนั้นโมเดลกลุ่มนี้ไม่เหมาะสมกับงานวิจัยนี้ จึงไม่นำไปพัฒนาเป็นเว็บแอปพลิเคชันต่อไป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


จากผลลัพธ์ของแต่ละโมเดลที่แสดงข้างต้น ผู้วิจัยจะเลือกเฉพาะโมเดลที่ดีที่สุดในแต่ละกลุ่ม นั่นคือ ResNet152V2, DenseNet169, MobileNetV2 และ EfficientNetV2S แต่เนื่องจาก EfficientNetV2S มีผลลัพธ์ที่ไม่ค่อยดีจึงไม่ได้นำโมเดลนี้ไปใช้งานต่อ ดังนั้นจะเหลือเพียง ResNet152V2, DenseNet169 และ MobileNetV2 ที่ได้นำไปพัฒนาต่อเป็นเว็บแอปพลิเคชัน แสดงดังตารางที่ 4.2 โดยพัฒนาขึ้นมาเพื่อให้อัปโหลดรูปภาพเข้าไป และโมเดลจะทำนายผลลัพธ์ออกมาว่า รูปภาพที่อัปโหลดเข้าไปเป็นรูปภาพของ กลุ่มที่ไม่มีไฟไหม้ กลุ่มที่มีไฟแต่ไม่ใช่ไฟป่า และ กลุ่มที่เป็นไฟป่า ซึ่งเป็นตัวต้นแบบเพื่อต่อยอดไปยังอนาคตสามารถที่จะนำไปเชื่อมกับระบบอื่นต่อไปได้

ตารางที่ 4.2 สรุปผลโมเดลที่นำไปพัฒนาเป็นเว็บแอปพลิเคชัน

Group	Model	Loss	Accuracy %	Precision %	Recall %	F1-Score %	Time
ResNet	ResNet152V2	0.19	92.75	92.81	92.75	92.75	3h 4min 57s
DenseNet	DenseNet169	0.23	91.47	91.62	91.47	91.51	2h 27min 57s
MobileNet	MobileNetV2	0.24	91.26	91.48	91.26	91.27	33min 17s


4.13 วิธีการใช้งานบนเว็บแอปพลิเคชันสามารถอธิบายได้ดังนี้

1) เลือกโมเดลที่ต้องการทำนายโดยประกอบด้วย 3 โมเดล คือ MobileNet, ResNet และ DenseNet แสดงดังรูปที่ 4.37 ซึ่งโมเดลนี้อ้างอิงมาจากตารางที่ 4.2



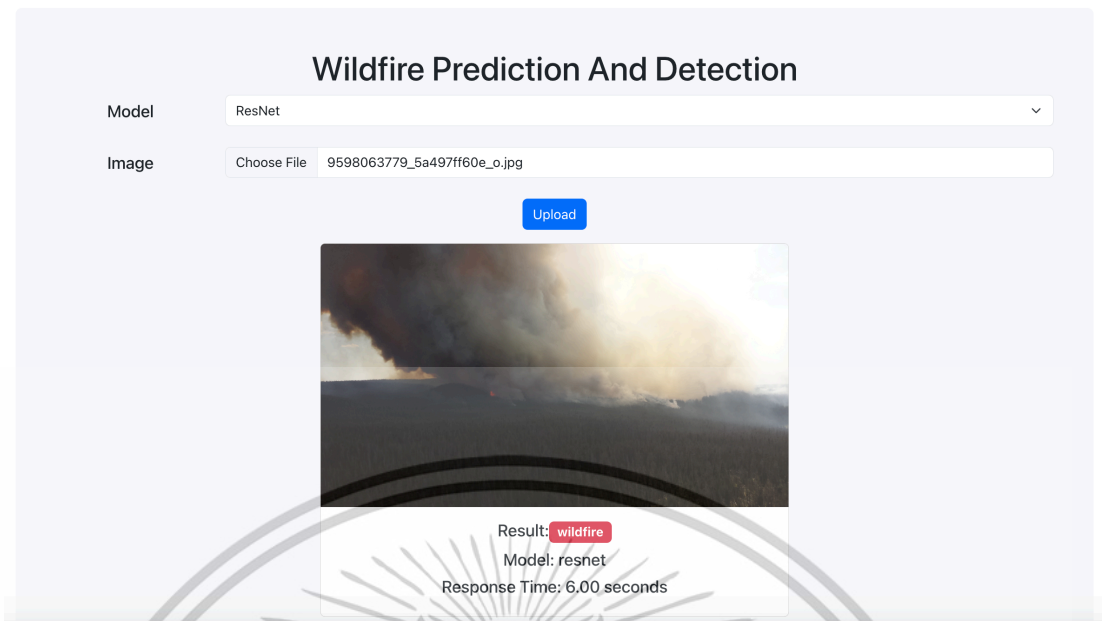
รูปที่ 4.37 เลือกโมเดลที่ต้องการใช้ทำนายของเว็บแอปพลิเคชัน

