

# Enhancing the Efficiency of Wildfire Detection Using Google's Teachable Machine

Supapit Khwanyoo<sup>1</sup>, Suabsakul Gururatana<sup>1,\*</sup>

## ABSTRACT

The objective of this study is to fine-tune hyperparameters for optimal learning performance from Google's Teachable Machine in wildfire detection and to apply in the development of a wildfire detection system. The procedure begins with researching data and theories related to wildfires and Google's Teachable Machine. Then, the data is prepared, categorized into three types: Wildfires, Smoke, No Wildfires. The data is divided into two sets: the first set, used for training, consists of 1,000 images per category and is used to train Google's Teachable Machine to find the optimal hyperparameters. The second set, used for testing, consists of 290 images per category, which have not been used in training, to measure the accuracy resulting from the hyperparameter adjustments. Using Google's Teachable Machine, the optimal hyperparameters were identified to achieve high accuracy: Epoch = 60, Batch Size = 16, and Learning Rate = 0.001. These settings resulted in an average accuracy of 97%, indicating that these hyperparameters are appropriate for use. This demonstrates that the technology can accurately detect wildfires, suggesting its potential for developing high-efficiency wildfire detection devices in the future.

**Keywords:** Machine Learning, Wildfire, Wildfire Detection, Hyperparameters

Published Online: 30 April 2025

ISSN: 3057-0778 (Online)

Supapit Khwanyoo<sup>1</sup>

<sup>1</sup>Faculty of Engineering,

Kasetsart University Sriracha Campus  
(supapit31122@gmail.com)

Suabsakul Gururatana<sup>1,\*</sup>

<sup>1</sup>Faculty of Engineering,

Kasetsart University Sriracha Campus  
(suabsakul.g@ku.th)

\*Corresponding Author

Received date: 25 August 2024

Revised date#1: 2 February 2525

Revised date#2: 9 April 2525

Accepted date: 23 April 2525

# การเพิ่มประสิทธิภาพในการตรวจจับไฟฟ้าโดยใช้ Google's Teachable Machine

ศุภาพิชญ์ ขวัญอยู่<sup>1</sup> สิบสกุล ศุรุรัตน์<sup>1,\*</sup>

## บทคัดย่อ

การวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาการปรับแต่งค่าไฮเปอร์พารามิเตอร์ให้เหมาะสมกับการเรียนรู้ข้อมูลของ Google's Teachable Machine ให้มีความแม่นยำในการตรวจจับไฟฟ้า และสามารถนำเครื่องมือ Google's Teachable Machine ไปประยุกต์ใช้ในการพัฒนาการตรวจพบการเกิดขึ้นของไฟฟ้าได้ ขั้นตอนในการดำเนินการจะเริ่มจากการศึกษาข้อมูลและทฤษฎีที่เกี่ยวข้องกับไฟฟ้าและที่ใช้ใน Google's Teachable Machine จากนั้นทำการเตรียมข้อมูลที่ใช้ แบ่งออกเป็น 3 ประเภท คือ รูปการเกิดไฟไหม้ป่า รูปควันไฟที่เกิดจากไฟไหม้ป่า และรูปไม่เกิดไฟไหม้ มีการแบ่งข้อมูลออกเป็น 2 ชุด คือ ชุดแรกข้อมูลที่ใช้เป็นชุดข้อมูลในการฝึกฝน ประเภทละ 1000 รูป ถูกนำไปสร้างเป็นการเรียนรู้ของ Google's Teachable Machine เพื่อหาค่าปรับแต่งไฮเปอร์พารามิเตอร์ที่เหมาะสม ชุดที่สองชุดข้อมูลที่ใช้ในการทดสอบจริงซึ่งเป็นรูปที่ไม่ได้ใช้เป็นชุดข้อมูลสำหรับฝึกฝนและไม่เคยเห็นมาก่อน ประเภทละ 290 รูป ใช้เพื่อหาค่าความแม่นยำที่เกิดขึ้นจากการปรับค่าไฮเปอร์พารามิเตอร์ จากการใช้ Google's Teachable Machine พบว่าค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมที่นำไปปรับใช้เพื่อให้ได้ค่าความแม่นยำที่เหมาะสม คือ Epoch = 60, Batch Size = 16, Learning Rate = 0.001 โดยได้ค่าความแม่นยำ (Accuracy) ที่ร้อยละ 97 เป็นค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมในการนำไปใช้ และแสดงให้เห็นว่าสามารถตรวจจับไฟฟ้าได้อย่างแม่นยำ ทำให้เทคโนโลยีนี้สามารถนำไปพัฒนาต่อยอดเป็นอุปกรณ์ตรวจจับไฟฟ้าที่มีประสิทธิภาพสูงได้ในอนาคต

**คำสำคัญ:** การเรียนรู้ของเครื่อง ไฟฟ้า การตรวจจับไฟฟ้า ไฮเปอร์พารามิเตอร์

Published Online: 30 เมษายน 2568

ISSN: 3057-0778 (Online)

ศุภาพิชญ์ ขวัญอยู่<sup>1</sup>

<sup>1</sup>คณะวิศวกรรมศาสตร์ ศรีราชา

มหาวิทยาลัยเกษตรศาสตร์ วิทยาเขตศรีราชา

(supapit31122@gmail.com)

สิบสกุล ศุรุรัตน์<sup>1,\*</sup>

<sup>1</sup>คณะวิศวกรรมศาสตร์ ศรีราชา

มหาวิทยาลัยเกษตรศาสตร์ วิทยาเขตศรีราชา

(suabsakul.g@ku.th)

\*Corresponding Author

Received date: 25 สิงหาคม 2567

Revised date#1: 2 กุมภาพันธ์ 2568

Revised date#2: 9 เมษายน 2568

Accepted date: 23 เมษายน 2568

## 1. บทนำ

ไฟไหม้ป่าเป็นปัญหาที่เกิดขึ้นได้จากทั้งสาเหตุธรรมชาติและการกระทำของมนุษย์ ซึ่งก่อให้เกิดความเสียหายทางทรัพยากรธรรมชาติ และส่งผลกระทบต่อสิ่งแวดล้อมอย่างรุนแรง สาเหตุจากธรรมชาติรวมถึงสภาพอากาศที่ร้อน แห้ง ฟ้าผ่า และการเสียดสีกันของกิ่งไม้ สาเหตุจากมนุษย์ เช่น การก่อไฟของนักท่องเที่ยว การทิ้งก้นบุหรี่ไม่ถูกที่ และการเผาไร่หรือสวน เป็นต้น เมื่อไฟป่าลุกลาม สามารถทำลายทรัพยากรธรรมชาติ ลดจำนวนสัตว์ป่า ทำลายแหล่งอาหาร และส่งผลกระทบต่อสุขภาพมนุษย์ผ่านการปล่อยฝุ่นละออง และการเปลี่ยนแปลงสภาพภูมิอากาศ ซึ่งอาจนำไปสู่ภาวะโลกร้อนในปัจจุบัน หลายประเทศทั่วโลกให้ความสนใจในการนำเทคโนโลยีเข้ามาใช้ในการตรวจจับไฟป่าเพื่อเพิ่มประสิทธิภาพในการป้องกันและรับมือกับเหตุการณ์ที่เกิดขึ้น หนึ่งในเทคโนโลยีที่ได้รับความนิยม คือ ปัญญาประดิษฐ์ (Artificial Intelligence หรือ AI) ซึ่งมีบทบาทสำคัญในการตรวจจับไฟป่า เช่น ใช้ในการตรวจจับหมอก ฝุ่น และควันจากการเผาไหม้ เป็นต้น โดยรวบรวมข้อมูลจากแหล่งต่าง ๆ เช่น ภาพถ่ายดาวเทียม เพื่อนำมาประมวลผล และแจ้งเตือนเจ้าหน้าที่กู้ภัย เป็นต้น นอกจากนี้ การพัฒนาโดรนดับเพลิง และเซ็นเซอร์ Internet of Things (IoT) ยังช่วยเพิ่มประสิทธิภาพในการตรวจจับ และจัดการกับไฟป่าได้อย่างแม่นยำ

หลายประเทศทั่วโลกจึงให้ความสนใจกับการนำเอาเทคโนโลยีเข้ามาใช้เพื่อการตรวจจับไฟป่า ยกตัวอย่างเช่น SAFERS เป็นอัลกอริทึม AI เป็นหนึ่งในเครื่องมือที่ใช้ในการค้นหาโดยตรวจจับหมอก ฝุ่น และควันที่เกิดจากการเผาไหม้ และตรวจสอบสถานการณ์ไฟป่า ระบบจะรวบรวมข้อมูลสนับสนุนจากแหล่งต่าง ๆ เช่น ภาพถ่ายดาวเทียม เป็นต้น ข้อมูลทั้งหมดจะถูกนำมาประมวลผลผ่านอัลกอริทึม และส่งไปยังเจ้าหน้าที่กู้ภัย หรือการพัฒนาโดรนดับเพลิงระบบ AI มาใช้งานร่วมกับเซ็นเซอร์ Internet of thing (IoT) จากผู้ให้บริการด้านดิจิทัลไลฟ์โดยบริษัท Advanced Info Service (AIS) ซึ่งกระจายอยู่ในป่าคอยทำหน้าที่ตรวจจับสัญญาณควันไฟ เพื่อตรวจจับสัญญาณควัน ความร้อน และอุณหภูมิ เพื่อแจ้งเตือนไฟป่า โดรนที่ได้รับการพัฒนาสามารถตรวจจับจุดความร้อน โดยมุ่งหน้าสู่พื้นที่ดับเพลิงโดยอัตโนมัติ เพื่อช่วยในการสำรวจพื้นที่ ตรวจสอบสถานการณ์ไฟป่า เพื่อให้เจ้าหน้าที่ได้เห็นภาพรวมของสถานการณ์ และสามารถรับมือได้อย่างแม่นยำ (Ruangsapdej, 2023)

