

การเพิ่มประสิทธิภาพการติดตามสภาวะวิกฤต: กรณีศึกษาฟาร์มเพาะเลี้ยง
กุ้ง



จรัสพงศ์ เทพมณี

วิทยานิพนธ์เสนอมหาวิทยาลัยพะเยา เพื่อเป็นส่วนหนึ่งของการศึกษา

หลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมคอมพิวเตอร์

พฤษภาคม 2568

ลิขสิทธิ์เป็นของมหาวิทยาลัยพะเยา

การเพิ่มประสิทธิภาพการติดตามสภาวะวิกฤต: กรณีศึกษาฟาร์มเพาะเลี้ยงกุ้ง



วิทยานิพนธ์เสนอมหาวิทยาลัยพะเยา เพื่อเป็นส่วนหนึ่งของการศึกษา


หลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมคอมพิวเตอร์

พฤษภาคม 2568

ลิขสิทธิ์เป็นของมหาวิทยาลัยพะเยา

CRISIS MONITORING PERFORMANCE ENHANCEMENT: A CASE STUDY OF LAC
CULTIVATION FARM



JARATPONG TEPMANEE

A Thesis Submitted to University of Phayao
in Partial Fulfillment of the Requirements
for the Master of Engineering Degree in Computer Engineering
May 2025

Copyright 2025 by University of Phayao

วิทยานิพนธ์

เรื่อง

การเพิ่มประสิทธิภาพการติดตามสถานะวิกฤต: กรณีศึกษาฟาร์มเพาะเลี้ยงกุ้ง

ของ จรัสพงศ์ เทพมณี

ได้รับพิจารณาอนุมัติให้เป็นส่วนหนึ่งของการศึกษา

หลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมคอมพิวเตอร์

ของมหาวิทยาลัยพะเยา

ประธานกรรมการสอบวิทยานิพนธ์

(ผู้ช่วยศาสตราจารย์ ดร. วีรพล จิรจรีต)

ประธานที่ปรึกษาวิทยานิพนธ์

(ผู้ช่วยศาสตราจารย์ ดร. จีราพร ไชยวงศ์สาย)

กรรมการที่ปรึกษาวิทยานิพนธ์

(ผู้ช่วยศาสตราจารย์ ดร. ธนา อุดมศรีไพบูลย์)

อาจารย์บัณฑิตศึกษามหาวิทยาลัยพะเยา

(ดร. นราศักดิ์ บุญเทพ)

อาจารย์บัณฑิตศึกษามหาวิทยาลัยพะเยา

(ผู้ช่วยศาสตราจารย์ ดร. บวรศักดิ์ ศรีสังสิทธิสันติ)

คณบดีคณะเทคโนโลยีสารสนเทศและการสื่อสาร

(ผู้ช่วยศาสตราจารย์ ดร. พรเทพ ไรจนวสุ)

เรื่อง: การเพิ่มประสิทธิภาพการติดตามสภาวะวิกฤต: กรณีศึกษาฟาร์มเพาะเลี้ยงกุ้ง

ผู้วิจัย: จรัสพงศ์ เทพมณี, วิทยานิพนธ์: วศ.ม. (วิศวกรรมคอมพิวเตอร์), มหาวิทยาลัยพะเยา, 2567

อาจารย์ที่ปรึกษา: ผู้ช่วยศาสตราจารย์ ดร. จิราพร ไชยวงศ์สาย อาจารย์ที่ปรึกษาร่วม ผู้ช่วยศาสตราจารย์ ดร.ธนา อุดมศรีไพบูลย์

คำสำคัญ: การติดตามสภาวะวิกฤต, การเพาะเลี้ยงกุ้ง, เซ็นเซอร์อัจฉริยะ, การตรวจจับการเกิดไฟไหม้, ระยะทางมหาลาโนบิส, คาลมาน ฟิลเตอร์