2) เลือกรูปภาพที่ต้องการทำนาย และทำการกดปุ่มอัปโหลด ดังรูปที่ 4.38



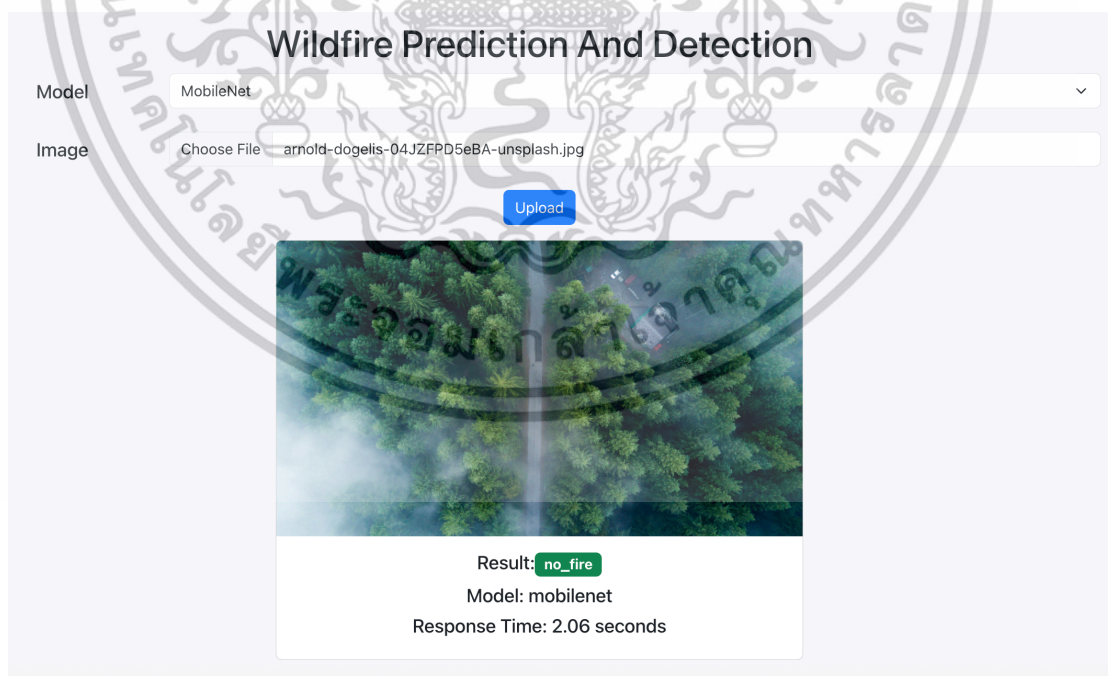
รูปที่ 4.38 การอัปโหลดรูปภาพของเว็บแอปพลิเคชัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับบริการเชิงงานเพื่อการศึกษาดูเท่านั้น เมื่ออนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.39 ผลลัพธ์เว็บแอปพลิเคชันในการทำนายไฟป่า