แนวคิดของปัญญาประดิษฐ์ (Artificial Intelligence: AI) คือ การจำลองจิตสำนึก พฤติกรรม และการคิดของมนุษย์ โดยผ่านเครื่องจักร นำมาคิด วิเคราะห์ และตัดสินใจได้ โดยใช้ข้อมูลเป็นฐานในการวิเคราะห์ คาดการณ์และตัดสินใจ ทำให้ปัญญาประดิษฐ์เป็นเทคโนโลยีที่เข้ามามีบทบาทสำคัญต่อการใช้ชีวิต การทำงาน และการดำเนินธุรกิจ (Ma, 2023; Saraubon, 2022) วิธีการเรียนรู้ของเครื่อง (Machine learning) เป็นศาสตร์ย่อยหนึ่งของปัญญาประดิษฐ์ โดยมีวิธีการนำข้อมูลมาสอนให้คอมพิวเตอร์เรียนรู้แล้วสร้างส่วนที่เป็นเหมือนสมอง ให้เรียนรู้ได้เองและคิดได้เอง โดยผู้พัฒนาจะนำชุดข้อมูล (Dataset) ทั้งที่เป็นส่วนของข้อมูลและการแสดงผลเข้าไปให้คอมพิวเตอร์เรียนรู้ เพื่อสร้างส่วนของโปรแกรมที่ทำการคำนวณประมวลผล การตั้งเงื่อนไข การตัดสินใจต่างๆ ซึ่งเป็นเหมือนสมองของโปรแกรม จากนั้นผู้พัฒนาจะเขียนโปรแกรมเพิ่มเติมเพื่อให้ได้โปรแกรมที่สมบูรณ์ออกมา (Saraubon, 2020) เครื่องมือมีชื่อเรียกว่า Google's Teachable Machine เป็นเครื่องมือสร้างโมเดลการเรียนรู้ในรูปแบบเว็บ (Machine Learning Web-Base Tool) ซึ่งพัฒนาโดย Google โดยจะมีการสร้างโปรแกรมให้ภายในตัวของเครื่องมือเอง ซึ่งทำให้การสร้างโมเดลการเรียนรู้รูปแบบที่ง่าย รวดเร็ว เข้าถึงกับผู้ใช้งานทุกคน และสามารถ Export Model เพื่อนำไปพัฒนาในรูปแบบอื่นๆได้ (Janthanasub, 2022)

บทความงานวิจัยที่เกี่ยวข้องข้องพบว่าการจำแนกรูปภาพสุนัข นก แมว และดอกไม้ ใช้รูปภาพของแต่ละชนิด ชนิดละ 30 รูปภาพ และกำหนดค่าไฮเปอร์พารามิเตอร์ Epoch = 50, Batch size = 32, Learn rate = 0.001 ให้อุปกรณ์สมาร์ตโฟน Android ฝังโมเดลการเรียนรู้ด้วยเครื่องโดยใช้ Teachable Machine ของ Google ในการตรวจจับด้วยชุดข้อมูล การฝึกอบรม (Agustian, Crisnapati, Novayanti, & Pertama, 2021) สำหรับด้านทันตกรรมนั้นมีการศึกษาความเป็นไปได้ของ Teachable Machine ของ Google ในการวินิจฉัยลิ้นที่มีรอยฟัน โดยใช้รูปภาพทั้งหมด 1250 รูป โดยการใช่วิธี Teachable Machine ในการวินิจฉัยลิ้นที่มีรอยฟัน โดยการกำหนดค่าไฮเปอร์พารามิเตอร์ดังนี้ Epoch = 75, Batch size = 128, Learn rate = 0.0001 ความแม่นยำของลิ้นที่มีรอยฟัน 92.1% และลิ้นที่ไม่มีรอยฟัน

72.6% (Jeong, 2020) ในส่วนของด้านการแพทย์การพัฒนาการพยากรณ์โรคจากการวิเคราะห์รูปภาพโดยใช้ Google's Teachable Machine เพื่อวิเคราะห์ภาพผ่านปัญญาประดิษฐ์ (AI) โดยใช้ภาพส่วนที่ย้อมสีด้วย Hematoxylin and eosin (H&E) ของมะเร็งผิวหนังเมลาโน 831 รูป และใช้กลุ่มผู้ป่วย 500 คน เป็นกลุ่มฝึกอบรม และ 331 คน เป็นกลุ่มทดสอบ กลุ่มทดสอบพบว่าพยากรณ์โรคที่มี "ความเสี่ยงต่ำ" 230 คน มีอัตราการรอดชีวิตโดยรวมอยู่ที่ 93% ในกลุ่มพยากรณ์โรคที่มี "ความเสี่ยงสูง" 101 คน มีอัตราการรอดชีวิตโดยรวมที่ 77.2% (Forchhammer, Abu-Ghazaleh, Metzler, Garbe, & Eigentler, 2022) และในหัวข้อการวิจัยในปัจจุบันจากงานวิจัยที่เกี่ยวข้องการสร้างแบบจำลองการแพร่กระจายของไฟป่าการประเมินความเสี่ยงจากไฟป่า ปัจจัยที่เอื้อต่อสิ่งแวดล้อม ฝุ่นละอองที่ปล่อยออกมาจากไฟป่า โดยนำเสนอวิธีการตรวจจับโดยใช้เครื่องมือต่าง ๆ ระบบโหนดเซ็นเซอร์ไร้สาย หอสังเกตการณ์ ยานพาหนะทางอากาศไร้คนขับที่ใช้ดาวเทียม และวิธีการไฮเปอร์สเปกตรัมย่านความถี่แคบสำหรับการตรวจจับไฟป่า ซึ่งเป็นการทบทวน (Review) งานวิจัย และวิธีการตรวจจับ โดยจะเห็นได้ว่าในช่วงเวลาหลายปีที่ผ่านมาการตรวจพบไฟป่าถูกได้รับความสนใจ และพัฒนาขึ้นอยู่ตลอดเวลา (Rizanov & Yakimov, 2023)

จากการตรวจเอกสารพบว่า ไฟป่าเป็นส่วนหนึ่งที่ทำให้เกิดความสูญเสียในทรัพย์สิน ทรัพยากร และส่งผลกระทบต่อสิ่งแวดล้อม นอกจากการทำลายทรัพยากรธรรมชาติแล้ว ไฟปายังส่งผลให้เกิดภาวะโลกร้อนเนื่องจากการปล่อยก๊าซเรือนกระจกหากมีการตรวจพบไฟป่าได้ด้วยความรวดเร็วก่อนที่จะมีการลุกลามไปยังพื้นที่อื่นจะทำให้ไม่เกิดเป็นไฟป่าที่มีความรุนแรง และเจ้าหน้าที่สามารถควบคุมการลุกลามของไฟป่าได้ จะไม่ก่อให้เกิดผลกระทบต่อป่าไม้ และสัตว์ด้วยเหตุนี้ การนำเทคโนโลยีมาช่วยในการตรวจจับไฟป่าจึงมีความสำคัญ โดยเฉพาะอย่างยิ่งการใช้ปัญญาประดิษฐ์ (AI) การเรียนรู้ของเครื่องสามารถเพิ่มความแม่นยำ และประสิทธิภาพในการตรวจจับไฟป่าได้มากขึ้นโดย Google's Teachable Machine เป็นเครื่องมือหนึ่งที่ได้รับการยอมรับในด้านนี้ การนำ Google's Teachable Machine มาใช้ในการสร้างโมเดลการเรียนรู้สำหรับตรวจจับไฟป่า ทำให้การพัฒนาโมเดลการเรียนรู้เป็นเรื่องง่าย และเข้าถึงได้สำหรับทุกคน การสร้างโมเดลการเรียนรู้ด้วย Teachable Machine จะช่วยในการวิเคราะห์ข้อมูลที่จะถูกแบ่งไปตามการเรียนรู้แล้วนำไปแสดงผลให้เจ้าหน้าที่เพื่อให้มีการตรวจสอบ และเพิ่มความรวดเร็วในการตรวจจับไฟป่า และสามารถลดความเสี่ยงที่จะเกิดความเสียหายจากไฟป่าได้อย่างมีประสิทธิภาพ จึงมีการนำมาเป็นเครื่องมือในการฝึกฝน และพัฒนาเพื่อสามารถตรวจจับการเกิดไฟป่าได้อย่างแม่นยำ

งานวิจัยนี้จะเป็นส่วนหนึ่งที่จะทำให้ผู้ที่สนใจในด้านการพัฒนาการตรวจจับไฟป่า โดยมีการใช้การเรียนรู้ของเครื่อง Google's Teachable Machine ได้นำข้อมูลที่ผู้วิจัยที่ได้ศึกษาไปประยุกต์ใช้กับการเรียนรู้ของเครื่องที่จะถูกนำไปวิเคราะห์ซึ่งช่วยเพิ่มความแม่นยำและลดความผิดพลาดตรวจจับได้ และพัฒนาเครื่องมือให้มีประสิทธิภาพในการตรวจจับไฟป่าได้ดีขึ้น

## วัตถุประสงค์

ศึกษาการปรับแต่งค่าไฮเปอร์พารามิเตอร์ให้เหมาะสมเพื่อเพิ่มประสิทธิภาพการเรียนรู้ข้อมูลของ Google's Teachable Machine ให้มีความแม่นยำในการตรวจจับไฟป่า และนำไปใช้ในการพัฒนาระบบตรวจจับไฟป่าได้

## 2. วิธีการวิจัย

### 2.1 การศึกษาทฤษฎีที่เกี่ยวข้องกับงานวิจัย

#### 2.1.1. องค์ประกอบของไฟ ประเภทของไฟ และวิธีในการดับไฟ

ตามมาตรฐานของสมาคมป้องกันอัคคีภัยแห่งชาติ (National Fire Protection Association, NFPA) ของประเทศสหรัฐอเมริกา ไฟจะเกิดขึ้นได้ต้องมีองค์ประกอบสามอย่าง ได้แก่ เชื้อเพลิง (Fuel) ซึ่งเป็นวัสดุที่สามารถเผาไหม้ได้ ได้แก่ ถ่านไม้ ไม้ น้ำมันเชื้อเพลิง และก๊าซหุงต้ม ความร้อน (Heat) ซึ่งเป็นสิ่งที่ทำให้อุณหภูมิสูงขึ้นจนถึงจุดติดไฟ และออกซิเจน (Oxygen: O<sub>2</sub>) ซึ่งเป็นแก๊สที่จำเป็นสำหรับการเผาไหม้ ทั้งสามองค์ประกอบนี้เรียกรวมกันว่า "สามเหลี่ยมไฟ" (Fire Triangle) ดัง Figure 1 สำหรับความเข้าใจองค์ประกอบของไฟนั้น เป็นพื้นฐานสำคัญ

ในการจัดการ และควบคุมไฟ หากองค์ประกอบใดองค์ประกอบหนึ่งขาดหายไปไฟก็จะดับลงวิธีการดับไฟจึงมักมุ่งเน้นไปที่การขจัดหรือลดปริมาณของเชื้อเพลิง ความร้อน หรือออกซิเจน (National Fire Protection Association, n.d.)