บทคัดย่อ

งานวิจัยนี้นำเสนอแนวทางในการเพิ่มประสิทธิภาพของระบบติดตามและแจ้งเตือนสภาวะวิกฤตในฟาร์มเพาะเลี้ยงกุ้ง โดยพัฒนาระบบที่สามารถตรวจจับไฟไหม้ได้อย่างแม่นยำในสภาพแวดล้อมกลางแจ้งซึ่งมีความแปรปรวนสูง ระบบดังกล่าวประกอบด้วย การเก็บข้อมูลจากเซ็นเซอร์ไมโครคอนโทรลเลอร์ ESP32 พร้อมโมดูลวัดอุณหภูมิและความชื้น SHT20 และเซ็นเซอร์ตรวจจับฝุ่นละออง PMS3003 เพื่อนำข้อมูลไปประมวลผลผ่านแพลตฟอร์ม ThingSpeak ร่วมกับ MATLAB โดยใช้เทคนิค Kalman Filter สำหรับลดสัญญาณรบกวน และ Mahalanobis Distance ในการตรวจจับความผิดปกติ ระบบที่พัฒนาขึ้นสามารถแจ้งเตือนไฟไหม้ได้ด้วยความแม่นยำ (Precision) เท่ากับ 75.41% และมีความสามารถในการตรวจจับเหตุการณ์จริง (Recall) ได้ 30.20% ซึ่งสูงกว่าวิธี Euclidean Distance ที่มีค่า Precision เท่ากับ 51.06% และ Recall เพียง 15.80% นอกจากนี้ ค่า F1 Score ของระบบที่ใช้ Mahalanobis Distance ยังสูงกว่าถึง 43.17% เมื่อเทียบกับ 24.08% ในวิธี Euclidean Distance แสดงถึงความสามารถในการลดการแจ้งเตือนผิดพลาด (False Alerts) ได้ดีกว่าอย่างชัดเจน ผลการทดลองแสดงให้เห็นว่าการใช้ Kalman Filter ร่วมกับ Mahalanobis Distance มีประสิทธิภาพในการตรวจจับไฟไหม้ในฟาร์มกลางแจ้งที่แวดล้อมด้วยปัจจัยแปรปรวนทางธรรมชาติได้อย่างแม่นยำ และสามารถนำไปประยุกต์ใช้กับระบบติดตามสิ่งแวดล้อมในบริบทอื่น ๆ ได้อย่างมีประสิทธิภาพ

Title: CRISIS MONITORING PERFORMANCE ENHANCEMENT: A CASE STUDY OF LAC CULTIVATION FARM

Author: Jaratpong Tepmanee, Thesis: M.En. (Computer Engineering), University of Phayao, 2024

Advisor: Assistant Professor Ph.D. Jirabhorn Chaiwongsai Co-advisor Assistant Professor Ph.D.Thana Udomsripaiboon

Keywords: Crisis monitoring, Lac cultivation, Wildfire detection, Intelligent sensors, Kalman Filter, Mahalanobis Distance

ABSTRACT

This research presents an approach to enhance the efficiency of monitoring and fire alert systems in outdoor lac cultivation farms by developing a system capable of accurately detecting fire hazards in highly variable outdoor environments. The system collects environmental data using ESP32 microcontrollers equipped with temperature and humidity sensors (SHT20) and particulate matter sensors (PMS3003). The data are transmitted to the ThingSpeak platform and processed using MATLAB, applying Kalman Filter for signal smoothing and Mahalanobis Distance for anomaly detection. The proposed system achieved a high fire alert precision of 75.41% and a recall of 30.20%, outperforming the Euclidean Distance method, which recorded a precision of 51.06% and a recall of only 15.80%. Furthermore, the F1 Score of the Mahalanobis-based system reached 43.17%, compared to 24.08% for the Euclidean-based system. These results indicate that Mahalanobis Distance significantly reduces false alerts and improves detection accuracy under real-world field conditions. The findings demonstrate that integrating Kalman Filtering with Mahalanobis Distance is effective for detecting fire anomalies in outdoor farming environments. The system provides a reliable foundation for early warning applications in agricultural fire prevention and can be extended to other environmental monitoring contexts requiring robust anomaly detection.

กิตติกรรมประกาศ

ข้าพเจ้าขอขอบพระคุณ อาจารย์ที่ปรึกษาหลัก ผู้ช่วยศาสตราจารย์ดร. จิราพร ไชยวงศ์ สาย และ อาจารย์ที่ปรึกษาร่วม ดร. ธนา อุดมศรีไพบุลย์ ที่ได้ให้คำแนะนำและสนับสนุนตลอด การทำวิทยานิพนธ์ฉบับนี้ ข้าพเจ้าขอขอบคุณ คณาจารย์ในสาขาวิชาวิศวกรรมคอมพิวเตอร์ ที่ได้ ให้คำแนะนำและความคิดเห็นอันเป็นประโยชน์ต่อการทำวิจัย

ข้าพเจ้าขอขอบคุณ ครอบครัว ที่คอยเป็นกำลังใจสำคัญและสนับสนุนในทุก ๆ ด้าน ตลอดระยะเวลาที่ผ่านมา รวมทั้งขอขอบคุณ เพื่อนร่วมงานและเพื่อนนักศึกษา ที่ได้ให้กำลังใจ และช่วยเหลือในกระบวนการวิจัยนี้

สุดท้ายนี้ ข้าพเจ้าขอขอบพระคุณ มหาวิทยาลัยพะเยา ที่ให้โอกาสและทรัพยากรในการ ศึกษาวิจัยครั้งนี้ ทั้งหมดนี้มีส่วนสำคัญในการทำให้งานวิจัยฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี

จรัสพงศ์ เทพมณี



สารบัญ

หน้า

บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
บทที่ 1 บทนำ	1
1.1 ที่มาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์.....	1
1. เพื่อพัฒนาระบบตรวจจับไฟไหม้สำหรับฟาร์มเพาะเลี้ยงครึ่งแบบอัจฉริยะ และแจ้งเตือน ผ่านไลน์แอปพลิเคชันผู้ใช้งานแบบอัตโนมัติได้.....	1
1.3 ขอบเขตของวิทยานิพนธ์.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	2
บทที่ 2 งานวิจัยที่เกี่ยวข้อง.....	3
2.1 ความรู้เบื้องต้นเกี่ยวกับครึ่ง.....	3
2.1.1 ครึ่ง	3
2.1.2 ประวัติความเป็นมาของครึ่ง.....	3
2.1.2 แมลงครึ่ง	4
2.1.3 การส่งเสริมเศรษฐกิจผ่านกิจกรรมการเพาะเลี้ยงครึ่ง	5
2.1.4 อุปสรรค ข้อจำกัดในกระบวนการเลี้ยงครึ่ง.....	6
2.1.5 ต้นไม้ที่เหมาะสมแก่การเพาะเลี้ยงครึ่ง.....	6
2.1.5 ช่วงฤดูกาล เพาะเลี้ยงครึ่ง.....	7
2.1.5 คุณสมบัติของครึ่ง.....	8

2.2 งานวิจัยที่เกี่ยวข้อง.....	9
2.2.1 การศึกษางานวิจัยที่เกี่ยวกับระบบตรวจจับการเกิดไฟไหม้.....	9
1. Long-Range Raman Distributed Fiber Temperature Sensor With Early Warning Model for Fire Detection and Prevention (Li และคณะ, 2019).....	13
2. Global analysis of burned areas for climate assessment: experiences from the Fire CCI project (Chuvieco, 2019)	15
3. LPWAN Based IoT Surveillance System for Outdoor Fire Detection (Roque และ Padilla, 2020)	16
4. Intelligent Multi-Sensor Detection System for Monitoring Indoor Building (Baek และคณะ, 2021).....	17
5. An Automatic System for Detection of Fires in Outdoor Areas (Hakeem, Shahadi และAbass, 2022).....	20
6. Instant Fire Detection and Toxic Fumes Monitoring in Forests with a Remote Integrated Rover(Muthulakshmi, Manimekalai และGopikrishna, 2022).....	23
7. Accurate Detection of IoT Sensor Behaviors in Legitimate, Faulty and Compromised Scenarios (Sood และคณะ, 2023)	25
8. Intelligent Air Pollution Sensors Calibration for Extreme Events and Drifts Monitoring (Zaidan และคณะ, 2023).....	27
9. The Analysis of Tourist Satisfaction Integrating the Artistic Intelligence Convolutional Neural Network and Internet of Things Technology (Yan, 2023)	30
10. A Study on the Fire Detection and Smoke Removal in Underground Utility.....	32
Tunnel Using CFD (Cho และคณะ, 2023).....	32
11. Review Study on Recent Developments in Fire Sensing Methods (Sulthana และคณะ, 2023).....	34

12. Uncertainty Assessment–Based Active Learning for Reliable Fire Detection Systems (Kim และKim, 2022)	38
บทที่ 3 การดำเนินงาน	45
3.1 จากการศึกษางานวิจัยที่เกี่ยวข้อง.....	45
3.1.1 การออกแบบเซ็นเซอร์ เพื่อติดตั้งในฟาร์มเพาะเลี้ยงกุ้ง.....	45
3.1.2 ภาพรวมของระบบตรวจจับสภาวะวิกฤต	48
48	
48	
3.2 เทคนิคและวิธีการ	49
3.2.1 ตัวเก็บข้อมูลเซ็นเซอร์.....	49
3.2.2 การกรองข้อมูล	50
3.2.3 ระบบตรวจจับสภาวะวิกฤต	51
3.2.4 การแจ้งเตือนสภาวะวิกฤต.....	55
3.2.4 การแจ้งเตือนการเกิดเพลิงไหม้	56
3.2.5 รูปแบบการเตือนภัยไปยังเกษตรกร.....	57
บทที่ 4	58
ผลการทดลอง.....	58
4.1 บทนำ.....	58
4.2 การกรองข้อมูล คาลมานฟิลเตอร์ (Kalman Filter) เทียบกับ ค่าเฉลี่ยเคลื่อนที่ (Moving Average).....	58
4.2.1 ผลการเปรียบเทียบคาลมานฟิลเตอร์กับค่าเฉลี่ยเคลื่อนที่	59
4.2.2 ข้อสรุปของการกรองข้อมูล.....	60
4.3 การตรวจจับค่าผิดปกติด้วยระยะทางมหาลาโนบิส (Mahalanobis Distance).....	61

