

การศึกษาและพัฒนาต้นแบบปัญญาประดิษฐ์ เพื่อระบบตรวจจับการเกิดไฟฟ้าด้วยข้อมูลภาพจากอากาศยานไร้คนขับ

ภูตินันท์ สิงห์คำฟู¹ และ พลภัทร เหมวรรณ^{2*}

วันที่รับ 5 กันยายน 2565 วันที่แก้ไข 4 ตุลาคม 2565 วันตอบรับ 7 ตุลาคม 2565

บทคัดย่อ

โครงการวิจัยในครั้งนี้มีวัตถุประสงค์ของการศึกษา คือ 1) เพื่อบินถ่ายภาพทางอากาศของเหตุการณ์การเกิดไฟฟ้าในพื้นที่ศึกษาด้วยอากาศยานไร้คนขับ และ 2) เพื่อศึกษาและพัฒนาาระบบปัญญาประดิษฐ์ในการตรวจจับการเกิดไฟฟ้าด้วยระบบอากาศยานไร้คนขับในพื้นที่เฝ้าระวังการเกิดไฟฟ้าซ้ำซาก ผลของการศึกษาจากการบินถ่ายภาพทางอากาศของภาพการเกิดไฟฟ้าจริงในพื้นที่ศึกษาด้วยอากาศยานไร้คนขับขนาดเล็กเพื่อนำมาใช้เป็นภาพต้นแบบของการสร้างการเรียนรู้ข้อมูลให้กับระบบปัญญาประดิษฐ์ในการตรวจจับการเกิดไฟฟ้าในพื้นที่จริง การทดลองได้ใช้ภาพที่ถูกกำหนดให้มีไฟ จำนวน 655 ภาพ และไม่มีไฟ จำนวน 3,881 ภาพ โดยมีการแบ่งข้อมูลใช้ในการทดลองเป็น 3 กลุ่ม คือ กลุ่มแรกใช้ในการฝึกสอน (train) กลุ่มที่สองใช้ในการประเมินความลำเอียงของโมเดล (validation) และกลุ่มที่สามใช้ทดสอบโมเดล (test) หลังจากนั้นได้แบ่งข้อมูลออกเป็นสองส่วนเพื่อนำมาทดสอบ โดยที่ใช้เทรนโมเดล จำนวน 840 ภาพ ทดสอบความเร็วและความถูกต้องโมเดล จำนวน 208 ภาพ และทดสอบการใช้งานโมเดล จำนวน 262 ภาพ งานวิจัยนี้ได้ใช้เครื่องมือวัดประสิทธิภาพของโมเดล 4 ชนิด คือ Accuracy, Sensitivity, Specificity, และ Matthews correlation coefficient ซึ่งได้นำมาทดสอบด้วยวิธี direct validation โดยในการนี้ได้ทดลองใช้อัลกอริทึมของการเรียนรู้เชิงลึกมาทดสอบ 6 ชนิด คือ Resnet18, Resnet34, Alexnet, Vgg11, Densenet121 และ Vgg16 และได้ทำการใช้กลุ่มภาพที่แยกไว้สำหรับสอนโมเดลทำการสอนโมเดลโดยใช้ Densenet121 ในระบบ Kaggle เพื่อฝึกสอนโมเดลเชิงลึก ซึ่งได้ผลลัพธ์ออกมาเป็นโมเดลที่พร้อมใช้งานที่มีประสิทธิภาพของการสอนทั้งหมดจำนวน 10 รอบ โดยจากผลลัพธ์เห็นได้ว่า จำนวนเปอร์เซ็นต์ความแม่นยำ (accuracy) จะเพิ่มขึ้นจาก 44.97% ไปจนถึง 68.42% ตามลำดับ และจำนวนครั้งที่ได้รับการฝึกสอนให้กับโมเดล

คำสำคัญ : อากาศยานไร้คนขับ, ระบบปัญญาประดิษฐ์ในการตรวจจับการเกิดไฟฟ้า

¹ วิทยาลัยศิลปะ สื่อ และเทคโนโลยี, มหาวิทยาลัยเชียงใหม่

² ภาควิชาภูมิศาสตร์, คณะสังคมศาสตร์, มหาวิทยาลัยเชียงใหม่

* ผู้แต่ง, อีเมล: phonpat.h@cmu.ac.th, p.hemwan@gmail.com

The Study and Development of Artificial Intelligence (AI) Prototype for Forest Fire Detection (FFD) System using Image Data from Unmanned Aerial Vehicle (UAV)

Phudinan Singkahmfu¹ and Phonpat Hemwan^{2*}

Received 5 September 2022, Revised 4 October 2022, Accepted 7 October 2022

Abstract

The research project aimed 1) to monitor the specific studied area of its wildfire, using Unmanned Aerial Vehicle (UAV) 2) to study and to develop the Artificial Intelligence (AI) system in purpose of detecting wildfire in surveillance location where may occur repeated fire, using automatic steering ship. Both operations in an actual location and applied theoretical knowledge used, were tested. Those done by the results from fire forest images data of actual locations using UAV, were used to build an Artificial Intelligence prototype in detecting forest fire in the actual location. The method of the research was made with specific 655 images of fire figure included within those 3,881 images of fire figure not included. The data was divided into 3 groups; the first group was used to train, the second group was used to validation, and the last group was used to test the model. The data then was divided into 2 parts for testing, which are composed of 840 images of train model, 208 images of speed and accuracy test on model, and 208 images of performance test on model. The research was applied 4 measurement tools; Accuracy, Sensitivity, Specificity, and Matthews correlation coefficient. Those of which were specifically tested through direct validation. Aside, to do the test, the research employed 6 deep learning algorithms, which included Restnet18, Restnet34, Alexnet, Vgg11, Densenet121, and Vgg16. Separated images were also used in the research to teach models, and deep models were taught using Densenet121 on the Kaggle system. Ten ready-models for effective teaching were shown in the results. As can be observed, both the quantity of training and the accuracy percentage increased from 44.79 to 68.42, respectively.