Figure 1 The Fire Triangle (Hoyles Fire and Safety Ltd, n.d.)

ถัดมาไฟป่า (Wildfire) คือ ไฟที่เกิดจากการเผาไหม้เชื้อเพลิงธรรมชาติ เช่น เศษดิน เศษหญ้า กิ่งไม้ และใบไม้แห้ง หรือเกิดจากการกระทำของมนุษย์ เช่น การหาของป่า เผาไร่ เป็นต้น จนเกิดไฟลุกลามไหม้ ไฟป่ามักเกิดจากการติดไฟในจุดเล็กๆ ก่อนขยายตัวเป็นวงกว้างตามเชื้อเพลิง และทิศทางการลม โดยปัจจัยที่มีผลต่อพฤติกรรมของไฟป่ามีอยู่ 3 ปัจจัย ได้แก่ ลักษณะเชื้อเพลิง ลักษณะอากาศ และลักษณะภูมิประเทศ โดยเฉพาะความลาดชัน (Slope) ของภูมิประเทศที่มีอิทธิพลโดยตรงต่อทิศทาง และอัตราการลุกลามของไฟ ในอดีตไฟป่าเป็นสิ่งที่เกิดขึ้นตามธรรมชาติ และมีประโยชน์ต่อระบบนิเวศบางประเภท เช่น ป่าผลัดใบ ที่มีความชื้นน้อยเพื่อให้ออกซิเจนใหม่ และป้องกันการระบาดของโรคและแมลง อย่างไรก็ตาม ในปัจจุบันการเกิดไฟป่ามักมีสาเหตุมาจากการกระทำของมนุษย์ ทำให้ความถี่ในการเกิดไฟป่ามากขึ้น และเกิดในพื้นที่ที่ไม่ควรเกิด เช่น ป่าดิบที่ต้นไม้ไม่มีกลไกป้องกันไฟป่า ส่งผลให้เกิดความเสียหายต่อระบบนิเวศอย่างรุนแรง (Seub Nakhasathien Foundation, 2018)

### 2.1.2. หลักการ แนวคิด ทฤษฎีเกี่ยวกับปัญญาประดิษฐ์ (Artificial Intelligence, AI)

ปัญญาประดิษฐ์ เป็นเรื่องที่เกี่ยวข้องกับการศึกษาวิจัยและพัฒนาาระบบคอมพิวเตอร์รวมถึงเครื่องจักรกล ให้มีความสามารถในการจดจำ แยกแยะ ประมวลผลข้อความ ภาพ และเสียง สามารถวิเคราะห์ คิด และตัดสินใจได้ โดยใช้ข้อมูลเป็นฐานในการวิเคราะห์ คาดการณ์ และตัดสินใจ เช่น ระบบแนะนำสินค้า และบริการ โดยจะทำการเก็บข้อมูลของแต่ละบุคคล จากนั้นทำการวิเคราะห์ และเลือกแนะนำให้เหมาะสมกับความสนใจของแต่ละบุคคล (Sarabon, 2022)

### 2.1.3. การเรียนรู้ของเครื่อง (Machine learning)

การเรียนรู้ของเครื่องเป็นศาสตร์ย่อยหนึ่งของปัญญาประดิษฐ์ที่ทำให้คอมพิวเตอร์สามารถเรียนรู้จากข้อมูลได้เอง จากนั้นนำข้อมูลที่ได้จากการเรียนรู้มาใช้ในการวิเคราะห์ และคาดการณ์ เพื่อให้ AI สามารถตัดสินใจได้อย่างมีประสิทธิภาพ ในส่วนนี้บริษัท Google ได้พัฒนาแอปพลิเคชันบนเว็บที่ชื่อว่า Google's Teachable Machine ซึ่งช่วยให้ผู้ใช้งานสามารถสร้างโมเดล Machine Learning ได้อย่างรวดเร็ว ง่ายตาย และเข้าถึงได้สำหรับทุกคนออกมา (Sarabon, 2020)

### 2.1.4. Google's Teachable Machine

Teachable Machine เป็นเครื่องมือบนเว็บไซต์จาก Google ที่ช่วยให้ทุกคนสามารถสร้างโมเดลการเรียนรู้ของเครื่อง ได้อย่างรวดเร็ว ง่ายตาย และเข้าถึงได้ง่ายดัง Figure 2 โดยสามารถสร้างโมเดลการเรียนรู้ของเครื่องได้ 3 รูปแบบ ได้แก่ แบบรูปภาพ สำหรับการจำแนกรูปภาพโดยใช้ไฟล์หรือเว็บแคม, แบบเสียง สำหรับการจำแนกเสียง โดยการบันทึกตัวอย่างเสียงสั้น ๆ และแบบท่าทาง สำหรับการจำแนกตำแหน่งของร่างกายโดยใช้ไฟล์หรือท่าทางที่โดดเด่น การสร้างโมเดลด้วย Teachable Machine ใช้วิธีการ 3 ขั้นตอน ได้แก่ ขั้นแรก รวบรวม และจัดกลุ่มตัวอย่างเป็นขั้นเรียนหรือหมวดหมู่ที่ต้องการให้คอมพิวเตอร์เรียนรู้ ขั้นต่อมา ฝึกโมเดลด้วยข้อมูลที่รวบรวมไว้ และสุดท้าย ทำการทดสอบโมเดลทันที เพื่อดูว่าตัวอย่างสามารถจำแนกประเภทได้อย่างถูกต้องหรือไม่ เมื่อโมเดลผ่าน

การฝึกแล้ว สามารถส่งออกโมเดลสำหรับใช้งานในโครงการต่าง ๆ เช่น เว็บไซต์และแอปพลิเคชัน เป็นต้น นอกจากนี้ยังสามารถดาวน์โหลดโมเดลเพื่อนำไปใช้ต่อได้อีกด้วย (Google, n.d.)

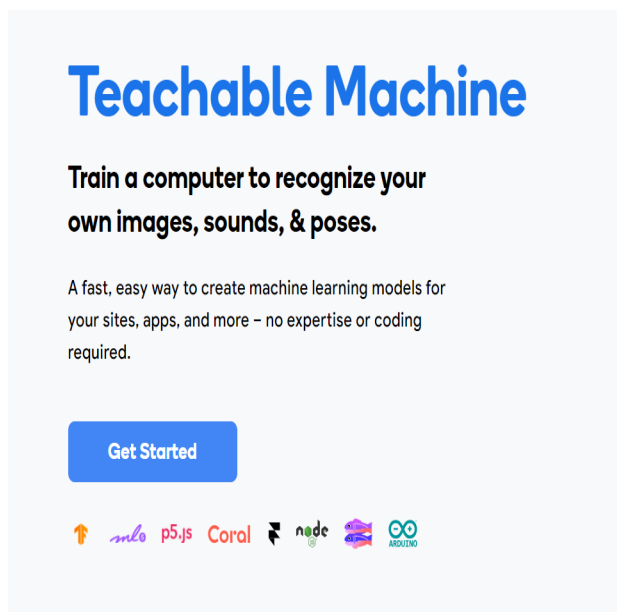


Figure 2 Google's Teachable Machine from Teachable Machine (Google, n.d.)

แนวคิดของ Convolutional Neural Network (CNN) มาจากกระบวนการรับรู้ด้านการมองเห็นของมนุษย์ ซึ่งสามารถ มองเห็น และแยกแยะวัตถุหรือภาพเป็นพื้นที่ย่อย ๆ ได้ CNN ทำงานโดยการจำแนกและดึงลักษณะเด่นในแต่ละภาพ เช่น เส้นขอบ เส้นโค้ง สี และลักษณะพื้นผิว เป็นต้น จากนั้นนำลักษณะเด่นเหล่านี้มารวมกันเพื่อวิเคราะห์ ทำการคาดการณ์ และตัดสินใจได้อย่างแม่นยำ CNN ประกอบด้วยหลายชั้นที่ทำงานร่วมกัน เพื่อดึงลักษณะเด่น และจำแนกประเภทของภาพ ชั้นแรก คือ Convolutional Layer ทำหน้าที่ดึงลักษณะเด่นจากภาพโดยใช้ฟิลเตอร์หรือเคอร์เนลที่เคลื่อนที่ผ่านภาพเพื่อสร้างแผนที่ลักษณะเด่น ชั้นที่สอง คือ Pooling Layer ลดขนาดของแผนที่ลักษณะเด่นเพื่อให้การคำนวณมีประสิทธิภาพมากขึ้น และช่วยลดความไวต่อการเปลี่ยนแปลงตำแหน่งเล็กน้อยของลักษณะเด่นในภาพ ชั้นสุดท้าย คือ Fully Connected Layer เชื่อมต่อทุกนิวรอนในชั้นก่อนหน้ากับทุกนิวรอนในชั้นนี้ เพื่อทำการรวมข้อมูลลักษณะเด่นทั้งหมด และส่งออกเป็นผลลัพธ์ที่ต้องการ เช่น การจำแนกประเภทของภาพ การทำงานร่วมกันของชั้นเหล่านี้ทำให้ CNN สามารถเรียนรู้ และจำแนกประเภทของภาพได้อย่างแม่นยำทำให้เป็นเทคโนโลยีที่มีประสิทธิภาพสูงในการประมวลผล และวิเคราะห์ภาพในหลาย ๆ ด้าน เช่น การตรวจจับวัตถุ การรู้จำใบหน้า และการตรวจจับไฟฟ้า เป็นต้น (Agustian et al., 2021)




Figure 3 Convolution Neural Network (CNN) (Agustian et al., 2021)

### 2.1.5. ไฮเปอร์พารามิเตอร์ (Hyperparameters) และการปรับแต่ง (Tuning)

ไฮเปอร์พารามิเตอร์เป็นตัวแปรใน Google's Teachable Machine ที่ต้องมีการปรับแต่งให้เหมาะสม เพื่อให้ได้การวิเคราะห์ คาดการณ์ และตัดสินใจที่แม่นยำมากขึ้น โดยไฮเปอร์พารามิเตอร์ที่สำคัญประกอบไปด้วย