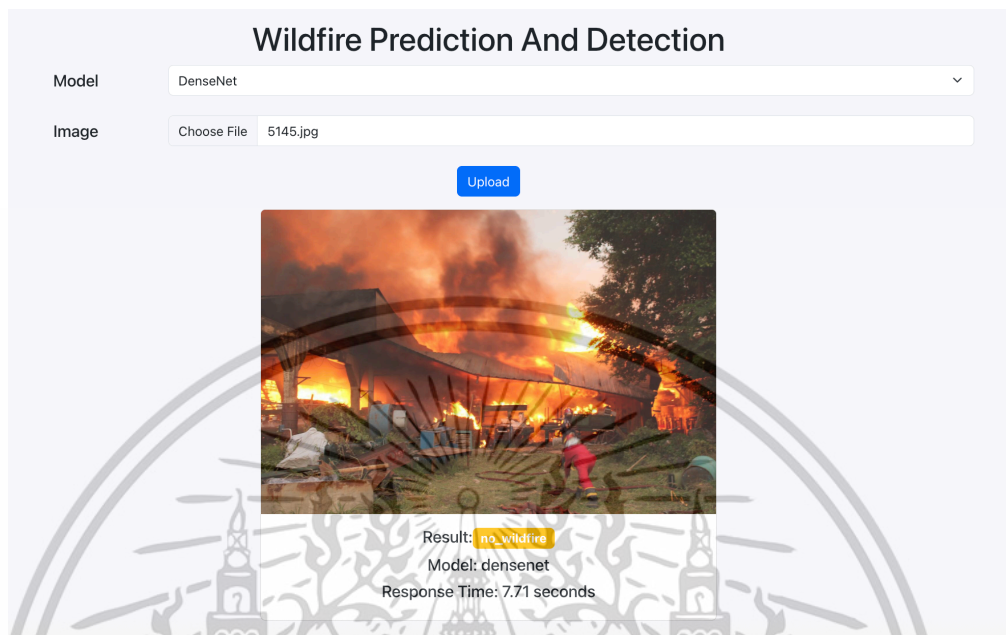
เมื่อเลือกโมเดลและอัปโหลดรูปภาพที่ต้องการทำนายแล้วกดปุ่มอัปโหลดก็จะได้ผลลัพธ์แสดงดังรูปที่ 4.39 ซึ่งจะบอกว่ารูปภาพนี้เป็นกลุ่มเพลิงไหม้ไฟป่า และบอกเวลาที่โมเดลใช้ในการประมวลผลแล้วตอบกลับมาซึ่งรูปภาพนี้ใช้เวลา 6 วินาทีในการประมวลผลของโมเดล ResNet



รูปที่ 4.40 ผลลัพธ์เว็บแอปพลิเคชันของกลุ่มไม่มีไฟไหม้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 4.40 ซึ่งจะบอกว่ารูปภาพนี้เป็นกลุ่มไม่มีไฟไหม้ และบอกเวลาที่โมเดลใช้ในการประมวลผลแล้วตอบกลับมาซึ่งรูปภาพนี้ใช้เวลา 2.06 วินาทีในการประมวลผลของโมเดล MobileNet



รูปที่ 4.41 ผลลัพธ์เว็บแอปพลิเคชันของกลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า

รูปที่ 4.41 ซึ่งจะบอกว่ารูปภาพนี้เป็นกลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า และบอกเวลาที่โมเดลใช้ในการประมวลผลแล้วตอบกลับมาซึ่งรูปภาพนี้ใช้เวลา 7.71 วินาทีในการประมวลผลของโมเดล DenseNet

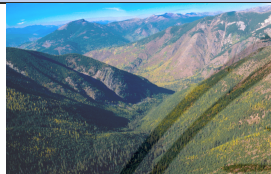








รูปที่ 4.42 ผลลัพธ์เว็บแอปพลิเคชันของกลุ่มที่เป็นไฟป่า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 4.42 ซึ่งจะบอกว่ารูปภาพนี้เป็นกลุ่มที่เป็นไฟป่า และบอกเวลาที่โมเดลใช้ในการประมวลผลแล้วตอบกลับมาซึ่งรูปภาพนี้ใช้เวลา 2.38 วินาทีในการประมวลผลของโมเดล MobileNet หลังจากที่ได้ลองทดสอบกับชุดข้อมูลเพิ่มเติมสำหรับเว็บแอปพลิเคชันที่เตรียมไว้ ซึ่งไม่ใช่ชุดข้อมูลของการฝึกฝนและทดสอบ โดยใช้กลุ่มละ 5 รูปภาพ รวมทั้งหมด 15 รูปภาพ ซึ่งโมเดลไม่เคยเห็นรูปภาพของชุดข้อมูลนี้มาก่อน แสดงผลลัพธ์ดังตารางที่ 4.3