4.3.1 วิเคราะห์ผลการตรวจจับค่าผิดปกติจากกราฟระยะทางมหาลาโนบิส (Mahalanobis) ทั้ง 3 ฤดูกาล	61
62	
4.3.2 เหตุผลในการเลือกใช้ VR และ SI เป็นตัวประเมินผล	65
4.3.3 การแสดงผลการทดลองจำแนกค่าผิดปกติในแต่ละฤดูกาล	66
4.3.4 การประเมินผลจากการทดลองไฟไหม้ระยะลูกกลม	68
4.3.5 สรุปผลการประเมินประสิทธิภาพของระบบตรวจจับค่าผิดปกติ	72
4.4 ระบบแจ้งเตือนอัตโนมัติ	73
4.4.1 เงื่อนไขการแจ้งเตือน	73
4.4.2 อัตราการแจ้งเตือนของระบบตรวจจับไฟไหม้ในแต่ละฤดูกาล	73
4.5 รวมต้นทุนอุปกรณ์ทั้งหมด	74
บทที่ 5 สรุปผล	75
5.1 สรุปผลการศึกษา	75
5.2 อภิปรายผล	76
5.2.1 การเปรียบเทียบประสิทธิภาพของ คาลมาน ฟิลเตอร์ (Kalman Filter) และ ค่าเฉลี่ยเคลื่อนที่ (Moving Average)	76
5.2.2 การวิเคราะห์ผลตามฤดูกาลโดยใช้ ระยะห่างมหาลาโนบิส (Mahalanobis Distance)	76
5.2.3 ผลการเปรียบเทียบวิธี Mahalanobis และ Euclidean Distance ($k = 1.0$)	77
5.3 ข้อเสนอแนะ	77
บรรณานุกรม	88
ประวัติผู้วิจัย	92

สารบัญตาราง

หน้า

ตาราง 1 งานวิจัยที่เกี่ยวกับระบบตรวจจับการเกิดไฟไหม้	9
ตาราง 2 ผลการเปรียบเทียบระหว่างค่าลมานฟิลเตอร์และค่าเฉลี่ยเคลื่อนที่.....	59
ตาราง 3 ผลการเปรียบเทียบค่าระยะทาง Mahalanobis และ Euclidean – ฤดูร้อน (Summer)	66
ตาราง 4 ผลการเปรียบเทียบค่าระยะทาง Mahalanobis และ Euclidean – ฤดูฝน (Rainy).....	67
ตาราง 5 ผลการเปรียบเทียบค่าระยะทาง Mahalanobis และ Euclidean – ฤดูหนาว (Winter) 67	
ตาราง 6 อัตราการแจ้งเตือนของระบบตรวจจับไฟไหม้ในแต่ละฤดูกาล	73



สารบัญภาพ

หน้า

ภาพ 1 ครึ่งและการแปรรูปแบบ เพื่อใช้ประโยชน์จากครึ่ง ที่มา (Bashir และคณะ, 2022)	3
ภาพ 2 Bivoltine life cycle of female <i>Kerria lacca</i> (Bashir และคณะ, 2022)	5
ภาพ 3 ตารางแสดงต้นไม้ ที่เหมาะแก่การเพาะเลี้ยงครึ่ง (เด่นรุ่งเรือง, 2014).....	7
ภาพ 4 Stic lac ที่มา https://naturaldyes.ca/lac	8
ภาพ 5 Experimental setup of RDFTS (Li และคณะ, 2019)	13
ภาพ 6 . Flow chart of temperature early warning model. (Li และคณะ, 2019)	14
ภาพ 7 Global Burned area from the FireCCI50 product 2016 (Chuvieco, 2019)	15
ภาพ 8 Wireless technologies comparison (Roque และPadilla, 2020).....	16
ภาพ 9 . Digital response timing according to different conditions(Roque และPadilla, 2020)	17
ภาพ 10 Recorded sensor signals from the proposed fire sensing system(Baek และคณะ, 2021).....	18
ภาพ 11 An overview of the proposed real-time fire detection system(Baek และคณะ, 2021).....	19
ภาพ 12 The proposed system of flame detection (Hakeem, Shahadi และAbass, 2022) ...	21
ภาพ 13 Flame detection based HSVcolor space (Hakeem, Shahadi และAbass, 2022)	22
ภาพ 14 Block Diagram of Proposed System (Muthulakshmi, Manimekalai และGopikrishna, 2022)	23
ภาพ 15 Flowchart for proposed system (Muthulakshmi, Manimekalai และGopikrishna, 2022)	24
ภาพ 16 The proposed high level system model. (Sood และคณะ, 2023)	25
ภาพ 17 The Forest Fire Dataset Details (Sood และคณะ, 2023)	26