2.1.5.1 Epoch หมายถึง จำนวนรอบที่โมเดลทำการฝึกอบรมกับชุดข้อมูลทั้งหมด โดยแต่ละตัวอย่างในชุดข้อมูลการฝึกอบรมจะถูกป้อนผ่านโมเดลการฝึกอบรมอย่างน้อยหนึ่งครั้ง ตัวอย่างเช่น หากกำหนด Epoch เป็น 50 หมายความว่าโมเดลจะทำงานผ่านชุดข้อมูลการฝึกทั้งหมด 50 ครั้ง การเลือกจำนวน Epoch ที่เหมาะสม จะช่วยให้โมเดลเรียนรู้ได้อย่างมีประสิทธิภาพโดยไม่เกิดการ overfitting (เรียนรู้มากเกินไป) หรือ under-fitting (เรียนรู้น้อยเกินไป)

2.1.5.2 Batch Size คือ จำนวนตัวอย่างข้อมูลที่ใช้ในหนึ่งรอบการฝึกซ้ำ (Iteration) การฝึกอบรมข้อมูล จะทำโดยการแบ่งข้อมูลออกเป็นชุดข้อมูลขนาดเล็ก ๆ แต่ละชุดเรียกว่า Batch ตัวอย่างเช่น หากมีรูปภาพ 80 รูป และเลือก Batch Size เป็น 16 หมายความว่าข้อมูลจะถูกแบ่งออกเป็น 5 ชุด ( $80 / 16 = 5$ ) และเมื่อทั้ง 5 Batches ถูกป้อนผ่านโมเดล 1 Epoch ก็จะสามารถจบรอบได้ การปรับขนาด Batch Size ที่เหมาะสมจะช่วยให้การฝึกอบรมมีประสิทธิภาพ และเสถียรภาพ

2.1.5.3 Learning Rate เป็นตัวกำหนดขนาดของขั้นตอนในการปรับปรุงค่า weights ของโมเดล ในแต่ละรอบการฝึกอบรม ค่านี้ต้องถูกกำหนดอย่างระมัดระวัง หากกำหนดค่าสูงเกินไป อาจทำให้โมเดลไม่สามารถหาค่าที่ดีที่สุดได้เนื่องจากการเปลี่ยนแปลงที่มากเกินไป แต่หากกำหนดค่าต่ำเกินไป การฝึกอบรมจะช้า และอาจไม่สามารถหาค่าที่ดีที่สุดได้ การปรับค่า Learning Rate ที่เหมาะสมเป็นสิ่งสำคัญที่จะช่วยให้การเรียนรู้ของ Teachable Machine มีความแม่นยำ และเสถียร

การปรับแต่งไฮเปอร์พารามิเตอร์ให้เหมาะสมเป็นกระบวนการที่สำคัญในการพัฒนาโมเดล Machine Learning โดยต้องมีการทดลอง และทดสอบค่าต่าง ๆ ของไฮเปอร์พารามิเตอร์ เช่น Epoch, Batch Size และ Learning Rate เป็นต้น เพื่อหาค่าที่ให้ผลลัพธ์ที่ดีที่สุดสำหรับข้อมูล และงานที่ต้องการ การปรับแต่งนี้ช่วยให้โมเดลสามารถเรียนรู้ได้อย่างมีประสิทธิภาพ โดยไม่เกิดการ overfitting (เรียนรู้มากเกินไป) หรือ underfitting (เรียนรู้น้อยเกินไป) การเลือก Epoch ที่เหมาะสมจะช่วยให้โมเดลได้รับการฝึกอบรมเพียงพอ ส่วน Batch Size ที่เหมาะสมจะช่วยให้การฝึกอบรมมีประสิทธิภาพ และเสถียรภาพ การตั้งค่า Learning Rate ที่ถูกต้องจะช่วยให้การปรับปรุงโมเดล เป็นไปอย่างรวดเร็ว และรวดเร็ว ดังนั้น การปรับแต่งไฮเปอร์พารามิเตอร์จึงเป็นกระบวนการที่ต้องใช้ความระมัดระวัง และความละเอียดรอบคอบเพื่อให้ได้โมเดลที่มีความแม่นยำสูงที่สุดในการทำนาย และการตัดสินใจ (Agustian et al., 2021; Google, n.d.)

### 2.1.6. การออกแบบการทดลอง (Design of Experiment)

การทดลองแบบแฟกทอเรียล (Factorial Experiment) คือ การทดลองที่มีวัตถุประสงค์หลักในการศึกษาผลกระทบร่วมระหว่างปัจจัยหลาย ๆ ปัจจัยพร้อมกัน โดยเลือกใช้การออกแบบการทดลองแบบแฟกทอเรียลเต็มรูปแบบ (Full Factorial Experiment) ซึ่งเป็นการทดลองที่สร้างขึ้นเพื่อศึกษาปัจจัยตั้งแต่ 2 ปัจจัยขึ้นไปในทุกกรณีที่เป็นไปได้ การออกแบบการทดลองแบบนี้จะช่วยให้เราสามารถวิเคราะห์ และทำความเข้าใจถึงปฏิสัมพันธ์ระหว่างปัจจัยต่างๆ ได้อย่างละเอียด และครบถ้วน นอกจากนี้ยังช่วยให้สามารถหาค่าที่เหมาะสมที่สุดสำหรับแต่ละปัจจัยได้อย่างแม่นยำ โดยการพิจารณาผลกระทบที่เกิดขึ้นจากการปรับเปลี่ยนค่าของปัจจัยแต่ละตัวรวมถึงผลกระทบที่เกิดจากการทำงานร่วมกันของปัจจัย (Pongpornsop, 2017)

### 2.1.7. การกำหนดประชากรและกลุ่มตัวอย่าง (Identifying Population and Sample)

เพื่อหากลุ่มตัวอย่างของรูปภาพที่ต้องการนำไปเป็นกำหนดชุดข้อมูลในการทดสอบของ Google's Teachable Machine โดยจะใช้กรณีที่มีจำนวนประชากรแน่นอน 1000 รูปภาพ และมีระดับความมีนัยสำคัญเท่ากับ 0.05 (Janjaroen, 2011) สามารถเขียนได้ดังสมการที่ (1)

$$n = \frac{N}{1+Ne^2} \quad (1)$$

หรือสามารถเขียนได้ดังสมการที่ (2)

$$n = \frac{400N}{300+N} \quad (2)$$

เมื่อ  $n$  = จำนวนกลุ่มตัวอย่าง

$N$  = ขนาดของประชากร

$e$  = ความคลาดเคลื่อนของการสุ่มตัวอย่าง โดยกำหนดความคลาดเคลื่อนของการสุ่มตัวอย่างเท่ากับ 0.05

### 2.1.8. การประเมิน Model สำหรับ Machine Learning

การประเมินประสิทธิภาพความแม่นยำของ Model นั้นใช้ตาราง Confusion Matrix ที่ใช้ประเมินผลลัพธ์การทำนาย หรือผลลัพธ์จากการโปรแกรม (Pre-diction) เปรียบเทียบกับค่าจริง (Actual) ที่ได้ ดังแสดงใน Table 1 (Sarabon, 2020)

**Table 1** Example Confusion Matrix

	Predicted Positive	Predicted Negative
Actual Positive	True Positive (TP)	False Negative (FN)
Actual Negative	False Positive (FP)	True Negative (TN)

โดยมีความหมายดังนี้ True Positive (TP) = ทำนายว่าจริงและสิ่งที่เกิดขึ้นจริงก็เป็นจริงตามที่ทำนาย, True Negative (TN) = ทำนายว่าไม่จริง และสิ่งที่เกิดขึ้นจริงก็เป็นไม่จริงตามที่ทำนาย, False Positive (FP) = ทำนายว่าจริงแต่สิ่งที่เกิดขึ้นจริงกลับไม่จริง False Negative (FN) = ทำนายว่าไม่จริงแต่สิ่งที่เกิดขึ้นจริงกลับเป็นจริง

ต่อมา *Accuracy* คือ สัดส่วนร้อยละความถูกต้อง : จำนวนที่ทำนายถูกต้อง/จำนวนทั้งหมด สามารถเขียนได้ดังสมการที่ (3)

$$Accuracy = \frac{TP+TN}{All} \quad (3)$$

จากนั้น Precision ความแม่นยำของผลการทำนาย คือ Model ที่ทำนายมานั้น โดยแสดงผลในรูปร้อยละ สำหรับ *Precision (Positive)* ความแม่นยำของผลการทำนายว่าเป็นของดี สามารถเขียนได้ดังสมการที่ (4)

$$Precision (Positive) = \frac{TP}{TP+FP} \quad (4)$$

ส่วน *Precision (Negative)* ความแม่นยำของผลการทำนายว่าเป็นของเสีย สามารถเขียนได้ดังสมการที่ (5)

$$Precision (Negative) = \frac{TN}{TN+FN} \quad (5)$$

ถัดมา Recall การวัดความแม่นยำอีกมิติ ที่สนใจผลลัพธ์เทียบกับที่เป็นจริง (Actual) คือ Model ที่ทำนายมานั้น โดยแสดงผลในรูปร้อยละเมื่อเทียบกับของจริง สำหรับ *Recall (Positive)* หรือ ความไว (Sensitive) ของจริงมีของดี ทั้งหมดร้อยละเท่าไร ดังสมการที่ (6)

$$Recall (Positive) = \frac{TP}{TP+FN} \quad (6)$$

ต่อมา  $Recall (Negative)$  ของจริงมีของเสียทั้งหมดร้อยละเท่าไร ดังสมการที่ (7)

$$Recall (Negative) = \frac{TP}{TN+FP} \quad (7)$$

สุดท้าย  $F1 Score$  ค่าที่แสดงประสิทธิภาพ ซึ่งนำ Precision กับ Recall มาคำนวณหาค่าเฉลี่ยความแม่นยำในการตรวจจับ สามารถเขียนได้ดังสมการที่ (8)

$$F1 Score = \frac{2PR}{P+R} \quad (8)$$

โดย  $P$  = Precision ความแม่นยำของผลการทำนาย และ  $R$  = Recall การวัดความแม่นยำอีกมิติ

## 2.2 ขั้นตอนดำเนินการวิจัย

1. ศึกษาข้อมูลและทฤษฎีที่เกี่ยวข้องกับไฟป่าและที่ใช้ใน Google's Teachable Machine
2. ศึกษาโปรแกรมที่ใช้ Google's Teachable Machine