ตารางที่ 4.3 สรุปผลการทำนายของชุดข้อมูลเพิ่มเติมสำหรับเว็บแอปพลิเคชัน

รูปภาพทดสอบ	โมเดล	ค่าจริง	ค่าทำนาย	ระยะเวลา
	ResNet	ไม่มีไฟไหม้	ไม่มีไฟไหม้	8.29 วินาที
	DenseNet		ไม่มีไฟไหม้	8.53 วินาที
	MobileNet		ไม่มีไฟไหม้	2.54 วินาที
	ResNet	ไม่มีไฟไหม้	ไฟไหม้แต่ไม่ใช่ไฟป่า	8.61 วินาที
	DenseNet		ไฟป่า	8.89 วินาที
	MobileNet		ไม่มีไฟไหม้	3.08 วินาที
	ResNet	ไม่มีไฟไหม้	ไม่มีไฟไหม้	9.15 วินาที
	DenseNet		ไม่มีไฟไหม้	9.46 วินาที
	MobileNet		ไฟป่า	3.05 วินาที
	ResNet	ไม่มีไฟไหม้	ไฟไหม้แต่ไม่ใช่ไฟป่า	8.69 วินาที
	DenseNet		ไม่มีไฟไหม้	8.15 วินาที
	MobileNet		ไม่มีไฟไหม้	2.72 วินาที
	ResNet	ไม่มีไฟไหม้	ไฟป่า	8.54 วินาที
	DenseNet		ไฟป่า	9.19 วินาที
	MobileNet		ไม่มีไฟไหม้	2.49 วินาที
	ResNet	ไฟไหม้แต่ไม่ใช่ไฟป่า	ไฟไหม้แต่ไม่ใช่ไฟป่า	6.88 วินาที
	DenseNet		ไม่มีไฟไหม้	6.66 วินาที
	MobileNet		ไฟป่า	2.36 วินาที
	ResNet	ไฟไหม้แต่ไม่ใช่ไฟป่า	ไฟไหม้แต่ไม่ใช่ไฟป่า	8.31 วินาที
	DenseNet		ไฟไหม้แต่ไม่ใช่ไฟป่า	7.19 วินาที
	MobileNet		ไฟป่า	2.38 วินาที

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.3 (ต่อ) สรุปผลการทำนายของชุดข้อมูลเพิ่มเติมสำหรับเว็บแอปพลิเคชัน

รูปภาพทดสอบ	โมเดล	ค่าจริง	ค่าทำนาย	ระยะเวลา
	ResNet	ไฟไหม้แต่ไม่ใช่ไฟป่า	ไฟไหม้แต่ไม่ใช่ไฟป่า	8.17 วินาที
	DenseNet		ไฟไหม้แต่ไม่ใช่ไฟป่า	7.25 วินาที
	MobileNet		ไฟไหม้แต่ไม่ใช่ไฟป่า	2.36 วินาที
	ResNet	ไฟไหม้แต่ไม่ใช่ไฟป่า	ไฟไหม้แต่ไม่ใช่ไฟป่า	7.15 วินาที
	DenseNet		ไฟไหม้แต่ไม่ใช่ไฟป่า	7.16 วินาที
	MobileNet		ไฟไหม้แต่ไม่ใช่ไฟป่า	2.12 วินาที
	ResNet	ไฟไหม้แต่ไม่ใช่ไฟป่า	ไฟไหม้แต่ไม่ใช่ไฟป่า	7.05 วินาที
	DenseNet		ไฟไหม้แต่ไม่ใช่ไฟป่า	7.08 วินาที
	MobileNet		ไฟไหม้แต่ไม่ใช่ไฟป่า	2.45 วินาที
	ResNet	ไฟป่า	ไฟป่า	7.48 วินาที
	DenseNet		ไฟป่า	7.25 วินาที
	MobileNet		ไฟป่า	2.60 วินาที
	ResNet	ไฟป่า	ไม่มีไฟไหม้	7.39 วินาที
	DenseNet		ไฟป่า	7.51 วินาที
	MobileNet		ไฟป่า	2.29 วินาที
	ResNet	ไฟป่า	ไฟป่า	7.32 วินาที
	DenseNet		ไฟป่า	7.39 วินาที
	MobileNet		ไฟป่า	2.34 วินาที
	ResNet	ไฟป่า	ไฟป่า	7.52 วินาที
	DenseNet		ไฟป่า	7.27 วินาที
	MobileNet		ไฟป่า	2.63 วินาที
	ResNet	ไฟป่า	ไฟป่า	7.30 วินาที
	DenseNet		ไฟป่า	7.12 วินาที
	MobileNet		ไฟป่า	2.41 วินาที