Keywords : Unmanned Aerial Vehicle (UAV), Artificial Intelligent (AI) in detecting forest fire

¹ College of Arts, Media and Technology, Chiang Mai University

² Department of Geography, Faculty of Social Science, Chiang Mai University

* Corresponding author, E-mail: phonpat.h@cmu.ac.th, p.hemwan@gmail.com

1. บทนำ

ปัญหาหมอกควันภาคเหนือเป็นปัญหาที่เริ่มเกิดขึ้นเมื่อประมาณปี พ.ศ. 2549 จนกระทั่งในปัจจุบัน ถือเป็นภัยพิบัติที่ได้สร้างผลกระทบต่อพื้นที่ภาคเหนือและภูมิภาคอื่นๆ ของประเทศ และได้ทวีความรุนแรงมากยิ่งขึ้น โดยสาเหตุหลักประการหนึ่งที่ทำให้มีความเข้มข้นของฝุ่นควันขนาดเล็ก PM 2.5 คือ การเผาไหม้ในที่โล่ง โดยเฉพาะการเกิดไฟป่าที่มีการเข้าถึงในการเข้าควบคุมไฟไม่ให้ลุกลามหรือการดับไฟนั้นกระทำได้อย่างยาก โดยจากข้อมูลการประเมินจุดความร้อน (fire hotspot) ข้อมูลดาวเทียมระบบ MODIS ในปี 2562 ที่ผ่านมา พบว่า มีจุดความร้อนเกิดขึ้นทั้งหมด 10,214 จุด คิดเป็นเนื้อที่ประมาณ 7,211,517 ไร่ โดยในจำนวนนี้เป็นจุดความร้อนที่เกิดขึ้นในพื้นที่เขตป่าทั้งป่าสงวนแห่งชาติ จำนวน 4,274 จุด และป่าอนุรักษ์ จำนวน 5,045 จุด รวมเป็นจำนวน 9,319 จุด หรือคิดเป็นร้อยละ 91 ของจุดความร้อนที่เกิดขึ้นทั้งหมด [1]

ปัจจุบันในการติดตาม (monitoring) และตรวจจับ (detection) พื้นที่เผาไหม้ในที่โล่งและพื้นที่เกิดไฟป่าได้มีเพียงวิธีการเดียว คือ การได้มาจากการประมวลผลด้วยข้อมูลจุดความร้อน (active fire hotspot) โดยอาศัยข้อมูลจากระบบเซนเซอร์ของดาวเทียมที่มีความสามารถในการติดตามข้อมูลความร้อนบนพื้นผิวโลกในระบบหลักขององค์การบริหารการบินและอวกาศแห่งสหรัฐอเมริกา (NASA) ด้วยดาวเทียมใน 2 ระบบ คือ ระบบ VIIRS จากดาวเทียม Suomi NPP ที่มีความละเอียดเชิงพื้นที่ของข้อมูล 375 เมตร ทำการบันทึกข้อมูลใน 2 ช่วงเวลาของทุกวัน คือ เวลา 14:00-16:00 น. และ 02:00-04:00 น. และตรวจหาด้วยระบบ MODIS จากดาวเทียม TERRA และ AQUA ที่มีความละเอียดเชิงพื้นที่ 1 กิโลเมตร ทำการบันทึกข้อมูลใน 4 ช่วงเวลา

ของทุกวัน คือ เวลา 00:00-02:00 น. 10:00-12:00 น. 12:00-14:00 น. และ 22:00-24:00 น. ทั้งนี้จากการตรวจจับข้อมูลจุดความร้อนด้วยระบบดาวเทียมดังกล่าว ถือได้ว่าจะมีข้อจำกัดของรอบเวลาในการบันทึกข้อมูลซ้ำในพื้นที่เดิมหรือความละเอียดเชิงเวลา (temporal resolution) ที่มีความละเอียดต่ำต่อการนำมาประยุกต์ใช้การติดตามและเฝ้าระวังการเกิดไฟป่าในระดับพื้นที่ [2]

จากประเด็นดังกล่าวข้างต้น คณะผู้วิจัยจึงมีความสนใจต่อการศึกษาทางด้านการพัฒนาเทคนิควิธีการด้วยปัญญาประดิษฐ์ (Artificial Intelligence) หรือที่รู้จักกันดีในนามของเทคโนโลยี AI เพื่อการพัฒนาาระบบตรวจจับการเกิดไฟป่าในพื้นที่เฝ้าระวังการเกิดไฟป่าซ้ำซากหรือมีความเสี่ยงต่อการเกิดไฟป่าในแบบอัตโนมัติด้วยอากาศยานไร้คนขับ (หลังจากนี้เรียกว่า UAV) เพื่อเป็นการทดแทนข้อจำกัดทางด้านเวลาในการบันทึกซ้ำในพื้นที่เดิมจากระบบดาวเทียม ดังนั้น ระบบเฝ้าระวังการเกิดไฟป่าด้วยระบบตรวจจับการเกิดไฟป่าด้วยปัญญาประดิษฐ์บนแพลตฟอร์มของระบบ UAV ขนาดเล็กจึงมีความสำคัญต่อการดำเนินงานในระดับพื้นที่อย่างมีประสิทธิภาพ ด้วยเป็นการดำเนินงานจากเทคโนโลยีที่ทันสมัยเพื่อให้ได้มาซึ่งข้อมูลเชิงพื้นที่จากการสำรวจระยะไกลที่มีประสิทธิภาพ ต้นทุนต่ำ และสะดวกต่อการดำเนินการ [3] โดยเฉพาะหน่วยงานในระดับพื้นที่สามารถนำไปประยุกต์ดำเนินการได้จริง อันจะเป็นประโยชน์ต่อการนำไปประยุกต์ใช้ในการสนับสนุนต่อการประเมินพื้นที่เสี่ยงภัยพิบัติระดับพื้นที่ในการกิจด้านการป้องกันและบรรเทาสาธารณภัย โดยเป็นการจัดสร้างชุดข้อมูลภูมิสารสนเทศและแผนที่พื้นที่เสี่ยงภัยพิบัติที่ในหลายหน่วยงานยังคงมีความต้องการและมีความถี่สูงต่อการใช้งานจากข้อมูลภาพถ่ายทางอากาศที่เป็นปัจจุบันและทันสมัย

2. ขอบเขตการวิจัย

การศึกษานี้เป็นการวิจัยประยุกต์เชิงพัฒนา นวัตกรรม โดยดำเนินการศึกษาจากกระบวนการ ปฏิบัติงานในพื้นที่จริง มุ่งศึกษาองค์ความรู้ที่มีอยู่ ในเชิงทฤษฎีโดยนำไปใช้ในปฏิบัติการและทดลอง ดำเนินงานเพื่อสร้างและค้นหาองค์ความรู้ใหม่จาก กระบวนการและผลลัพธ์ของการดำเนินงานดังกล่าว สามารถแยกขอบเขตการดำเนินงานใน 2 ประเด็น ดังนี้