3. เตรียมข้อมูลที่ใช้ในงานวิจัย สามารถค้นหาได้จากแหล่งข้อมูลต่างๆ เช่น หนังสือพิมพ์ออนไลน์, ข่าวสารที่เผยแพร่ทาง Google ชุดข้อมูล Fire dataset ถูกสร้างขึ้นโดยทีมของ Ahmed Saied (Saied, 2020) และ NASA Space Apps Challenge ในปี 2018 โดยมีเป้าหมายที่จะใช้ชุดข้อมูลนี้เพื่อพัฒนาแบบจำลองที่สามารถจดจำรูปที่มีไฟได้ ซึ่งเผยแพร่ผ่านทางออนไลน์ Kaggle เลือกรูปที่มีขนาดของรูปที่ใหญ่กว่า 640x480 Pixel และแบ่งรูปออกเป็น 2 ชุดข้อมูล เพื่อใช้ในการวิจัยนี้ คือ ชุดข้อมูลที่ใช้ในการฝึกฝน (Train) และชุดข้อมูลในการทดสอบจริง ดังแสดงใน Table 2

3.1 ชุดข้อมูลที่ใช้ในการฝึกฝน (Train) ของ Google's Teachable Machine เพื่อสร้างโมเดลการเรียนรู้ของเครื่อง และใช้ในการศึกษาการปรับแต่งค่าไฮเปอร์พารามิเตอร์ โดยทำการจำแนกประเภทของข้อมูลที่สนใจประกอบไปด้วยรูปการเกิดไฟไหม้ป่า ดังแสดงใน Figure 4 (A) 1000 รูป, รูปควันไฟที่เกิดจากไฟไหม้ป่า ดังแสดงใน Figure 4 (B) 1000 รูป และรูปไม่เกิดไฟไหม้ ดังแสดงใน Figure 4 (C) 1000 รูป



Figure 4 Example Training Dataset image of Google's Teachable from Fire Dataset (Saied, 2020)

3.2 ชุดข้อมูลการทดสอบจริง เป็นรูปที่ไม่มีในชุดข้อมูลที่ใช้ในการฝึกฝน (Train) ของ Google's Teachable Machine มีที่มาจากรูปของผู้วิจัยเอง, จากช่องทางข่าวสารไทยรัฐ BBC และข่าวสารจากศูนย์แจ้งเตือนไฟป่า

เพื่อนำรูปไปใช้ทดสอบหาค่าความแม่นยำของข้อมูลที่ได้จากการทดสอบจริง ว่าค่าไฮเปอร์พารามิเตอร์ที่ได้จากการศึกษา การปรับแต่งค่าไฮเปอร์พารามิเตอร์มีความเหมาะสมการการเรียนรู้ของเครื่อง Google's Teachable Machine

**Table 2** The number of images in each class of data preparation.

		The number of images in each dataset	
		Training Dataset (Images)	Actual Test Dataset (Images)
Class of images	Wildfire	1000	290
	Smoke	1000	290
	No Wildfire	1000	290

จำนวนรูปของชุดข้อมูลในการทดสอบจริง ใช้สมการของการกำหนดประชากรและกลุ่มตัวอย่าง ใช้สูตรกรณีที่มีจำนวนประชากรแน่นอน เมื่อระดับความมีนัยสำคัญเท่ากับ 0.05 (Yamane, 1970: 580 -581) ในการกำหนดรูป โดยแบ่งตามประเภทของรูป ดังสมการที่ (2) คือ

$$n = \frac{400(N)}{399 + (N)}$$

$$n = \frac{400(1000)}{399 + (1000)}$$

$$n = \frac{400,000}{1399}$$

$$n \approx 286$$

n = จำนวนกลุ่มตัวอย่าง ได้มาจากการคำนวณจากสูตรข้างต้น 286 รูป นำใช้กำหนดเป็นชุดข้อมูลในการทดสอบจริง  
N = ขนาดของประชากร ได้มาจากรูปของข้อมูลที่สนใจ คือ ชุดข้อมูลที่ใช้ในการฝึกฝน (Train) ประเภทละ 1000 รูป  
จะได้ชุดข้อมูลในการทดสอบจริงที่ได้มาจากการคำนวณสูตร ประกอบไปด้วยรูปเกิดไฟไหม้ป่า 290 รูป รูปควันไฟที่เกิดจากไฟไหม้ป่า ดังแสดงใน 290 รูป และรูปไม่เกิดไฟไหม้ 290 รูป

4. กำหนดค่าไฮเปอร์พารามิเตอร์ ประกอบไปด้วย Epoch, Batch Size และ Learning rate เพื่อปรับแต่งไฮเปอร์พารามิเตอร์ (Hyperparameters Tuning) โดยใช้การออกแบบการทดลองแบบแฟกทอเรียลเต็มรูป (Full Factorial Experiment) เป็นการทดลองที่สร้างขึ้นเพื่อศึกษาปัจจัยตั้งแต่ 2 ปัจจัยขึ้นไปในทุกกรณีที่เป็นไปได้สามารถวิเคราะห์ และทำความเข้าใจถึงความสัมพันธ์ระหว่างปัจจัยต่างๆ ได้อย่างละเอียด ครบถ้วน มีรายละเอียดดังนี้

กำหนด Epochs จำนวน 6 ชุด คือ 50, 60, 70, 80, 90 และ 100, Batch Size จำนวน 6 ชุด คือ 16, 32, 64, 128, 256 และ 512 และ Learning rate จำนวน 7 ชุด คือ 0.05, 0.01, 0.005, 0.001, 0.0005, 0.0001, 0.00005 และ 0.00001 ตามลำดับ ทำการกระจายค่าต่าง ๆ แล้วหาค่าในทุกกรณีที่เป็นไปได้ที่จะเกิดขึ้นกับไฮเปอร์พารามิเตอร์ที่เกี่ยวข้อง ซึ่งจะได้ผลลัพธ์ที่เกิดขึ้นของค่าไฮเปอร์พารามิเตอร์ จำนวน  $6 \times 6 \times 8 = 288$  ชุด ดังแสดงใน Figure 5

Full Factorial Experiment																							
Epochs	Batch size	Learning Rate	Epochs	Batch size	Learning Rate	Epochs	Batch size	Learning Rate	Epochs	Batch size	Learning Rate	Epochs	Batch size	Learning Rate	Epochs	Batch size	Learning Rate						
50	16	0.05	60	16	0.05	70	16	0.05	80	16	0.05	90	16	0.05	100	16	0.05						
		0.01			0.01			0.01			0.01			0.01			0.01	0.01					
		0.005			0.005			0.005			0.005			0.005			0.005	0.005					
		0.001			0.001			0.001			0.001			0.001			0.001	0.001					
		0.0005			0.0005			0.0005			0.0005			0.0005			0.0005	0.0005					
		0.0001			0.0001			0.0001			0.0001			0.0001			0.0001	0.0001					
		0.00005			0.00005			0.00005			0.00005			0.00005			0.00005	0.00005					
		0.00001			0.00001			0.00001			0.00001			0.00001			0.00001	0.00001					
	32	0.05		0.05	0.05		0.05	0.05		0.05	0.05		0.05	0.05		0.05	0.05	0.05	0.05	0.05	0.05	0.05	0.05
		0.01		0.01	0.01		0.01	0.01		0.01	0.01		0.01	0.01		0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01
		0.005		0.005	0.005		0.005	0.005		0.005	0.005		0.005	0.005		0.005	0.005	0.005	0.005	0.005	0.005	0.005	0.005
		0.001		0.001	0.001		0.001	0.001		0.001	0.001		0.001	0.001		0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001
		0.0005		0.0005	0.0005		0.0005	0.0005		0.0005	0.0005		0.0005	0.0005		0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005
		0.0001		0.0001	0.0001		0.0001	0.0001		0.0001	0.0001		0.0001	0.0001		0.0001	0.0001	0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
		0.00005		0.00005	0.00005		0.00005	0.00005		0.00005	0.00005		0.00005	0.00005		0.00005	0.00005	0.00005	0.00005	0.00005	0.00005	0.00005	0.00005
		0.00001		0.00001	0.00001		0.00001	0.00001		0.00001	0.00001		0.00001	0.00001		0.00001	0.00001	0.00001	0.00001	0.00001	0.00001	0.00001	0.00001
	64	0.05		0.05	0.05		0.05	0.05		0.05	0.05		0.05	0.05		0.05	0.05	0.05	0.05	0.05	0.05	0.05	0.05
		0.01		0.01	0.01		0.01	0.01		0.01	0.01		0.01	0.01		0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01
		0.005		0.005	0.005		0.005	0.005		0.005	0.005		0.005	0.005		0.005	0.005	0.005	0.005	0.005	0.005	0.005	0.005
		0.001		0.001	0.001		0.001	0.001		0.001	0.001		0.001	0.001		0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001
		0.0005		0.0005	0.0005		0.0005	0.0005		0.0005	0.0005		0.0005	0.0005		0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005
		0.0001		0.0001	0.0001		0.0001	0.0001		0.0001	0.0001		0.0001	0.0001		0.0001	0.0001	0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
		0.00005		0.00005	0.00005		0.00005	0.00005		0.00005	0.00005		0.00005	0.00005		0.00005	0.00005	0.00005	0.00005	0.00005	0.00005	0.00005	0.00005
		0.00001		0.00001	0.00001		0.00001	0.00001		0.00001	0.00001		0.00001	0.00001		0.00001	0.00001	0.00001	0.00001	0.00001	0.00001	0.00001	0.00001
	128	0.05		0.05	0.05		0.05	0.05		0.05	0.05		0.05	0.05		0.05	0.05	0.05	0.05	0.05	0.05	0.05	0.05
		0.01		0.01	0.01		0.01	0.01		0.01	0.01		0.01	0.01		0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01
		0.005		0.005	0.005		0.005	0.005		0.005	0.005		0.005	0.005		0.005	0.005	0.005	0.005	0.005	0.005	0.005	0.005
		0.001		0.001	0.001		0.001	0.001		0.001	0.001		0.001	0.001		0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001
		0.0005		0.0005	0.0005		0.0005	0.0005		0.0005	0.0005		0.0005	0.0005		0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005
		0.0001		0.0001	0.0001		0.0001	0.0001		0.0001	0.0001		0.0001	0.0001		0.0001	0.0001	0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
		0.00005		0.00005	0.00005		0.00005	0.00005		0.00005	0.00005		0.00005	0.00005		0.00005	0.00005	0.00005	0.00005	0.00005	0.00005	0.00005	0.00005
		0.00001		0.00001	0.00001		0.00001	0.00001		0.00001	0.00001		0.00001	0.00001		0.00001	0.00001	0.00001	0.00001	0.00001	0.00001	0.00001	0.00001
	256	0.05		0.05	0.05		0.05	0.05		0.05	0.05		0.05	0.05		0.05	0.05	0.05	0.05	0.05	0.05	0.05	0.05
		0.01		0.01	0.01		0.01	0.01		0.01	0.01		0.01	0.01		0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01
		0.005		0.005	0.005		0.005	0.005		0.005	0.005		0.005	0.005		0.005	0.005	0.005	0.005	0.005	0.005	0.005	0.005
		0.00		0.00	0.00		0.00	0.00		0.00	0.00		0.00	0.00		0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
		0.0001		0.0001	0.0001		0.0001	0.0001		0.0001	0.0001		0.0001	0.0001		0.0001	0.0001	0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
		0.00005		0.00005	0.00005		0.00005	0.00005		0.00005	0.00005		0.00005	0.00005		0.00005	0.00005	0.00005	0.00005	0.00005	0.00005	0.00005	0.00005
		0.00001		0.00001	0.00001		0.00001	0.00001		0.00001	0.00001		0.00001	0.00001		0.00001	0.00001	0.00001	0.00001	0.00001	0.00001	0.00001	0.00001
		0.05		0.05	0.05		0.05	0.05		0.05	0.05		0.05	0.05		0.05	0.05	0.05	0.05	0.05	0.05	0.05	0.05
	516	0.01		0.01	0.01		0.01	0.01		0.01	0.01		0.01	0.01		0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01
		0.005		0.005	0.005		0.005	0.005		0.005	0.005		0.005	0.005		0.005	0.005	0.005	0.005	0.005	0.005	0.005	0.005
		0.001		0.001	0.001		0.001	0.001		0.001	0.001		0.001	0.001		0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001
		0.0005		0.0005	0.0005		0.0005	0.0005		0.0005	0.0005		0.0005	0.0005		0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005
		0.0001		0.0001	0.0001		0.0001	0.0001		0.0001	0.0001		0.0001	0.0001		0.0001	0.0001	0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
		0.00005		0.00005	0.00005		0.00005	0.00005		0.00005	0.00005		0.00005	0.00005		0.00005	0.00005	0.00005	0.00005	0.00005	0.00005	0.00005	0.00005
		0.00001		0.00001	0.00001		0.00001	0.00001		0.00001	0.00001		0.00001	0.00001		0.00001	0.00001	0.00001	0.00001	0.00001	0.00001	0.00001	0.00001
		0.05		0.05	0.05		0.05	0.05		0.05	0.05		0.05	0.05		0.05	0.05	0.05	0.05	0.05	0.05	0.05	0.05