จากตารางที่ 4.3 นำมาสรุปผลของแต่ละโมเดลที่ได้ทำนายรูปภาพ ในชุดข้อมูลเพิ่มเติม สำหรับเว็บแอปพลิเคชันของแต่ละกลุ่มเพื่อให้เห็นภาพชัดมากขึ้นในการนำไปต่อยอดได้ในอนาคต แสดงดังตารางที่ 4.4

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.4 สรุปผลลัพธ์การทำนายเว็บแอปพลิเคชันของแต่ละโมเดล

โมเดล	ถูกต้อง	ผิดพลาด	เวลาทำนายต่อรูปภาพ
ResNet	11 รูปภาพ	4 รูปภาพ	6-8 วินาที
DenseNet	12 รูปภาพ	3 รูปภาพ	6-9 วินาที
MobileNet	12 รูปภาพ	3 รูปภาพ	2-3 วินาที

จากตารางที่ 4.4 จะเห็นได้ว่าโมเดล ResNet ที่มีค่าวัดผลที่ดีที่สุดแต่นำมาทำนายกับข้อมูลเพิ่มเติมสำหรับเว็บแอปพลิเคชันยังน้อยกว่าโมเดล DenseNet และ MobileNet แต่ต่างเพียง 1 รูปภาพจึงยังทำให้ทั้งสามโมเดลนี้ยังมีประสิทธิภาพใกล้เคียงกัน จึงไม่เป็นผลในมุมมองของความถูกต้องในการที่จะนำโมเดลไปใช้งานต่อ แต่หากพิจารณาถึงความเร็วในการทำนายซึ่ง MobileNet มีความเร็วที่สุดในการทำนายแล้วได้ผลลัพธ์ออกมาดี

ดังนั้น ในอนาคตหากผู้วิจัยจะนำไปต่อยอดบนแอปพลิเคชันอื่นที่มีทรัพยากรอย่างจำกัด เช่น แอปพลิเคชันมือถือ ก็สามารถเลือกโมเดลของ MobileNet ไปใช้งานเนื่องจากมีความถูกต้องในการทำนายสูงและมีความเร็วในการทำนายมากกว่าโมเดลอื่น

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

การวิจัยครั้งนี้เป็นการพัฒนาแบบจำลองด้วยเทคนิคโครงข่ายประสาทเทียมเพื่อพยากรณ์การเกิดไฟป่าจากรูปภาพ มีวัตถุประสงค์เพื่อสร้างโมเดลจำแนกไฟไหม้ที่มีความผิดปกติจากภาพถ่าย โดยแบ่งเป็น 3 ประเภท คือ กลุ่มที่ไม่มีไฟไหม้ กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า และกลุ่มที่เป็นไฟป่า เพื่อนำเสนอแนวทางในการนำโมเดลจำแนกไฟไหม้ไปใช้พัฒนาเป็นแอปพลิเคชันตรวจจับไฟป่าจากรูปภาพ

5.1.1 พัฒนาแบบจำลองการจำแนกไฟป่าจากรูปภาพ

การพัฒนาแบบจำลองการจำแนกไฟป่าจากรูปภาพนั้น ผู้วิจัยใช้วิธีโครงข่ายประสาทเทียม (Neural Network) โดยมีข้อมูลสำหรับการวิจัยประกอบด้วยข้อมูล 2 ชุดคือ Fire Detection และ The Wildfire Dataset มาทำการวิเคราะห์ เมื่อได้ข้อมูลมาแล้วก็นำมาปรับแก้รูปภาพและทำ Data Augmentation เพื่อให้นำไปใช้งานกับแบบจำลองต่อไป ซึ่งงานวิจัยนี้เลือกใช้เทคนิคของกลุ่ม Convolutional Neural Network (CNN) และใช้ร่วมกับ Transfer Learning เป็นตัวช่วยในการวิเคราะห์ ประกอบด้วย

- 1) กลุ่มของ ResNet ประกอบด้วย ResNet101 ResNet152 และ ResNet152V2
- 2) กลุ่มของ DenseNet ประกอบด้วย DenseNet121 DenseNet169 และ DenseNet201
- 3) กลุ่มของ MobileNet ประกอบด้วย MobileNetV2 MobileNetV3Small และ MobileNetV3Large
- 4) กลุ่มของ EfficientNet ประกอบด้วย EfficientNetV2S EfficientNetV2M และ EfficientNetV2L