1) การบินถ่ายภาพทางอากาศด้วยอากาศยาน ไร้คนขับขนาดเล็กของการเกิดไฟป่าจริงในพื้นที่ศึกษา ด้วยการใช้อัล้องช่วงแสงขาวมองเห็นได้ (visible light) หรือในระบบตรวจจับแสงในช่วงคลื่น Blue Green และ Red ที่ติดตั้งอยู่ในกล้องถ่ายภาพของ UAV ทั่วไป [4] เพื่อนำมาใช้เป็นภาพต้นแบบของการสร้าง การเรียนรู้ข้อมูลให้กับระบบปัญญาประดิษฐ์ในการ ตรวจสอบการเกิดไฟป่าในพื้นที่จริง

2) การศึกษาและพัฒนาระบบตรวจจับไฟป่า แบบอัตโนมัติด้วยปัญญาประดิษฐ์ (AI) โดยการใช้ แพลตฟอร์มของระบบอากาศยานไร้คนขับหรือระบบ UAV ขนาดเล็กเพื่อพัฒนาระบบตรวจจับควันไฟ รวมถึง แหล่งกำเนิดควันไฟในที่โล่งหรือพื้นที่มีต้นไม้หนาแน่น โดยมีเป้าหมายที่จะสามารถตรวจจับพื้นที่หรือจุดที่ เกิดไฟป่าหรือการเกิดการเผาไหม้ในที่โล่ง โดยการใช้ วิธีการเก็บระบบภาพถ่าย (snap shot) จากระบบ กล้องถ่ายภาพของ UAV แล้วนำมาวิเคราะห์หาจุด เป้าหมาย และรายงานเป็นตำแหน่งพิกัด (coordinate) โดยอัตโนมัติ เพื่อนำข้อมูลไปประมวลผลเพื่อพร้อม สำหรับการต่อยอดสร้างระบบเตือนภัยและแจ้งเตือน การเผาไหม้ในพื้นที่เผ่าระวังการเกิดไฟป่าที่มีต้นทุน ต่ำอันสามารถนำไปประยุกต์ใช้ได้จริงในระดับพื้นที่

3. วิธีการวิจัย

การพัฒนาระบบปัญญาประดิษฐ์ในการตรวจจับ ไฟป่าด้วยการใช้ข้อมูลภาพถ่ายจากอากาศยาน ไร้คนขับขนาดเล็กมาสร้างระบบจำแนกวัตถุด้วย AI แบบประมวลผลภาพ (Image processing) ได้แก่

1) ส่วนการพัฒนาการสร้างตัวจำแนกประเภท โดยการลงพื้นที่และใช้อากาศยานไร้คนขับถ่ายภาพ เก็บ ข้อมูลในพื้นที่เป้าหมายในสภาพต่าง ๆ เช่น พื้นที่ ที่ยังไม่เกิดไฟตอนสมบูรณ์ พื้นที่ที่ยังไม่เกิดไฟตอน หน้าแล้ง และพื้นที่เกิดไฟตามจุดต่าง ๆ หลังจากนั้น นำข้อมูลที่ได้มาคัดกรองและแยกประเภท (labeled) ขึ้นตอนสุดท้ายเป็นการวัดผลการทำนายและทดสอบ จากการลงพื้นที่สำรวจจริงในภาคสนาม


2) ส่วนของการพัฒนาระบบแจ้งเตือนจาก AI โดยแจ้งเตือนจากข้อมูลโดรนสำรวจในรูปแบบของ พิกัดตำแหน่งจาก GPS โดยการพัฒนาซอฟต์แวร์ที่ รับภาพจาก UAV มาจำแนกข้อมูลและแสดงผลพิกัด จุดที่เกิดปัญหาและจุดที่ควรเผ่าระวัง โดยอัตโนมัติ

กระบวนการเตรียมภาพสำหรับสอนโมเดล ภาพแต่ละภาพที่ได้จากอากาศยานไร้คนขับมีขนาด ใหญ่เกินกว่าที่จะนำไปใช้งานได้ จึงต้องซอยแบ่งภาพ ขนาดใหญ่ให้ได้เป็นส่วนของภาพตามขนาดมาตรฐาน ของโมเดลเป็นภาพขนาดเล็กคือ 416 x 416 pixels



รูปที่ ๑ ตัวอย่างภาพใหญ่ที่ถูกซอยย่อยเป็นภาพขนาด 416 x 416 pixels

ได้ทำการแบ่งภาพเป็นสองกลุ่ม คือ กลุ่มแรกเป็นภาพที่มีไฟป่าหรือควันไฟในภาพ เก็บภาพกลุ่มนี้ไว้ในโฟลเดอร์ที่มีชื่อว่า Fire และให้ชื่อสถานะเป็นหมายเลข 0 กลุ่มที่สองเป็นภาพที่ไม่มีไฟหรือควันไฟในภาพ เก็บภาพกลุ่มนี้ในโฟลเดอร์ที่มีชื่อว่า No_fire และให้สถานะภาพเป็นหมายเลข 1




รูปที่ ๒ ตัวอย่างภาพถ่ายที่มีการให้สถานะมีไฟป่า (0) และไม่มีไฟป่า (1)

ในแต่ละกลุ่มแบ่งภาพอีกเป็นสองกลุ่มย่อยเพื่อไว้ใช้สำหรับสอนและทดสอบโมเดล โดย 80% ของภาพจะใช้สำหรับการสอน ที่เหลืออีก 20% ใช้สำหรับการทดสอบความถูกต้องของโมเดล ภาพในกลุ่มที่ใช้สำหรับสอนโมเดลจะทำการ Augmentation เพื่อเพิ่มจำนวนคุณลักษณะภาพเพื่อให้การสอนโมเดลมีความแม่นยำมากขึ้น เช่น การหมุนภาพแนวตั้ง 90 องศา การกลับภาพ เป็นต้น การในการทดลองนี้ทำการ Augmentation จำนวน 10 แบบ จึงทำให้จำนวนภาพที่นำมาสอนโมเดลมีจำนวนเพิ่มขึ้น 10 เท่า

กระบวนการสอนโมเดล เป็นการสอนโมเดลการเรียนรู้เชิงลึกในเบื้องต้นใช้การเรียนรู้เชิงลึกที่มีอัลกอริทึมชื่อว่า Densenet121 เป็นโครงสร้างพื้นฐานใช้ภาพสำหรับสอนในการสอนโมเดลการเรียนรู้