Figure 5 The Epoch, Batch Size, and Learning rate values used to find the optimal hyperparameters.

5. ทำการจัดเรียงชุดข้อมูลทั้ง 2 ชุด โดยจัดรูปให้อยู่ตรงกลาง และเห็นรูปได้อย่างชัดเจน

6. สร้างการเรียนรู้ของ Google's Teachable Machine โดยทำการจัด Class ให้กับรูป ซึ่งแบ่งเป็น 3 Class คือ Class 1: Wildfire (ไฟไหม้ป่า), Class 2: Smoke (ควันไฟที่เกิดจากไฟไหม้ป่า) และ Class 3: No Wildfire (ไม่เกิดไฟไหม้) และทำการตั้งค่าไฮเปอร์พารามิเตอร์ ที่ประกอบไปด้วย Epoch, Batch Size และ Learning rate ให้เหมาะสมกับการเรียนรู้

7. ทำการทดสอบความแม่นยำของข้อมูลโดยใช้ชุดข้อมูลในการฝึกฝนเพื่อหาการปรับแต่งค่าไฮเปอร์พารามิเตอร์ ที่เหมาะสมที่จะนำไปใช้กับการทดสอบจริงกับ Google's Teachable Machine โดยทำการประเมินโดยใช้ความแม่นยำ Accuracy จากการฝึกฝน จะต้องได้ค่าที่ความแม่นยำ Accuracy มากกว่าร้อยละ 95 ของในแต่ละ Class เพื่อหาค่าไฮเปอร์พารามิเตอร์ที่เหมาะสม

8. หลังจากการศึกษาการฝึกฝนและปรับค่าไฮเปอร์พารามิเตอร์ได้แล้วนั้น ทำการทดสอบจริงกับชุดข้อมูลที่เตรียมไว้ใช้เป็นชุดข้อมูลในการทดสอบ จำนวนประเภทละ 290 รูป กับ Google's Teachable Machine เพื่อให้ได้ค่าความแม่นยำที่ได้จากการทดสอบจริง

9. ทำการบันทึกผล วิเคราะห์ผลการประเมินประสิทธิภาพความแม่นยำของ Model นั้น โดยใช้ตาราง Confusion Matrix ที่ใช้ประเมินผลลัพธ์การทำนาย หรือผลลัพธ์จากการโปรแกรม (Pre-diction) เปรียบเทียบกับค่าจริง ๆ (Actual) ที่ได้

10. สรุปผลที่ได้จากการวิเคราะห์ประสิทธิภาพความแม่นยำเพื่อศึกษาการปรับแต่งไฮเปอร์พารามิเตอร์ที่เหมาะสมที่ใช้กับการตรวจจับไฟป่าโดยใช้ Google's Teachable Machine และประยุกต์ใช้ Google's Teachable Machine ในการพัฒนาระบบตรวจจับไฟป่าให้มีประสิทธิภาพ และความแม่นยำสูง

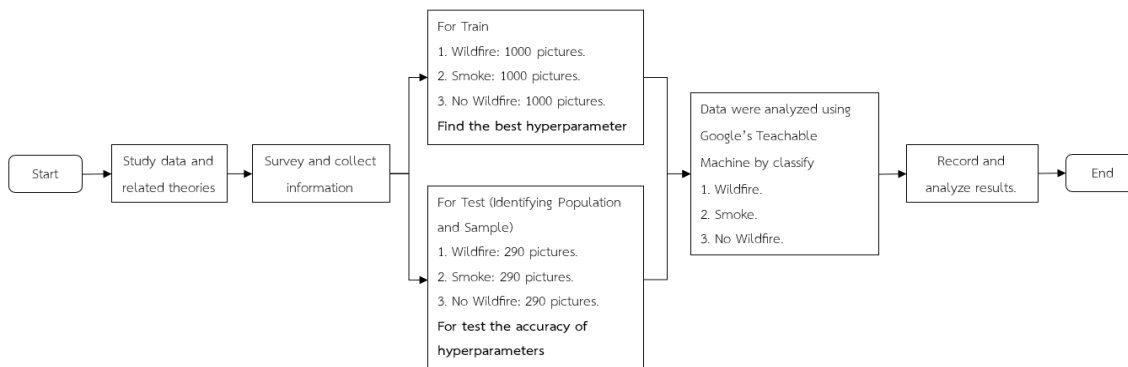


Figure 6 Demonstrate the research procedure

### 3. ผลการวิจัย

#### 3.1 ผลการศึกษาการปรับแต่งค่าไฮเปอร์พารามิเตอร์

ผลการศึกษาการปรับแต่งค่าไฮเปอร์พารามิเตอร์ ที่ประกอบไปด้วย Epoch Batch Size และ Learning rate ที่ใช้ในการหาค่าไฮเปอร์พารามิเตอร์ที่เหมาะสม ดังแสดงใน Figure 5 ให้ค่าความแม่นยำ Accuracy จากการฝึกฝนออกมาเป็นจำนวน 288 ชุด และมีชุดที่ได้ค่าที่ความแม่นยำ Accuracy มากกว่าร้อยละ 95 ของแต่ละ Class อยู่จำนวน 2 ชุด ดังแสดงใน Table 3

Table 3 The results of the study of the tuning of hyperparameters with an accuracy of more than 95 percent

No	Hyperparameters			Accuracy		
	Epochs	Batch size	Learning Rate	Wildfire	Smoke	No Wildfire
1	60	16	0.001	0.97	0.96	0.96
2	70	16	0.00001	0.97	0.96	0.97

สำหรับชุดแรกมีค่า Epoch = 60, Batch Size = 16 และ Learning rate = 0.001 ส่งผลให้มีค่า Accuracy ของ Wildfire (ไฟไหม้ป่า) Smoke (ควันไฟที่เกิดจากไฟไหม้ป่า) และ No Wildfire (ไม่เกิดไฟไหม้ป่า) ร้อยละ 97, 96 และ 96 ตามลำดับ ดังแสดงใน Figure 7

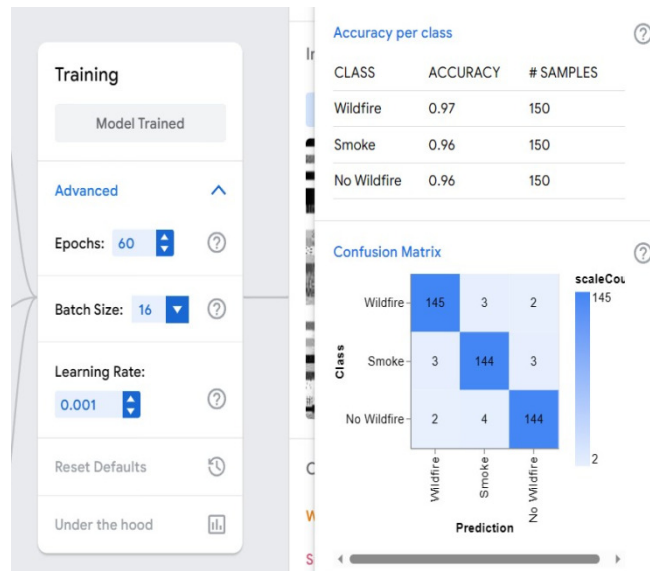


Figure 7 Accuracy per class when Epoch = 60, Batch Size = 16, Learning rate = 0.001.