เมื่อได้แบบจำลองที่เสร็จแล้ว นำข้อมูลจากแบบจำลองที่ได้ไปวัดผล โดยจะสรุปมาเฉพาะแบบจำลองที่ดีที่สุดของแต่ละกลุ่ม

5.1.2 แนวทางการนำแบบจำลองไปพัฒนาเป็นเว็บแอปพลิเคชัน

ผู้วิจัยนำแบบจำลองที่ได้ไปประยุกต์ใช้โดยจะนำโมเดลผลลัพธ์ที่ดีที่สุดของแต่ละกลุ่ม มาสร้างเป็นเว็บแอปพลิเคชันเพื่อให้สะดวกต่อการใช้งาน จะแบ่งเป็นสองฝั่ง คือ ฝั่งหน้าบ้านจะพัฒนาโปรแกรมด้วย React หรือที่เรียกว่า React.js และ ฝั่งหลังบ้านจะพัฒนาโปรแกรมด้วย FastAPI คือเว็บเฟรมเวิร์กสำหรับ Python โดยเว็บแอปพลิเคชันนี้ จะสามารถเลือกโมเดลที่ต้องการใช้ทำนายและอัปโหลดรูปภาพเข้าไป เพื่อทำนายผลลัพธ์ออกมาจากรูปภาพนี้อยู่ใน กลุ่มที่ไม่มีไฟไหม้ กลุ่มที่มีไฟไหม้แต่ไม่ใช่ไฟป่า และกลุ่มที่เป็นไฟป่า และแสดงผลเวลาที่ใช้ประมวลผลของการทำนาย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สรุปผลการวิจัย พบว่า เมื่อนำแบบจำลองด้วยเทคนิคโครงข่ายประสาทเทียมไปทำนายบนเว็บแอปพลิเคชัน ถึงแม้ว่าโมเดล ResNet ที่มีค่าวัดผลที่ดีที่สุดในการทดสอบ แต่นำมาทำนายกับข้อมูลเพิ่มเติมสำหรับเว็บแอปพลิเคชันก็ยังไม่ดีกว่าโมเดล DenseNet และ MobileNet แต่ต่างเพียงแค่รูปภาพเดียว จึงทำให้ทั้งสามโมเดลนี้มีประสิทธิภาพใกล้เคียงกัน จึงไม่เป็นผลในมุมมองของความถูกต้องในการที่จะนำโมเดลไปใช้งานต่อ หากพิจารณาในด้านของความเร็วในการทำนายความเร็วซึ่ง MobileNet มีความเร็วที่สุด โดยภาพรวมจากงานวิจัยนี้ สรุปได้ว่าโมเดลที่สามารถนำไปใช้กับงานเว็บแอปพลิเคชันได้ดีที่สุดได้แก่ MobileNet ซึ่งมีการทำนายผลลัพธ์ได้ดี และระยะเวลาที่ใช้ในการทำนายได้เร็วกว่าโมเดลอื่นถึงสองเท่า

5.2 ข้อจำกัด

งานวิจัยนี้ได้ถูกวิจัยภายใต้ทรัพยากรด้านฮาร์ดแวร์และเวลาที่ค่อนข้างจำกัด จึงได้คัดเลือกจำนวนรูปภาพจากแหล่งข้อมูลต้นทางทั้งหมดเหลือเพียง 2,345 รูปภาพ สำหรับการฝึกฝนในกลุ่มของ ResNet, DenseNet, MobileNet และ EfficientNet จะกำหนดรอบของ Epoch อยู่ที่ 50 รอบ เพื่อให้เหมาะสมกับทรัพยากรที่มีและเพื่อประสิทธิภาพที่เหมาะสมกับการนำไปพัฒนาต่อได้

5.3 ข้อเสนอแนะ

5.3.1 ขั้นตอนในการเตรียมข้อมูลหากนำไปใช้ในพื้นทีเฉพาะทาง ต้องเตรียมข้อมูลของพื้นที่นั้นๆ ให้โมเดลฝึกฝนเพิ่มขึ้น เพื่อให้รองรับกับสภาพแวดล้อมที่จะนำไปใช้งานจริงได้มากขึ้น

5.3.2 ถ้าผลลัพธ์ยังไม่ดี อาจจะลองทดสอบด้วยแบบจำลองอื่นๆ ที่เป็น Neural Network อาจจะไม่ใช่เพียงตระกูลของ Convolutional Neural Network เท่านั้นเพื่อผลลัพธ์ที่ดีมากขึ้น