เชิงลึกเพื่อให้โมเดลได้เรียนรู้การแยกภาพมีไฟหรือไม่มีไฟ ระหว่างการสอนมีการปรับอัตราการเรียนรู้ (learning rate) ของโมเดลเพื่อให้ได้อัตราการเรียนรู้ที่เหมาะสม หากอัตราการเรียนรู้ต่ำไปจะเกิดเหตุการณ์โมเดล Underfitting แต่หากอัตราการเรียนรู้สูงเกินไปจะเกิดเหตุการณ์โมเดล Overfitting ทั้งนี้เมื่อได้เลือกค่าอัตราการเรียนรู้ที่เหมาะสมส่งผลให้ค่าความสูญเสียในการเรียนรู้จะลดลงแต่เมื่อถึงจุดหนึ่งเมื่อค่าอัตราการเรียนรู้เพิ่มขึ้นค่าความสูญเสียไม่ได้ลดลงแต่กลับเพิ่มขึ้น ดังแสดงในรูปที่ 3



รูปที่ ๓ ตัวอย่างความสัมพันธ์ระหว่างอัตราการเรียนรู้และความสูญเสียที่เกิดขึ้น

epoch	train_loss	valid_loss	accuracy	time
0	0.297418	0.953580	0.799043	00:21
1	0.427451	1.257859	0.866029	00:21
2	0.433230	0.616897	0.837321	00:20
3	0.413947	0.809503	0.818182	00:21
4	0.392105	0.907639	0.688995	00:21
5	0.376523	0.475150	0.842105	00:20
6	0.377835	0.320377	0.880383	00:21
7	0.342661	0.279484	0.889952	00:21
8	0.318579	0.270332	0.899522	00:20
9	0.293501	0.260011	0.904306	00:21

รูปที่ ๔ ตัวอย่างประสิทธิภาพของโมเดลที่ได้หลังจากได้รับการสอนไปจำนวน 10 รอบ

เมื่อได้โมเดลที่ได้รับการสอนจากการทดสอบแล้วจึงได้ทำการทดสอบโมเดลที่ได้มาด้วยการนำเข้ากลุ่มภาพที่ใช้สำหรับการทดสอบเพื่อหาประสิทธิภาพของโมเดล หากประสิทธิภาพของโมเดลยังไม่มีคุณภาพตามระดับที่ยอมรับได้ก็จะทำการปรับปรุงโมเดล โดยวิธีการ คือ เพิ่มจำนวนภาพที่ใช้สอน เปลี่ยนโครงสร้างของอัลกอริทึมที่ใช้ เพิ่มจำนวนรอบในการสอน เป็นต้น [5]

การทดสอบความเหมาะสมของโมเดลที่เลือกใช้นั้น ได้ผ่านการวัดประสิทธิภาพด้วยวิธีการ direct validation กับโมเดลชนิดอื่น และได้ทำการใช้ตัวแปรในการวัดประสิทธิภาพ คือ Accuracy เป็นการวัดความแม่นยำของโมเดลกับประเภทของข้อมูลที่นำไปเทรน Sensitivity คือ ความไวต่อผลบวกจริง (true positive rate) ซึ่งความไวมีความสัมพันธ์กับการแยกผลลบปลอม โดยหากมีความไวมากขึ้นก็จะส่งผลให้การพบผลลบปลอม (false negative) นั้นลดน้อยลง ส่วน Specificity คือ ความจำเพาะซึ่งเป็นสัดส่วนของผลลัพธ์ที่เป็นจริงของการทดสอบนั้น ๆ โดยที่ความจำเพาะนี้มีประโยชน์ในการกันผลลบปลอม (false negative) ซึ่งพบว่าหากการทดสอบมีความจำเพาะมากขึ้นก็จะส่งผลให้โอกาสที่จะได้ผลบวกที่ไม่เป็นจริง (false positive) นั้นก็จะลดน้อยลงเช่นกัน และ Matthews correlation coefficient คือ ค่าสัมประสิทธิ์สหสัมพันธ์แมตทิวส์ เป็นตัวชี้วัดคุณภาพของไบนารี (สองชั้น) โดยการจำแนกประเภทนี้เป็นการวัดค่าทางสถิติที่จะให้คะแนนสูงเมื่อการทำนายได้ผลดีในทั้งสี่ตัวแปรดังกล่าวด้วยการวัดค่าผลรวมของตัวแปรทั้งสี่ประเภทรวมกัน หากผลลัพธ์ของการทดสอบที่ได้มีค่ามากก็แสดงถึงอัลกอริทึมที่ทำงานแบบเดาสุ่มน้อยลงหรือมีความแม่นยำมากขึ้น

4. ผลการวิจัย

4.1 การบินถ่ายภาพทางอากาศด้วยอากาศยานไร้คนขับขนาดเล็กของการเกิดไฟป่าจริงในพื้นที่ศึกษา


การเก็บข้อมูลด้วยอากาศยานไร้คนขับเป็นการบินถ่ายภาพครอบคลุมพื้นที่ป่าไม้ โดยกำหนดให้มีรูปแบบของการถ่ายภาพให้เป็นภาพตั้ง (vertical image) ที่มีแกนของกล้องถ่ายภาพมีมุม 90 องศา กับระดับพื้นดิน และมีความละเอียดของไฟล์ภาพที่ 20 เมกะพิกเซล โดยกำหนดความสูงของการบินถ่ายภาพที่ 425 เมตรจากระดับของพื้นที่ดินที่จุดปล่อยของ UAV ซึ่งจากความสูงดังกล่าวส่งผลให้สามารถกำหนดความละเอียดเชิงพื้นที่หรือระยะสุ่มเชิงพื้นที่ (GSD) ของภาพถ่ายอยู่ที่ระดับ 10 เซนติเมตรต่อจุดภาพ (pixel) ซึ่งถือเป็นภาพถ่ายทางอากาศที่มีความละเอียดสูง (high spatial resolution)



รูปที่ ๕ ตัวอย่างภาพถ่ายทางอากาศที่มีการเกิดไฟจริงจากอากาศยานไร้คนขับ

สำหรับความถูกต้องเชิงพื้นที่ (spatial accuracy) ของภาพถ่ายได้ถูกกำหนดรูปแบบการบินถ่ายภาพด้วยเทคนิคการปรับค่าเชิงตำแหน่งเวลาจริงแบบ Real-Time Kinematic (RTK) ร่วมกับ