ภาพ 18 Recognition accuracy of (a) Classification and regression trees, (b) Random forest, and (c) Support vector machine models for temperature outliers.(Sood และคณะ, 2023) .26	26
ภาพ 19 Intelligent air pollution sensors calibration process(Zaidan และคณะ, 2023).....28	28
ภาพ 20 Time-series data of PM2.5 concentration obtained in the experiment (Zaidan และคณะ, 2023)29	29
ภาพ 21 LCS METEOROLOGICAL SENSORS:CONSISTENCY (Zaidan และคณะ, 2023)29	29
ภาพ 22 Comparison of feature extraction structures.(Yan, 2023)30	30
ภาพ 23 Comparison of improvement effects of different strategies. (Yan, 2023) 31	31
ภาพ 24 Flowchart of the research procedure.(Cho และคณะ, 2023)32	32
ภาพ 25 Internal ceiling core temperature in case of fire source at 7-0: (a) Winter, fans working (b) Winter, fans (Cho และคณะ, 2023)33	33
ภาพ 26 Fire sensing method.(Sulthana และคณะ, 2023).....34	34
ภาพ 27 Fire detection techniques.(Sulthana และคณะ, 2023).....35	35
ภาพ 28 Overall active learning framework for continuous improvement of fire detection performance.(Kim และKim, 2022).....39	39
ภาพ 29 Overall active learning framework for continuous improvement of fire detection performance. (Astillo และคณะ, 2020)42	42
ภาพ 30 ภาพรวมโครงสร้างของอุปกรณ์ ตรวจจับไฟไหม้45	45
ภาพ 31 หน้าแดชบอร์ด ของ ThingSpeak46	46
ภาพ 32 แสดงการวิเคราะห์ข้อมูล เพื่อตรวจหาความผิดปกติ โดย MatLab ออนไลน์46	46
ภาพ 33 อุปกรณ์ตรวจจับไฟไหม้ที่ถูกติดตั้งบนต้นไม้ ในสถานที่จริง..... 47	47
ภาพ 34 บล็อกไดอะแกรม กระบวนการทำงานของระบบตรวจจับสภาวะวิกฤต48	48
ภาพ 35 แสดงการเปรียบเทียบระหว่าง ข้อมูลดิบจากเซ็นเซอร์ และข้อมูลที่ถูกฟิลเตอร์ด้วย คาลมาน ฟิลเตอร์ 51	51
ภาพ 36 ตัวอย่างเหตุการณ์ เพื่อแจ้งเตือนเหตุการณ์สภาวะวิกฤต.....56	56

ภาพ 37 ตัวอย่างเหตุการณ์ เพื่อแจ้งเตือนเหตุการณ์ไฟไหม้	56
ภาพ 38 แสดงตัวอย่างการแจ้งเตือนเกษตรกร และระบุตำแหน่งจุดเกิดเหตุ	57
ภาพ 39 แสดงการเปรียบเทียบค่าลมามานฟิลเตอร์และค่าเฉลี่ยเคลื่อนที่สำหรับ อุณหภูมิ (Temperature).....	59
ภาพ 40 แสดงการเปรียบเทียบค่าลมามานฟิลเตอร์และค่าเฉลี่ยเคลื่อนที่สำหรับ ความชื้น (Humidity).....	60
ภาพ 41 แสดงการเปรียบเทียบค่าลมามานฟิลเตอร์และค่าเฉลี่ยเคลื่อนที่สำหรับ ค่าฝุ่นละออง PM2.5.....	60



บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของปัญหา

ปัจจุบันภาวะโลกร้อนและการระบาดของไฟป่าได้เกิดขึ้นอย่างแพร่หลาย ส่งผลกระทบต่อการทำเกษตรกรรมเลี้ยงครั้งที่หลายประเทศต้องเผชิญหน้า ทำให้เกิดภัยแล้งและอุณหภูมิสูงขึ้น ส่งผลให้เกษตรกรรมต้องรับมือกับสภาวะที่อาจทำให้การผลิตลดลง การทำเกษตรกรรมใกล้ป่ามีความเป็นไปได้ที่จะต้องพบกับปัญหาที่ร้ายแรงจากไฟป่า เนื่องจากป่ามีลักษณะทางธรรมชาติที่ทำให้เป็นจุดอ่อนต่อการระบาดของไฟป่า ไฟป่าไม่เพียงแต่สร้างความเสียหายต่อสิ่งแวดล้อมและชีวิตคนนอกป่า คำนวณไฟป่าส่งผลกระทบ ทำให้มีผู้เสียชีวิตก่อนวัยอันควรประมาณ 7 ล้านคนทุกๆปี (WHO, 2024) และยังมีส่งผลกระทบต่อการเลี้ยงครั้งแรกและทรัพยากรทางธรรมชาติ จำนวนมหาศาล ความเสียหายต่อเศรษฐกิจโลกประมาณ 100 พันล้านดอลลาร์ต่อปี (Reduction, 2022)