5.3.3 สามารถนำไปพัฒนาเป็นแอปพลิเคชันอื่นๆ เช่น โมบายแอปพลิเคชัน เนื่องจากงานวิจัยนี้ได้เริ่มต้นพัฒนาที่เว็บแอปพลิเคชันเพียงอย่างเดียว

เอกสารอ้างอิง

- [1] กรมป่าไม้. 2567, “องค์ความรู้เกี่ยวกับไฟป่า” [ออนไลน์].
<https://www.forest.go.th/wp-content/uploads/2021/09/องค์ความรู้เกี่ยวกับไฟป่า.pdf>
- [2] Wikipedia contributors. 2567, “ปัญญาประดิษฐ์” [ออนไลน์].
<https://th.wikipedia.org/wiki/ปัญญาประดิษฐ์>
- [3] Wikipedia contributors. 2567, “การเรียนรู้ของเครื่อง” [ออนไลน์].
<https://th.wikipedia.org/wiki/การเรียนรู้ของเครื่อง>
- [4] Wikipedia contributors. 2567, “การเรียนรู้เชิงลึก” [ออนไลน์].
<https://th.wikipedia.org/wiki/การเรียนรู้เชิงลึก>
- [5] Natthawat Phongchit. 2561, “Convolutional Neural Network :CNN” [ออนไลน์].
<https://medium.com/@natthawatphongchit/มาลองดูวิธีการคิดของ-cnn-กัน-e3f5d73eebaa>
- [6] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun. 2015, “Deep Residual Learning for Image Recognition” [Online]. <https://arxiv.org/abs/1512.03385>
- [7] Gao Huang, Zhuang Liu, Laurens van der Maaten, Kilian Q. Weinberger. 2018, “Densely Connected Convolutional Networks” [Online].
<https://arxiv.org/abs/1608.06993>
- [8] Andrew G. Howard, Menglong Zhu, Bo Chen, Dmitry Kalenichenko, Weijun Wang, Tobias Weyand, Marco Andreetto, Hartwig Adam. 2017, “MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications” [Online].
<https://arxiv.org/abs/1704.04861>
- [9] Mingxing Tan, Quoc V. Le. 2020, “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks” [Online]. <https://arxiv.org/abs/1905.11946>
- [10] Panaya Sudta. 2023, “นักการตลาดกับ AI: Confusion Matrix และหลักการประเมินประสิทธิภาพ ML Model” [ออนไลน์]. <https://everydaymarketing.co/business-and-marketing-case-study/ai/confusion-matrix-ml-evaluation/>
- [11] Sridhar P, Rexna Devi N, Samyuktha S, Sanjeev A, Srinivasan C. 2022, “Wildfire Detection and Avoidance of false Alarm Using Densenet” [Online].
<https://ieeexplore.ieee.org/document/9984493>
- [12] Hoor Ul Ain Tahir, Abdullah Waqar, Shehzad Khalid, Syed Muhammad Usman. 2022, “Wildfire detection in aerial images using deep learning” [Online].
<https://ieeexplore.ieee.org/document/9787417>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [13] Shubhangi N. Ghate, Pallavi Sapkale, Moresh Mukhedkar. 2023, “Forest Wildfire Detection and Forecasting Utilizing Machine Learning and Image Processing” [Online]. <https://ieeexplore.ieee.org/document/10080840>
- [14] Rahmi Arda Aral, Cemil Zalluhoğlu, Ebru Akçapınar Sezer. 2023, “Wildfire Classification Using Infrared Unmanned Aerial Vehicle Data with Convolutional Neural Networks” [Online]. <https://ieeexplore.ieee.org/document/10215891>
- [15] Xinjie Deng, Burhan Khan, Chee Peng Lim, Ming-Yu Liao. 2023, “A MobileNetV2-CBAM-based Model for Forest Fire Classification Using UAV Imagery” [Online]. <https://ieeexplore.ieee.org/document/10348345>
- [16] D Elizaroshan, J.S. Raj Kumar. 2024, “Forest Wildfire Detection from Satellite Image Using Deep Learning” [Online]. <https://ieeexplore.ieee.org/document/10550351>