การประมวลผลหลังการดำเนินงานแบบ Post-Processing Kinematic (PPK) ด้วยการรับสัญญาณจากเครื่องรับวัดตำแหน่ง GNSS ในภาคสนามเพื่อให้มีความคลาดเคลื่อนเชิงตำแหน่งทางราบของภาพถ่ายอยู่ที่ระดับ 2 เซนติเมตร ซึ่งถือได้ว่ามีความถูกต้องเชิงพื้นที่สูงตามมาตรฐานทางแผนที่ของ ASPRS โดยความถูกต้องของภาพถ่ายนี้จะถูกนำไปยืนยันในการระบุพิกัดตำแหน่งของการเกิดไฟป่าในระบบแจ้งเตือนไฟป่าต่อไประบบการแจ้งเตือนไฟป่าที่พัฒนาขึ้นนั้นได้ออกแบบให้มีการนำข้อมูลภาพถ่ายจากอากาศยานไร้คนขับนำมาทำการอัปโหลดเข้าสู่ระบบเพื่อจำแนกหาตำแหน่งที่มีควันและไฟในภาพ พร้อมทั้งรายงานตำแหน่งพิกัดด้วยการแสดงตำแหน่งไฟลงบนแผนที่พื้นฐานเพื่อแจ้งพิกัดการเกิดไฟด้วยภาพถ่ายทางอากาศจากระบบอากาศยานไร้คนขับ



รูปที่ ๖ ภาพถ่ายออร์โธโมเสกที่มีการเกิดไฟป่า จำนวน 452 ภาพ

4.2 การศึกษาและพัฒนาระบบตรวจจับไฟป่าแบบอัตโนมัติด้วยปัญญาประดิษฐ์ (AI) โดยการใช้ภาพจากอากาศยานไร้คนขับ (UAV)

4.2.1 การสร้างและทดสอบระบบรู้จำรูปภาพ


ข้อมูลภาพที่นำมาใช้ในการทดลองได้ใช้ภาพที่มีไฟเกิดขึ้น 655 ภาพ และไม่มีไฟ 3,881 ภาพ จากภาพที่ถ่ายได้จากอากาศยานไร้คนขับในฤดูกาลไฟป่าที่ผ่านมา โดยมีแบ่งข้อมูลใช้ในการทดลองเป็น 3 กลุ่ม คือ กลุ่มแรกใช้ในการฝึกสอน (train)

กลุ่มที่สองใช้ในการประเมินความลำเอียงของโมเดล (validation) และกลุ่มที่สามใช้ทดสอบโมเดล (test) จากตารางเห็นว่าจำนวนของภาพที่มีไฟและไม่มีไฟมีจำนวนต่างกันมาก ซึ่งพิจารณาได้ว่าข้อมูลไม่มีความสมดุล เพื่อแก้ปัญหาคำสมดุลของข้อมูล ผู้วิจัยใช้ภาพที่มีไฟทุกภาพในการทดลอง แต่สำหรับกลุ่มภาพไม่มีไฟผู้วิจัยได้สุ่มเลือกภาพในกลุ่มนี้มาในจำนวนที่เท่ากับภาพมีไฟ ภาพในกลุ่มที่หนึ่งและสองมีจำนวนภาพรวมกันเป็นร้อยละ 80 ของภาพทั้งหมดที่เหลือเป็นกลุ่มที่สาม

ตารางที่ 1 รายละเอียดชุดข้อมูลที้นำมาใช้ในการทดลอง

	Fire	No Fire
Number	655	3881
Train	420	420
Validation	104	104
Test	131	131

การสร้างโมเดลการเรียนรู้เชิงลึกในงานวิจัยนี้ ได้ใช้แพลตฟอร์มของ Kaggle ซึ่งเป็นบริการหนึ่งของ Google ที่ให้บริการซอฟต์แวร์และฮาร์ดแวร์ ซึ่งอนุญาตให้นักวิทยาศาสตร์ข้อมูลได้ทำการทดลองแนวคิด สร้าง แบ่งปันชุดข้อมูลและโมเดลที่สร้างขึ้น เพื่อเป็นการแลกเปลี่ยนเรียนรู้ของผู้คนในวงการ รวมถึงจัดให้มีการแข่งขันแก้ปัญหาทางด้านวิทยาศาสตร์ข้อมูลเพื่อชิงเงินรางวัลอีกด้วย ดังรูปที่ 7 แสดงหน้าเว็บของ Kaggle และตัวอย่างการใช้งาน ในภาพเป็นการฝึกสอนโมเดลการเรียนรู้เชิงลึกอัลกอริทึมหนึ่ง 10 รอบ และแสดงผลความถูกต้องของโมเดลจากกราฟสรุป ทีมวิจัยจึงเลือกใช้ Densenet121 เนื่องจากมีประสิทธิภาพสูงที่สุดจากการวัดประเมินผล




รูปที่ ๗ หน้าจอแสดงผลของ Kaggle

โดยจากรูปที่ 7 train_loss คือ loss ที่เกิดจากการคำนวณจากข้อมูลที่ใช้สอนโมเดล และ valid_loss คือ loss ที่เกิดจากการคำนวณจากข้อมูลที่ไม่เคยเห็นมาก่อน ใช้เพื่อทดสอบโมเดลในกรณีที่เรานำไปใช้จริง แล้วโมเดลต้องเจอกับข้อมูลที่ไม่เคยเห็นมาก่อน แล้วจะยังสามารถทำอย่างที่เราต้องการได้หรือไม่ ความสามารถที่โมเดลเรียนรู้เมื่อโมเดลการเรียนรู้เชิงลึกผ่านการฝึกสอนมากขึ้น

4.2.2 การสอนโมเดล

ในการสอนโมเดลการเรียนรู้เชิงลึกในเบื้องต้น ใช้การเรียนรู้เชิงลึกที่มีอัลกอริทึมชื่อว่า Densenet121 เป็นโครงสร้างพื้นฐาน ภาพสำหรับสอนในการสอนโมเดลการเรียนรู้เชิงลึกเพื่อให้โมเดลได้เรียนรู้การแยกภาพมีไฟหรือไม่มีไฟ ได้มาจากการเก็บข้อมูลภาคสนามในฤดูกาลที่ผ่านมา ทั้งนี้ระหว่างการสอนต้องมีการปรับอัตราการเรียนรู้ (learning rate) ของโมเดลเพื่อให้ได้อัตราการเรียนรู้ที่เหมาะสม หากอัตราการเรียนรู้ต่ำไปจะเกิดเหตุการณ์โมเดล Underfitting แต่หากอัตราการเรียนรู้สูงเกินไปจะเกิดเหตุการณ์โมเดล Overfitting เมื่อเลือกค่าอัตราการเรียนรู้ที่เหมาะสมค่าความสูญเสียในการเรียนรู้จะลดลง แต่เมื่อถึงจุดหนึ่งเมื่อค่าอัตราการเรียนรู้เพิ่มขึ้นค่าความสูญเสียไม่ได้ลดลงแต่กลับเพิ่มขึ้นดังแสดงในรูป