เกษตรกรผู้เลี้ยงครั้งที่ตั้งอยู่ใกล้ป่าจึงต้องเผชิญหน้ากับความอ่อนไหวต่อภัยพิบัติจากไฟป่าอย่างต่อเนื่อง รายงานพบว่าพื้นที่ป่าประมาณ 350 ล้านเฮกเตอร์ถูกเผาไหม้ในช่วง 20 ปีที่ผ่านมาและไฟป่าเป็นสาเหตุหลักของการสูญเสียป่าไม้ (FAO, 2022) ซึ่งเป็นปัจจัยสำคัญของการเพาะเลี้ยงครั้งแรก (เด่นรุ่งเรือง, 2014) ต้องมีการเตรียมความพร้อมและมีการวางแผนเพื่อลดผลกระทบที่อาจเกิดขึ้นจึงเป็นสิ่งสำคัญ ทั้งนี้ เราต้องเข้าใจถึงความสำคัญของการปกป้องทรัพยากรธรรมชาติและการทำเกษตรกรรม

จากแนวคิดที่ศึกษาจากปัญหาดังกล่าว ผู้วิจัยมีความสนใจที่จะดำเนินการสร้างอุปกรณ์ตรวจจับไฟป่าชนิดลูกกลม ที่มีการวิเคราะห์สภาพแวดล้อมจากเซนเซอร์ต่างๆ เพื่อลดความเสียหายที่จะรุนแรงขึ้น และยังสามารถส่งตำแหน่งจุดเกิดเหตุได้ทันที

1.2 วัตถุประสงค์

1. เพื่อพัฒนาระบบตรวจจับไฟไหม้สำหรับฟาร์มเพาะเลี้ยงครั้งแรกแบบอัจฉริยะ และแจ้งเตือนผ่านไลน์แอปพลิเคชันผู้ใช้งานแบบอัตโนมัติได้
2. เพื่อวิจัยและพัฒนาระบบตรวจจับไฟไหม้ในฟาร์มเพาะเลี้ยงครั้งแรก ให้สามารถลดความผิดพลาดของการตรวจจับไฟไหม้ และสภาพอากาศร้อนจัดได้

1.3 ขอบเขตของวิทยานิพนธ์

1. ระบบสามารถตรวจจับไฟไหม้ระยะก่อนลุกลามและแจ้งเตือนไปยังผู้ใช้งานผ่านไลน์ แอปพลิเคชันได้
2. ระบบสามารถลดความแปรปรวนจากการอ่านค่าเซ็นเซอร์โดยใช้ตัวกรอง คาลมาน (Kalman Filter)
3. ระบบสามารถตรวจจับสภาวะผิดปกติ ของค่าอุณหภูมิ ความชื้น และ คาร์บอนไดออกไซด์ โดยใช้เซ็นเซอร์ PM2.5 เมื่อฟาร์มครั้งมีสภาพอากาศร้อนจัด และไฟไหม้ โดยใช้วิธีการ ระยะทางมหาลาโนบิส (Mahalanobis Distance)
4. ระบบสามารถแนะนำเส้นทาง ระยะทาง ระยะเวลาจากตำแหน่งปัจจุบันไปยังตำแหน่งฟาร์มโดยใช้ กูเกิ้ลแมพ อินเตอร์เฟซ (Google Maps Interface)
5. ระบบถูกประเมินความถูกต้องของการตรวจจับไฟไหม้และสภาพอากาศร้อนจัดโดยใช้ข้อมูล อุณหภูมิ ความชื้น และ คาร์บอนไดออกไซด์เซ็นเซอร์ PM2.5 จากการเก็บข้อมูลเซ็นเซอร์ทุกๆ 30 วินาที

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1. ระบบสามารถตรวจจับไฟไหม้ก่อนระยะลุกลาม และตรวจจับสภาพอากาศร้อนจัดในฟาร์มเพาะเลี้ยงครั้งได้อย่างถูกต้อง จึงสามารถแจ้งเตือนไปยังผู้ใช้งานในสภาวะวิกฤตไปยังผู้ใช้งานได้อย่างเหมาะสม
2. โมดูลเซ็นเซอร์อัจฉริยะสามารถส่งค่า อุณหภูมิ ความชื้น และ คาร์บอนไดออกไซด์ไปยังคลาวด์เซิร์ฟเวอร์แบบอัตโนมัติ จึงสามารถเรียกดูข้อมูลและประมวลผลข้อมูลได้อย่างต่อเนื่อง
3. ระบบตรวจจับไฟไหม้สามารถลดความสูญเสียผลผลิตครั้งเมื่อเกิดสภาวะวิกฤตภายในฟาร์มได้อย่างทันท่วงที