ต่อมาในชุดที่สองนั้นมีค่า Epoch = 70, Batch Size = 16 และ Learning rate = 0.00001 ส่งผลให้มีค่า Accuracy ของ Wildfire (ไฟไหม้ป่า) Smoke (ควันไฟที่เกิดจากไฟไหม้ป่า) และ No Wildfire (ไม่เกิดไฟไหม้ป่า) ร้อยละ 97, 96 และ 97 ตามลำดับ ดังแสดงใน Figure 8

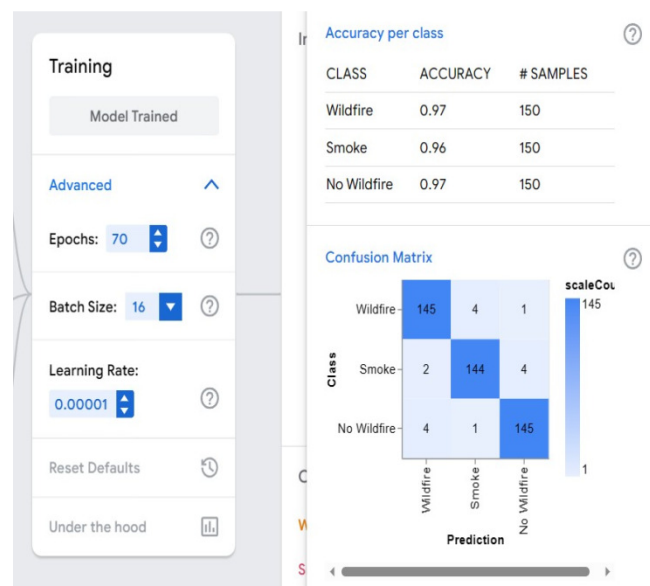


Figure 8 Accuracy per class when Epoch = 70, Batch Size = 16, Learning rate = 0.00001

จากการทำการศึกษการปรับแต่งค่าไฮเปอร์พารามิเตอร์ พบว่าการปรับแต่งค่า Learning rate ที่ 0.05 ที่ Epoch และ Batch size ที่ค่าต่าง ๆ ตามที่กำหนด จะให้ค่าความแม่นยำ Accuracy จากการฝึกฝนของบางประเภท Class ที่ร้อยละ 0 ดังแสดงใน Figure 9 ซึ่งเป็นผลมากจากการเลือกกำหนดค่าสูงเกินไป ทำให้โมเดลกำหนดขนาด ของขั้นตอนในการปรับปรุงค่า weights ของโมเดลในแต่ละรอบการฝึกอบรม มีการเปลี่ยนแปลงที่มากเกินไป ส่งผลต่อความแม่นยำในการทำนาย และการตัดสินใจ

Hyperparameters			Accuracy			Hyperparameters			Accuracy		
Epochs	Batch size	Learning Rate	Wildfire	Smoke	No Wildfire	Epochs	Batch size	Learning Rate	Wildfire	Smoke	No Wildfire
50	16	0.05	1	0	0	80	16	0.05	0	0.76	0.97
50	32	0.05	0	0.87	0.94	80	32	0.05	1	0	0
50	64	0.05	0	1	0	80	64	0.05	1	0	0
50	128	0.05	1	0	0	80	128	0.05	0	1	0.83
50	256	0.05	1	0	0	80	256	0.05	0	0.95	0.95
50	512	0.05	0	0.99	0.87	80	512	0.05	0	0.89	0.99
60	16	0.05	0	1	0	90	16	0.05	0	0	1
60	32	0.05	0	0	1	90	32	0.05	0	1	0
60	64	0.05	0	0.95	0.88	90	64	0.05	0.03	1	0
60	128	0.05	1	0	0	90	128	0.05	1	0	0
60	256	0.05	0.89	0.98	0.7	90	256	0.05	0.97	0	0.96
60	512	0.05	0.96	0.93	0.98	90	512	0.05	0	0.95	0.99
70	16	0.05	0	1	0	100	16	0.05	0	0	1
70	32	0.05	0	0	1	100	32	0.05	0	0	1
70	64	0.05	0	0.93	0.96	100	64	0.05	0.99	0.66	0
70	128	0.05	0.99	0	0.96	100	128	0.05	0.95	0.95	0
70	256	0.05	1	0	0	100	256	0.05	0.94	0.95	0
70	512	0.05	0	0.97	0.96	100	512	0.05	0	0.98	0.94

Figure 9 Accuracy per class when tuning Learning rate to 0.05 at different Epoch and Batch size

### 3.2 ผลการทดสอบจริง

หลังจากการศึกษาการฝึกฝน และปรับค่าไฮเปอร์พารามิเตอร์แล้วนั้นได้ ชุดของไฮเปอร์พารามิเตอร์ที่ให้ค่าความแม่นยำในแต่ละประเภทมากกว่าร้อยละ 95 มีจำนวน 2 ชุด จากนั้นทำการทดสอบความแม่นยำของข้อมูลโดยใช้ชุดข้อมูลในการทดสอบจริง จำนวน 290 รูป เพื่อให้ได้ค่าความแม่นยำที่ได้จากการทดสอบจริงจากรูปที่ไม่ได้มาจากการเป็นชุดข้อมูลที่ใช้ในการฝึกฝน (Train) ของ Google's Teachable Machine

ในการทดสอบได้กำหนดเกณฑ์ขั้นต่ำของค่าความแม่นยำอยู่ที่ร้อยละ 95 โดยในชุดแรกปรับค่าไฮเปอร์พารามิเตอร์ ที่ประกอบไปด้วย Epoch = 60, Batch Size = 16 และ Learning rate = 0.001 ดังแสดงใน Figure 7 จากการบันทึกผล แสดงให้เห็นว่ามีรูปที่มีความแม่นยำตรงกันมีจำนวนรูปแบ่งเป็น Wildfire (ไฟไหม้ป่า), Smoke (ควันไฟที่เกิดจากไฟไหม้ป่า), No Wildfire (ไม่เกิดไฟไหม้ป่า) ที่ 280 รูป, 280 รูป และ 280 รูป ตามลำดับ ดังแสดงใน Table 4

Table 4 The results of actual test at Epoch = 60, batch size = 16 and learning rate = 0.001

		Prediction		
		Wildfire	Smoke	No Wildfire
Actual	Wildfire	280	5	5
	Smoke	6	280	4
	No Wildfire	6	4	280

เมื่อนำมาหาค่าแสดงประสิทธิภาพของ Wildfire (ไฟไหม้ป่า) ได้ค่า Precision, Recall, F1 และ Accuracy ร้อยละ 96, 97, 96, 97 ตามลำดับ, Smoke (ควันไฟที่เกิดจากไฟไหม้ป่า) ได้ค่า Precision, Recall, F1 และ Accuracy ร้อยละ 97, 97, 97, 97 ตามลำดับ และ No Wildfire (ไม่เกิดไฟไหม้ป่า) ได้ค่า Precision, Recall, F1

และ Accuracy ร้อยละ 97, 97, 97, 97 ตามลำดับ ซึ่งสามารถหาค่าความแม่นยำ Accuracy เฉลี่ยของไฮเปอร์พารามิเตอร์นี้ได้ร้อยละ 97 ดังแสดงใน Table 6

สำหรับชุดที่ 2 นั้นกำหนดค่า Epoch = 70, Batch Size = 16 และ Learning rate = 0.00001 ดังแสดงใน Figure 8 จากการบันทึกผล แสดงให้เห็นว่ามีภาพที่มีความแม่นยำตรงกันมีจำนวนภาพแบ่งเป็น Wildfire (ไฟไหม้ป่า), Smoke (ควันไฟที่เกิดจากไฟไหม้ป่า), No Wildfire (ไม่เกิดไฟไหม้ป่า) ที่ 271 รูป, 273 รูป และ 281 รูป ตามลำดับ ดังแสดงใน Table 5

**Table 5** The results of actual test at Epoch = 70, Batch Size = 16 and Learning rate = 0.00001

		Prediction		
		Wildfire	Smoke	No Wildfire
Actual	Wildfire	271	17	2
	Smoke	7	273	10
	No Wildfire	4	5	281

ต่อมาค่าแสดงประสิทธิภาพของ Wildfire (ไฟไหม้ป่า) โดยมีค่า Precision, Recall, F1 และ Accuracy ร้อยละ 96, 93, 96, 93 ตามลำดับ, Smoke (ควันไฟที่เกิดจากไฟไหม้ป่า) มีค่า Precision, Recall, F1 และ Accuracy ร้อยละ 93, 94, 93, 94 ตามลำดับ และ No Wildfire (ไม่เกิดไฟไหม้ป่า) มีค่า Precision, Recall, F1 และ Accuracy ร้อยละ 96, 97, 97, 97 ตามลำดับ ซึ่งสามารถหาค่าความแม่นยำ Accuracy เฉลี่ยของไฮเปอร์พารามิเตอร์นี้ได้ คือ 0.95 หรือ 95% ดังแสดงใน Table 6

**Table 6** Evaluation of hyperparameters that accuracy values in each class of more than 95 percent

No	1			2		
Hyperparameters	Epoch = 60, Batch Size = 16, Learning rate = 0.001			Epoch = 70, Batch Size = 16, Learning rate = 0.00001		
Class from Google's Teachable Machine	Wildfire	Smoke	No Wildfire	Wildfire	Smoke	No Wildfire
Precision	96	97	97	96	93	96
Recall	97	97	97	93	94	97
F1 Score	96	97	97	96	93	97
Accuracy per Class	97	97	97	93	94	97
Accuracy	97			95		

จากการศึกษาผลการทดสอบจริงในการตรวจจับไฟป่าโดยใช้ Google's Teachable Machine และการปรับค่าไฮเปอร์พารามิเตอร์ พบว่าชุดของไฮเปอร์พารามิเตอร์ที่ให้ค่าความแม่นยำสูงสุดประกอบด้วย Epoch = 60, Batch Size = 16, และ Learning rate = 0.001 การทดสอบนี้แบ่งประเภทข้อมูลออกเป็น 3 ประเภท ได้แก่ Wildfire (ไฟไหม้ป่า), Smoke (ควันไฟที่เกิดจากไฟไหม้ป่า), และ No Wildfire (ไม่เกิดไฟไหม้ป่า) โดยใช้ชุดข้อมูลในการฝึกฝนประเภทละ 1000 รูป และชุดข้อมูลในการทดสอบประเภทละ 290 รูป

ผลการทดสอบการเรียนรู้ของ Google's Teachable Machine ด้วยค่าไฮเปอร์พารามิเตอร์ที่ระบุ พบว่า ได้ค่าความแม่นยำ (Accuracy) ของการตรวจจับ Wildfire, Smoke และ No Wildfire อยู่ที่ร้อยละ 97 สำหรับทั้งสามประเภท