รูปที่ ๘ ความสัมพันธ์ระหว่างอัตราการเรียนรู้และความสูญเสียที่เกิดขึ้น

หลังจากได้โมเดลที่ได้รับการสอนแล้ว การทำการทดสอบโมเดลที่ได้มาด้วยการป้อนกลุ่มภาพที่ใช้สำหรับการทดสอบเพื่อหาประสิทธิภาพของโมเดล ผลที่ได้มีการพัฒนาประสิทธิภาพของโมเดลยังไม่ได้ระดับที่คาดหวังจะทำการสอนสามารถทำการปรับปรุงโมเดลหลายวิธี เช่น เพิ่มจำนวนภาพที่ใช้สอน เปลี่ยนโครงสร้างของอัลกอริทึมที่ใช้ เพิ่มจำนวนรอบในการสอน เป็นต้น

4.2.3 ระบบแจ้งเตือนการเกิดไฟป่า

ระบบแจ้งเตือนได้ทำการออกแบบให้มีขั้นตอน Pre-Processing Process โดยการอ่านค่าพิกัดจากภาพถ่ายทางอากาศที่ผู้ใช้ได้อัปโหลดสำเร็จแล้วเพื่อนำมาตัดแบ่งภาพออกเป็นภาพย่อย 4x5 ส่วน และ Processing Process โดยการนำค่า GNSS Info ที่ได้มาจากภาพถ่ายนำเข้าสูตรการคำนวณเพื่อหาพิกัดอ้างอิงเชิงตำแหน่งละติจูด (latitude) และลองจิจูด (longitude) โดยสามารถคำนวณได้ดังสมการ ดังนี้

$$C = d + \left(\frac{m}{60}\right) + \left(\frac{s}{3600}\right) \quad (1)$$

โดยที่ C คือ Coordinate

d คือ degrees


m คือ minutes

s คือ seconds

หลังจากการประมวลผลในขั้นทั้งหมดแล้ว ระบบจะทำการสรุปผลข้อมูล โดยแสดงผลการประเมินในแผนที่ออนไลน์ที่สามารถอ้างอิงพิกัดตำแหน่งของภาพที่อัปโหลดเพื่อประมวลผลในระบบ โดยการแสดงผลการทำงานและแสดงระบบแจ้งเตือนเป็นการอธิบายโดยภาพรวม ซึ่งระบบได้รับการพัฒนาอย่างต่อเนื่องเพื่อให้พร้อมสำหรับการใช้งานจริง ในฤดูกาลที่เกิดไฟป่าในปีถัดไปเพื่อเป็นระบบที่มีความแม่นยำและสามารถใช้งานได้อย่างอิงจากข้อมูล สภาพภูมิประเทศป่าของเชียงใหม่ เพื่อการสร้างผลตรวจจับอย่างแม่นยำทั้งนี้ความแม่นยำของโมเดลจะเพิ่มขึ้นได้เมื่อมีการเพิ่มจำนวนภาพตัวอย่างในการเรียนรู้ของโมเดล จะสามารถสร้างการจำแนกลักษณะไฟและควันที่เกิดขึ้นในพื้นที่ป่าได้อย่างมีประสิทธิภาพ ดังรูปที่ 9 และ 10



รูปที่ ๙ แสดงตัวอย่างผลการประเมินผลจาก AI โดยอ้างอิง Coordinate จากภาพที่อัปโหลด



รูปที่ ๑๐ แสดงตัวอย่างตำแหน่งที่ถูกประเมินว่าได้เกิดไฟป่าขึ้น โดยสามารถแสดงค่าร้อยละความเชื่อมั่นของการเกิดไฟ


5. อภิปรายผลการศึกษา

การพัฒนาแบบปัญญาประดิษฐ์ในการตรวจจับไฟป่าด้วยการใช้ข้อมูลภาพถ่ายจากอากาศยานไร้คนขับขนาดเล็กเพื่อสร้างระบบจำแนกวัตถุด้วย AI ด้วยการประมวลผลภาพ (Image processing) ประกอบด้วยการพัฒนาโมเดลที่ได้จาก Kaggle Export ซึ่งเป็น PT format นำมาประมวลผลร่วมกับ Pytorch Library ซึ่งใช้สำหรับการทำงานด้าน AI ด้วยรูปแบบภาษาโปรแกรมคอมพิวเตอร์ Python ที่สามารถพัฒนาโปรแกรมสำหรับการอัปโหลดภาพและการเข้าสู่กระบวนการจำแนกข้อมูลบนภาพได้ โดยหลังทำการอัปโหลดภาพถ่ายทางอากาศระบบได้ดำเนินการ Extract Exif Data จาก Metadata ของภาพถ่ายจากระบบอากาศยานไร้คนขับ โดยมีค่าพิกัดตำแหน่งของภาพ (GPSInfo) เป็นข้อมูลอ้างอิงเชิงตำแหน่งบนแผนที่ทั้งพิกัดละติจูดและลองจิจูด (GPSLatitudeRef และ GPSELongitudeRef) หลังจากทำการกระบวนการข้างต้นแล้วจะนำค่าที่ได้จากภาพมาทำการคำนวณหาพิกัดอ้างอิง และจัดเก็บไว้เป็นตามจุดที่มีการตรวจเจอไฟและควัน

การทดสอบความถูกต้องและประสิทธิภาพของโมเดลที่นำมาใช้ในการศึกษาและพัฒนาในครั้งนี้ โดยการเปรียบเทียบโมเดลต่าง ๆ เพื่อสร้างโมเดลทำนายข้อมูลแบบสองสถานะ (binary classifier) ด้วยการใช้เครื่องมือวัดประสิทธิภาพของโมเดลเพื่อทำการประเมินว่าโมเดลชนิดใดที่เหมาะสมต่อการนำมาใช้งานกับข้อมูลภาพถ่ายการเกิดไฟป่า งานวิจัยนี้ได้ใช้เครื่องมือวัดประสิทธิภาพของโมเดล 4 ชนิด คือ Accuracy, Sensitivity, Specificity, และ Matthews correlation coefficient