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

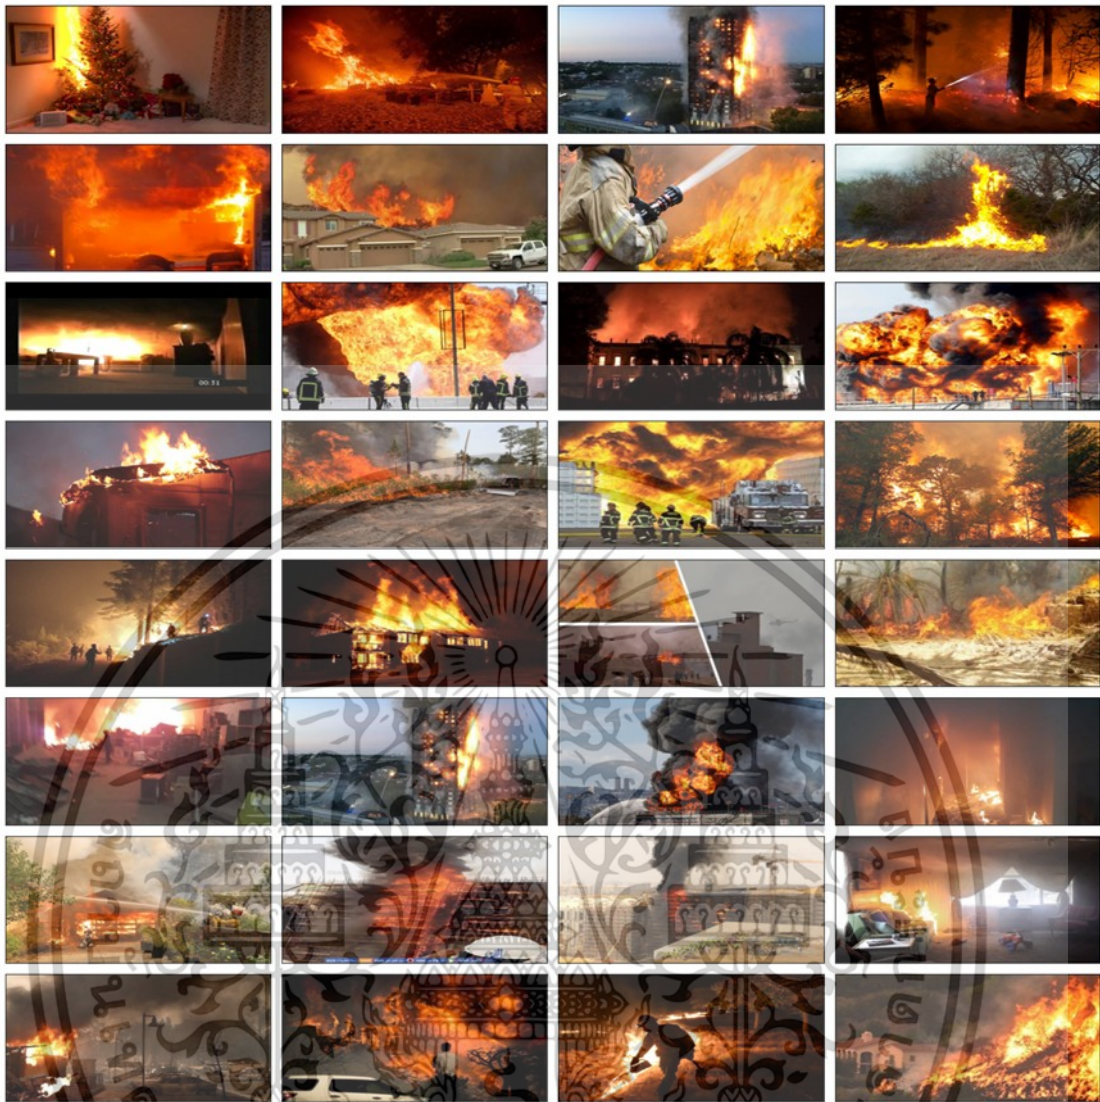


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ ก.1 กลุ่มที่ไม่มีไฟไหม้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ ก.2 กลุ่มมีไฟไหม้แต่ไม่ใช่ไฟฟ้า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ ก.3 กลุ่มที่เป็นไฟป่า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประวัติผู้เขียน

ชื่อ นาย ภูวนัย ทันเกื้อ
วัน เดือน ปีเกิด 2 พฤศจิกายน 2536
ประวัติการศึกษา 2559 วิทยาศาสตร์บัณฑิต สาขา วิทยาการคอมพิวเตอร์ เกรตเฉลี่ย 2.99
มหาวิทยาลัยทักษิณ



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้