บทที่ 2

งานวิจัยที่เกี่ยวข้อง

2.1 ความรู้เบื้องต้นเกี่ยวกับครั่ง

2.1.1 ครั่ง

ครั่งคือสารที่ออกจากตัวแมลงครั่งผ่านกระบวนการขับถ่าย เจริญอาศัยด้วยการดูดกินน้ำเลี้ยงจากกิ่งไม้ที่มีต้นแม่ครั่ง เมื่อกินแล้วมันจะเริ่มขับถ่ายยางครั่งที่จะห่อหุ้มตัวเป็นเกราะเพื่อป้องกันตัวจากอันตรายภายนอก ยางครั่งมีลักษณะเหนียวและมีสีเหลือง หากถูกอากาศนานเพียงพอ เมื่อแข็งตัวจะเปลี่ยนเป็นสีน้ำตาลแดง ครั่งดิบเป็นครั่งที่ถูกเก็บไว้หลังจากกระเทาะจากกิ่งไม้ มีเรซิน เชื้อรา ขี้ผึ้ง และส่วนประกอบอื่นๆ ที่สำคัญ ครั่งนี้ใช้เพื่อการป้องกันตัวของครั่ง มีการนำครั่งไปใช้ประโยชน์ในอุตสาหกรรม ได้แก่ สีครั่ง (lac dye) และครั่งเม็ด (seed lac) ซึ่งได้จากกระบวนการล้างครั่งดิบ (stick lac) (เด่นรุ่งเรือง, 2014)



ภาพ 1 ครั่งและการแปรรูปแบบ เพื่อใช้ประโยชน์จากครั่ง ที่มา (Bashir และคณะ, 2022)

2.1.2 ประวัติความเป็นมาของครั่ง


ครั่งเป็นสารที่มีประวัติความเป็นมาในอินเดียและจีนมาหลายพันปี ในอดีตได้ให้ความสำคัญกับครั่งในการใช้เป็นสมุนไพรในการรักษาโรค เช่น โรคโลหิตจาง นอกจากนี้ยังนิยมใช้ครั่งในการย้อมผ้าไหมและหนังสือสัตว์ และในปัจจุบันยังใช้ในการทำสีอาหาร เช่น ในการผลิตขนมชั้น การใช้ยางครั่งมีหลักฐานที่ปรากฏในคริสต์ศตวรรษที่ 16 โดยมีการพัฒนาวิธีทำยางครั่งให้บริสุทธิ์มากขึ้น และนำมาใช้ในการตกแต่งเครื่องใช้ เครื่องเรือนเพื่อสร้างความสวยงาม

ในคริสต์ศตวรรษที่ 19 มีการซื้อขายสินค้าครั้งอย่างจริงจัง เนื่องจากความต้องการในการค้าสีของครั้ง ในปี พ.ศ. 2394 ได้มีโรงงานอุตสาหกรรมที่เกี่ยวข้องกับครั้งเกิดขึ้นเป็นโรงงานแรกในอินเดีย เพื่อสกัดสีจากครั้งเพื่อนำมาขายในยุโรปและอเมริกา ต่อมาได้มีการสร้างสีสังเคราะห์เพื่อให้ตลาดสีครั้งเจริญเติบโต รวมทั้งมีการพัฒนาสารสังเคราะห์เพื่อทดแทนยางครั้ง แต่สารสังเคราะห์ไม่สามารถทดแทนครั้งได้ทุกชนิด ทำให้ครั้งยังคงเป็นสินค้าที่มีบทบาทสำคัญในเศรษฐกิจของประเทศ เป็นที่รู้จักดีในทุก ๆ ยุค ครั้งมีบทบาทที่สำคัญในการสร้างความสวยงามและใช้ประโยชน์ในหลาย ๆ ด้านของชีวิตประจำวัน ไม่ว่าจะเป็นการใช้เป็นสมุนไพรแผนศาสตร์เพื่อรักษาโรค หรือการใช้เป็นวัตถุดิบในอุตสาหกรรมทั้งย้อมผ้าไหมและหนังสือ และที่สำคัญคือในการผลิตสีอาหาร ซึ่งมีผลต่อการค้าส่งขายสินค้าครั้งในตลาดโลกอย่างต่อเนื่อง (เด่นรุ่งเรือง, 2014)

2.1.2 แมลงครั้ง

แมลงครั้ง (*Laccifer lacca* Kerr.) เป็นพวกเพลี้ยที่อยู่ในวงศ์ แลกซิเฟอริดี (*Lacciferidae*) และมักถูกเรียกว่า แทกคาร์เดีย แลกคา (*Tachardia lacca*) หรือ เคอเรีย แลกคา (*Kerria lacca*) ในภาษาท้องถิ่น มีลักษณะเป็นแมลงตัวเปี้ยพื้ที่อาศัยกินน้ำเลี้ยงจากต้นไม้และถือเป็นศัตรูของไม้ที่เลี้ยงครั้ง แมลงครั้งใช้ปากของตนเป็นวงดูดน้ำเลี้ยงจากต้นไม้เพื่อใช้ในการเลี้ยงชีวิตและระบายยาง โดยมีเกราะสีเหลืองทองที่เป็นเส้นรอบตัวเพื่อป้องกันตัวจากศัตรูต่าง ๆ ยางที่มีลักษณะเหนียวเมื่อถูกอากาศจะแข็งตัวและเรียกว่า "ครั้ง"