การศึกษาค้นคว้าได้ทดลองใช้อัลกอริทึมของการเรียนรู้เชิงลึกมาทดสอบ 6 ชนิด คือ Resnet18,

Restnet34, Alexnet, Vgg11, Densenet121 และ Vgg16 โดยได้ผลการวัดประสิทธิภาพ ดังรูปที่ 11 และ ตารางที่ 2 จะเห็นได้ว่า Densenet121 คือ โมเดลที่มีประสิทธิภาพสูงที่สุดในการใช้งานกับข้อมูลประเภทนี้ในระบบ Kaggle ด้วยมีผลของประสิทธิภาพในทั้ง 4 ด้านที่ดีที่สุด อันสามารถนำไปสู่การฝึกสอนโมเดลเชิงลึกที่มีประสิทธิภาพมากที่สุด



รูปที่ ๑๑ กราฟสรุปประเมินประสิทธิภาพของอัลกอริทึม

ตารางที่ 2 ผลการทดสอบเปรียบเทียบประสิทธิภาพของอัลกอริทึมการเรียนรู้เชิงลึก 6 แบบ

	Acc	Sens	Spec	MCC
Restnet18	0.899369	0.878032	0.878032	0.431277
Restnet34	0.892202	0.910987	0.910987	0.450118
Alexnet	0.912557	0.884883	0.884883	0.460309
Densenet121	0.893922	0.915548	0.915548	0.456683
Vgg11	0.884174	0.884809	0.884809	0.415829
Vgg16	0.849771	0.896279	0.896279	0.389063

จากกระบวนการทดสอบของอัลกอริทึมดังกล่าวเพื่อเป็นการวัดประสิทธิภาพของโมเดลแล้ว โดยการใช้กลุ่มภาพที่แยกไว้สำหรับทำการสอนโมเดล ซึ่งได้เลือกใช้อัลกอริทึม Densenet121 ในระบบ Kaggle เนื่องจากมีผลของประสิทธิภาพในทั้ง 4 ด้านที่ดีที่สุด เพื่อทำการฝึกสอนโมเดลเชิงลึก ผลลัพธ์ทำให้ได้โมเดลที่พร้อมใช้งานในการทดสอบโมเดลนั้น โดยได้ทำการทดสอบโดยการป้อนกลุ่มภาพที่แบ่งไว้ใช้

สำหรับทดสอบ จำนวน 208 รูป เพื่อหาประสิทธิภาพความแม่นยำในการจำแนกข้อมูล

epoch	train_loss	valid_loss	accuracy	time
0	1.410730	0.937948	0.449761	00:31
1	1.436906	1.002798	0.449761	00:29
2	1.345647	0.902475	0.535885	00:30
3	1.237255	0.790503	0.574163	00:29
4	1.178961	0.718780	0.636364	00:29
5	1.084527	0.672842	0.641148	00:30
6	1.012022	0.643200	0.665072	00:30
7	0.972650	0.621979	0.693780	00:29
8	0.920105	0.621864	0.688995	00:29
9	0.923507	0.615587	0.684211	00:29

รูปที่ ๑๒ การประเมินประสิทธิภาพของโมเดลจากการสอนจำนวน 10 รอบ

จากผลลัพธ์ของกระบวนการทดสอบประสิทธิภาพของการสอนโมเดลจะเห็นได้ว่าการสอนโมเดลทั้งหมด 10 รอบ จำนวนและร้อยละของความแม่นยำ (accuracy) โดยเริ่มจาก 44.97% เพิ่มความแม่นยำไปจนถึง 68.42% ตามลำดับ ซึ่งสอดคล้องกับจำนวนครั้งที่ได้รับการสอนโมเดลที่เพิ่มมากขึ้นก็จะส่งผลให้มีความแม่นยำมากขึ้นเช่นกัน ดังข้อมูลในรูปที่ 12 โดยจากการสอนโมเดลที่ใช้วิธีการ Transfer Learning ซึ่งสามารถทำการสอนโมเดลได้ด้วยเวลาและทรัพยากรที่จำกัดที่ไม่จำเป็นต้องสร้าง Convolutional Neural Network ใหม่อีกครั้ง หลังจากนั้นได้นำโมเดลดังกล่าวมาเป็นโมเดลตั้งต้นเพื่อทำการสอนให้เข้ากับชุดข้อมูลที่ผู้วิจัยได้ทำการจัดเก็บมา ซึ่งเป็น Dataset ขนาดเล็กในงานเฉพาะทาง จึงสามารถเป็นการลดระยะเวลาในการสอนโมเดลได้ภายใน 10 รอบ และได้ประสิทธิภาพที่ดีและให้อยู่ในระดับความแม่นยำที่ยอมรับได้

6. บทสรุป

การศึกษาและพัฒนาต้นแบบปัญญาประดิษฐ์เพื่อระบบตรวจจับการเกิดไฟฟ้าด้วยข้อมูลภาพจากอากาศยานไร้คนขับ ได้ทำการบินถ่ายภาพทางอากาศด้วยอากาศยานไร้คนขับขนาดเล็กของการเกิดไฟฟ้าจริงในพื้นที่ศึกษาด้วยการบันทึกภาพแบบ snap shot จากระบบกล้องถ่ายภาพของ UAV ในช่วงแสงขาวมองเห็นได้ (visible light) หรือในระบบตรวจจับแสงในช่วงคลื่น Blue Green และ Red เพื่อนำมาใช้เป็นภาพต้นแบบของการสร้างการเรียนรู้ข้อมูลให้กับระบบปัญญาประดิษฐ์ในการตรวจจับการเกิดไฟฟ้า โดยได้ทำการบันทึกภาพ รวมจำนวน 4,536 ภาพ โดยเป็นภาพที่มีไฟฟ้า จำนวน 655 ภาพ และไม่มีไฟฟ้านจำนวน 3,881 ภาพ และได้จำแนกข้อมูลออกเป็นสองส่วนเพื่อนำมาทดสอบและสอนโมเดล จำนวน 840 ภาพ ทดสอบความเร็วและความถูกต้องโมเดล 208 ภาพ และทดสอบการใช้งานโมเดล 262 ภาพ