#### 4. สรุปผลการวิจัย

จากผลการศึกษาการปรับแต่งค่าไฮเปอร์พารามิเตอร์มีชุดที่ได้ค่าที่ความแม่นยำ Accuracy มากกว่าร้อยละ 95 ของแต่ละ Class อยู่จำนวน 2 ชุด คือ Epoch = 60, Batch Size = 16, Learning rate = 0.001 และ Epoch = 70, Batch Size = 16, Learning rate = 0.00001 หลังจากนั้นนำค่าไฮเปอร์พารามิเตอร์ทั้ง 2 ชุด ไปเป็นตัวกำหนดค่าไฮเปอร์พารามิเตอร์เพื่อใช้ในการทดสอบความแม่นยำของข้อมูลกับชุดข้อมูลในการทดสอบจริง พบว่าชุดของไฮเปอร์พารามิเตอร์ที่ให้ค่าความแม่นยำสูงสุดประกอบด้วย Epoch = 60, Batch Size = 16, และ Learning rate = 0.001 ซึ่งได้ค่าความแม่นยำ (Accuracy) ของการตรวจจับ Wildfire, Smoke และ No Wildfire อยู่ที่ร้อยละ 97 สำหรับทั้งสามประเภท ข้อมูลนี้แสดงให้เห็นว่า Google's Teachable Machine สามารถใช้ในการตรวจจับไฟป่าได้อย่างมีประสิทธิภาพ และความแม่นยำสูง การปรับค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมทำให้โมเดลสามารถเรียนรู้ และจำแนกประเภทของไฟป่าได้อย่างถูกต้อง สอดคล้องกับเป้าหมาย ในการพัฒนาเทคโนโลยีเพื่อใช้ในการตรวจจับ และป้องกันไฟป่าในอนาคต การปรับแต่งไฮเปอร์พารามิเตอร์ให้เหมาะสมเป็นกระบวนการที่สำคัญ ในการพัฒนาโมเดล Machine Learning ในผลการศึกษาการปรับแต่งค่าไฮเปอร์พารามิเตอร์ พบว่าการกำหนดค่า Learning rate ที่ 0.05 ที่ Epoch และ Batch size ที่ค่าต่างๆตามที่กำหนด ให้ค่าความแม่นยำ Accuracy จากการ Train ของบางประเภทที่ร้อยละ 0 เป็นผลมากจากการเลือกกำหนดการปรับปรุงโมเดลที่สูงเกินไปทำให้เกิด การเกิดการ overfitting (เรียนรู้มากเกินไป) หรือ underfitting (เรียนรู้น้อยเกินไป) ภายในกระบวนการเรียนรู้ทำให้เกิดความไม่มีประสิทธิภาพ และเสถียรภาพในกระบวนการของความแม่นยำในการทำนาย และการตัดสินใจ

จากการตรวจสอบเอกสารพบว่ามีงานนำ Google's Teachable Machine มาใช้ในการวินิจฉัยลิ้นที่มีรอยฟัน โดย (Jeong, 2020) ซึ่งได้กำหนดค่าไฮเปอร์พารามิเตอร์ที่ Epoch = 75, Batch size = 128, Learning rate = 0.0001 การศึกษานี้แบ่งข้อมูลออกเป็น 2 ประเภท คือ ลิ้นที่มีรอยฟัน (tooth-marked tongue) และลิ้นที่ไม่มีรอยฟัน (no-marked tongue) ใช้ชุดข้อมูลในการฝึกฝนจำนวน 634 รูป และ 491 รูป ตามลำดับ และใช้ชุดข้อมูลในการทดสอบจำนวน 70 รูป และ 55 รูป ตามลำดับ โดยได้ค่าความแม่นยำในการตรวจจับลิ้นที่มีรอยฟัน อยู่ที่ร้อยละ 92.1 และลิ้นที่ไม่มีรอยฟันอยู่ที่ร้อยละ 72.6 เมื่อเปรียบเทียบค่าความแม่นยำที่ได้จากผลการทดสอบกับการตรวจสอบเอกสารที่มีการนำ Google's Teachable Machine มาใช้ แสดงให้เห็นว่าไฮเปอร์พารามิเตอร์ที่ Epoch = 60, Batch Size = 16, Learning rate = 0.001 ให้ค่าความแม่นยำที่สูงกว่าค่าไฮเปอร์พารามิเตอร์ที่ใช้ในการวินิจฉัยลิ้นที่มีรอยฟัน (Epoch = 75, Batch size = 128, Learning rate = 0.0001) ซึ่งยืนยันถึงความ เป็นไปได้ในการใช้ไฮเปอร์พารามิเตอร์ที่ได้จากผลการทดสอบนี้ว่าเป็นค่าที่เหมาะสม และให้ค่าความแม่นยำสูงกว่า ในการตรวจจับไฟป่า การศึกษานี้ยังแสดงให้เห็นถึงความสำคัญของการปรับค่าไฮเปอร์พารามิเตอร์ที่เหมาะสม ในการพัฒนาโมเดล Machine Learning ที่มีประสิทธิภาพสูง การปรับค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมสามารถ ช่วยเพิ่มความแม่นยำในการจำแนกประเภทของข้อมูล และลดความผิดพลาดในการทำนายได้ การเลือกค่า Epoch, Batch Size และ Learning Rate ที่เหมาะสมจึงเป็นสิ่งสำคัญที่จะทำให้โมเดลสามารถเรียนรู้ได้อย่างมีประสิทธิภาพ

การวิจัยเพิ่มเติมในอนาคตควรมุ่งเน้นไปที่การปรับปรุงประสิทธิภาพของโมเดล Machine Learning ในการตรวจจับไฟป่า การทดลองกับชุดข้อมูลที่หลากหลาย และการพัฒนาอัลกอริทึมที่มีความซับซ้อนมากขึ้นสามารถ ช่วยเพิ่มความแม่นยำในการตรวจจับ และทำนายไฟป่าได้ การใช้เทคโนโลยี Machine Learning ในการตรวจจับไฟป่า เป็นแนวทางที่มีศักยภาพสูงในการป้องกัน และลดผลกระทบจากไฟป่าที่เกิดขึ้นทั่วโลก

## 5. กิตติกรรมประกาศ

ขอขอบคุณอาจารย์ที่ปรึกษา เจ้าหน้าที่คณะวิศวกรรมศาสตร์ ศรีราชา มหาวิทยาลัยเกษตรศาสตร์ วิทยาเขตศรีราชา และเพื่อนร่วมงานทุกคน ที่ให้ความสนับสนุน อำนวยความสะดวก และช่วยเหลือในการทำวิจัยครั้งนี้

### ผลประโยชน์ทับซ้อน

ผู้เขียนขอยืนยันว่างานวิจัยนี้ไม่มีความขัดแย้งทางผลประโยชน์ที่เกี่ยวข้องกับบทความนี้กับบทความอื่น ๆ

## REFERENCES

- Agustian, D., Crisnapati, P. N., Novayanti, P. D., & Pertama, P. P. G. P. (2021). Implementation of machine learning using Google's Teachable Machine based on Android.
- Forchhammer, S., Abu-Ghazaleh, A., Metzler, G., Garbe, C., & Eigentler, T. (2022). Development of an image analysis-based prognosis score using Google's Teachable Machine in melanoma. *Cancers*, 14(9). doi:10.3390/cancers14092243
- Google. (n.d.). *Teachable Machine*. Retrieved from <https://teachablemachine.withgoogle.com/>
- Hoyles Fire and Safety Ltd. (n.d.). *What are the three elements of the fire triangle?* Retrieved from <https://www.hoyles.co.uk/latest-news/what-are-the-three-elements-of-the-fire-triangle/>
- Janjaroen, K. (2011). *Identifying population and sample* [in Thai]. Retrieved from [https://www.ict.up.ac.th/surinhips/ResearchMethodology\\_2554/เอกสารเพิ่มเติมการกำหนดประชากรและกลุ่มตัวอย่างPDF. \[In Thai\].](https://www.ict.up.ac.th/surinhips/ResearchMethodology_2554/เอกสารเพิ่มเติมการกำหนดประชากรและกลุ่มตัวอย่างPDF. [In Thai].)
- Janthanasub, V. (2022). *Mask detection by Teachable Machine* [in Thai]. Retrieved from [https://sci.rmutp.ac.th/web2558/wp-content/uploads/2022/02/KM05-Mask-Detection-by-Teachable-Machine-by-Veerawan.pdf. \[In Thai\].](https://sci.rmutp.ac.th/web2558/wp-content/uploads/2022/02/KM05-Mask-Detection-by-Teachable-Machine-by-Veerawan.pdf. [In Thai].)
- Jeong, H. (2020). Feasibility study of Google's Teachable Machine in diagnosis of tooth-marked tongue. *치위생과 학회지 / Journal of Dental Hygiene Science*, 20(4), 206. Retrieved from <https://portal.lib.ku.ac.th/login?url=https://search.ebscohost.com/login.aspx?direct=true&db=edskis&AN=edskis.3847205&site=eds-live>
- Ma, X. (2023). *Application of artificial intelligence in computer network technology*. Paper presented at the 2023 2nd International Conference on Artificial Intelligence and Autonomous Robot Systems (AIARS).
- National Fire Protection Association. (n.d.). *Reporters guide: All about fire*. Retrieved from <https://www.nfpa.org/About-NFPA/Press-Room/Reporters-Guide-to-Fire/All-about-fire>
- Pongpornsup, V. (2017). Design of experiment chapter 3 [in Thai]. *For Quality Management*, 23, 15-17. [In Thai].

- Rizanov, S., & Yakimov, P. (2023). *The technological ecosystem of modern wildfire detection: A review*. Paper presented at the 2023 XXXII International Scientific Conference Electronics (ET).
- Ruangsapdej, K. (2023). AI detects wildfires new approaches to global disasters [in Thai]. *Post Today*. Retrieved from <https://www.posttoday.com/international-news/701359>. [In Thai].
- Saied, A. (2020). *FIRE dataset*. Retrieved from <https://www.kaggle.com/datasets/phylake1337/fire-dataset?resource=download>
- Saraubon, K. (2020). Learning data science and AI: Machine learning using Python [in Thai]. *Machine Learning เบื้องต้น*, 1, 321-336. [In Thai].
- Saraubon, K. (2022). Learning AI: Deep learning using Python [in Thai]. *Machine Learning*, 1, 321-336. [In Thai].
- Seub Nakhasathien Foundation. (2018). *Knowledge the forest – forest fire* [in Thai]. Retrieved from <https://www.seub.or.th/blogging/knowledge/รู้รักษ์ป่า/ไฟป่า-รู้รักษ์ป่า/>. [In Thai].