สำหรับการพัฒนาระบบตรวจจับไฟฟ้าแบบอัตโนมัติด้วยปัญญาประดิษฐ์ (AI) เพื่อตรวจจับไฟฟ้าและควันไฟในพื้นที่ป่าไม้ที่มีต้นไม้หนาแน่น โดยการใช้เครื่องมือวัดประสิทธิภาพของโมเดล 4 ชนิด คือ Accuracy, Sensitivity, Specificity และ Matthews correlation coefficient ซึ่งได้นำมาทดสอบด้วยวิธี Direct validation โดยได้ทดลองใช้อัลกอริทึมของการเรียนรู้เชิงลึกมาทดสอบ 6 ชนิด คือ Resnet18, Resnet34, Alexnet, Vgg11, Densenet121 และ Vgg16 และได้ทำการใช้กลุ่มภาพที่แยกไว้สำหรับสอนโมเดลทำการสอนโมเดล จากการประเมินประสิทธิภาพโมเดล Densenet121 ในระบบ Kaggle ได้ถูกเลือกใช้ในการฝึกสอนโมเดลเชิงลึก ซึ่งได้ผลลัพธ์ออกมาเป็นโมเดลที่พร้อมใช้งานที่มีประสิทธิภาพของการสอน เพื่อทำการวิเคราะห์หาจุดเกิดไฟฟ้าเป้าหมาย และทำการรายงานเป็นพิกัดตำแหน่งของไฟฟ้าโดยอัตโนมัติในระบบแจ้งเตือนไฟฟ้า

7. กิตติกรรมประกาศ

คณะวิจัยขอขอบคุณสถาบันเทคโนโลยีป้องกันประเทศที่ได้อนุเคราะห์และสนับสนุนงบประมาณในการศึกษาและพัฒนาการวิจัยในครั้งนี้

8. เอกสารอ้างอิง

- [1] สำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ (องค์การมหาชน), “สรุปสถานการณ์ไฟฟ้าและหมอกควันด้วยภาพถ่ายดาวเทียมประจำปี 2562,” กระทรวงการอุดมศึกษา วิทยาศาสตร์ วิจัยและนวัตกรรม, 2562.
- [2] พ. เหมวรรณ. การวิเคราะห์และแปลความภาพถ่ายทางอากาศจากอากาศยานไร้คนขับ. เชียงใหม่: ภาควิชาภูมิศาสตร์ คณะสังคมศาสตร์ มหาวิทยาลัยเชียงใหม่, 2563.
- [3] ส. บุญธรรัตน์, ธ. เหล่าสุวรรณ, และ อ. ภูมิระกาญจนะ โรแบร์, “รูปแบบการตรวจสอบความเสียหายโครงข่ายสายส่งไฟฟ้าด้วยอากาศยานไร้คนขับ,” *วารสารวิชาการเทคโนโลยีป้องกันประเทศ*, ปีที่ 2, ฉบับที่ 4, น. 12 - 31, 2563.
- [4] พ. สันติธรรมนนท์, ภ. อุทัยศรี, และ ธ. ชื่นชม. สนามทดสอบการทำแผนที่ด้วยอากาศยานไร้คนขับ. กรุงเทพฯ: คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย, 2554.
- [5] W. Sun, P. Singkhamfu, and P. Suwansrikham, “UAV Photogrammetry-Based Accident Assessment Road Condition Analysis Using Image Classification,” in *Int. Conf. Digit. Arts, Media Technol.*, 2022, pp. 319 - 322, doi: 10.1109/ECTIDAMTNCN 53731.2022.9720398.
- [6] A. Bhradwaj, L. Sam, Akansaka, F. J. Martin -Torres, and R. Kumar, “UAVs as Remote

- Sensing Platform in Glaciology: Present Application and Future Prospects,” *Remote Sens. Environ.*, vol. 175, pp. 196 - 204, 2016.
- [7] S. P. Bemis *et al.*, “Ground-based and UAV-based Photogrammetry: A Multi-scale, High Resolution Mapping Tool for Structural Geology and Paleoseismology,” *J. Struct. Geol.*, vol. 69, Part A, pp. 163 - 178, 2014.
- [8] C. C. Li, G. S. Zhang, T. J. Lei, and A. D. Gong, “Quick Image-processing Method of UAV without Control Points Data in Earthquake Disaster Area,” *Trans. Nonferrous Met. Soc. China*, vol. 21, Supplement 3, pp. s523 - s528, 2011.
- [9] J. R. R. Uijlings, K. E. A. Van de Sande, T. Gevers, and A. W. M. Smeulders, “Selective Search for Object Recognition,” *Int. J. Comput. Vis.*, vol. 104, pp. 154 - 171, 2013.
- [10] O. Küng *et al.*, “The Accuracy of Automatic Photogrammetric Techniques on Ultra-light UAV Imagery,” *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, vol. XXXVIII-1/C22, pp. 125 - 130, 2011.
- [11] S. Nebiker, A. Annen, M. Scherrer, and D. Oesch, “A Light-weight Multispectral Sensor for Micro UAV Opportunities for Very High Resolution Airborne Remote Sensing,” in *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, Beijing, China, 2008, pp. 1193 - 1199.
- [12] C. A. Rokhmana, “The Potential of UAV-based Remote Sensing for Supporting Precision Agriculture in Indonesia,” *Procedia Environ. Sci.*, vol. 24, pp. 245 - 253, 2015.
- [13] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” in *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 39, no. 6, pp. 1137 - 1149, 2017.
- [14] S. Siebert and J. Teizer, “Mobile 3D Mapping for Surveying Earthwork Projects Using an Unmanned Aerial Vehicle (UAV) System,” *Autom. Constr.*, vol. 41, pp. 1 - 14, 2014.
- [15] S. Sudhakar, V. Vijayakumar, C. Sathiyakumar, V. Priya, L. Ravi, and V. Subramaniaswamy, “Unmanned Aerial Vehicle (UAV) based Forest Fire Detection and Monitoring for Reducing False Alarms in Forest-fires,” *Comput. Commun.*, vol. 149, pp. 1 - 16, 2020.
- [16] M. Uysal, A. S. Toprak, and N. Polat, “DEM Generation with UAV Photogrammetry and Accuracy Analysis in Sahitler Hill,” *Measurement*, vol. 73, pp. 539 - 543, 2015.
- [17] D. Ventura, M. Bruno, G. J. Lasinio, A. Belluscio, and G. Ardizzone, “A Low-cost Drone Based Application for Identifying and Mapping of Coastal Fish Nursery Grounds,” *Estuar. Coast. Shelf Sci.*, vol. 171, pp. 85 - 98, 2016.
- [18] S. A. Vollgger and A. R. Cruden, “Mapping Folds and Fractures in Basement and Cover Rocks using UAV Photogrammetry, Cape Liptrap and Cape Paterson, Victoria, Australia,” *J. Struct. Geol.*, vol. 85, pp. 168 - 187, 2016.