แมลงครั้งเป็นแมลงที่มีวงจรชีวิตแบบ Oviparous ซึ่งหมายความว่าพวกมีการวางไข่ก่อนแล้วค่อยฟักเป็นตัวอ่อน และมีการเจริญเติบโตแบบ Complete Metamorphosis ซึ่งประกอบไปด้วยไข่, ตัวอ่อน, ดักแด้, และตัวแก่ ตัวผู้และตัวเมียมีรูปร่างและการเจริญเติบโตที่แตกต่างกัน ตัวผู้มี 2 ชนิด คือ มีปีกและไม่มีปีก และไข่มีอายุประมาณ 8-20 นาที ก่อนที่จะถูกฟักเป็นตัวอ่อนหรือลูกครั้ง สัปดาห์ที่ 4, แมลงครั้งจะลอกคราบครั้งแรก และจะลอกคราบรวม 4 ครั้ง ขนาดของตัวโตจะเพิ่มขึ้น และตัวจะเจริญเติบโตสู่ระยะดักแด้ ภายในประมาณ 2 เดือน ตัวเมียจะมีลักษณะกลม และเมื่อลอกคราบครั้งต่อไปลักษณะตัวจะกลมยิ่งขึ้น พร้อมทั้งจะผสมพันธุ์ เมื่ออายุประมาณ 2 เดือน วงจรชีวิตของแมลงครั้งมีระยะเวลาประมาณ 5 เดือน และในปีหนึ่งมี 2 รุ่นที่เกิดขึ้น (เด่นรุ่งเรือง, 2014)



ภาพ 2 Bivoltine life cycle of female *Kerria lacca* (Bashir และคณะ, 2022)

วงจรชีวิตแบบ Bivoltine ของตัวเมียแมลง *Kerria lacca* (หรือลัค) มีลักษณะดังนี้: E หมายถึงไข่ L1 หมายถึงตัวอ่อนช่วงแรก L2 หมายถึงตัวอ่อนช่วงที่สอง A1 หมายถึงวัยผู้ในช่วงต้น A2 หมายถึงวัยผู้ในช่วงกลาง และ A3 หมายถึงวัยผู้ในช่วงสุดท้าย รุ่นที่เกิดในฤดูร้อนของแมลงครั้งจะแสดงลักษณะที่แตกต่างของสารลัค, ในขณะที่รุ่นที่เกิดในฤดูหนาวจะแสดงการเกาะตัวไปยังต้นพืชโดยใช้ทดสอบลัคของพวกเขา (Bashir และคณะ, 2022)

2.1.3 การส่งเสริมเศรษฐกิจผ่านกิจกรรมการเพาะเลี้ยงครั้ง

การพัฒนาเศรษฐกิจในการส่งเสริมครั้งเป็นกระบวนการที่ควรให้ความสำคัญกับการทราบถึงปัญหาและอุปสรรคที่เกิดขึ้นในขณะเพาะเลี้ยงครั้ง การทราบถึงปัญหาเหล่านี้และการวางแผนแก้ไขมีบทบาทสำคัญในการเพิ่มประสิทธิภาพและความสำเร็จของกิจกรรมทางการเกษตรและอุตสาหกรรมที่เกี่ยวข้องกับครั้ง

การเลี้ยงครั้งเป็นอาชีพที่มีความสำคัญในวงจรเศรษฐกิจของเกษตรกรที่อาศัยในชนบทของประเทศไทย โดยมีผลทำให้เกษตรกรสามารถเพิ่มรายได้และเสริมสร้างความมั่งคั่งในชนบท ปกติแล้ว เกษตรกรไทยจะใช้เวลาว่างจากการทำนาและอาชีพอื่นๆ ประมาณ 200 วันต่อปีเพื่อทำกิจกรรมเลี้ยงครั้ง. การเลี้ยงครั้งไม่เพียงเสริมแรงงานในช่วงเวลาว่างของเกษตรกรแต่ยังมีผลทำให้เกิดรายได้เพิ่มขึ้นทั้งส่วนตัวและในระดับชุมชน นอกจากนี้ การเลี้ยงครั้งยังเป็นอีกทางเลือกหนึ่งในการแก้ไขปัญหาแรงงานในชนบท

การสร้างโรงงานแปรรูปครั้งนั้นทำให้เกิดอุตสาหกรรมในประเทศ ซึ่งมีผลในการสร้างงานทำ และเสริมสร้างรายได้ในระดับท้องถิ่น การเพิ่มโรงงานแปรรูปครั้งยังส่งผลให้มีการจ้างแรงงานมากขึ้น การส่งออกของผลิตภัณฑ์ที่มีคุณภาพมากขึ้น และส่งเสริมการใช้สินค้าที่ผลิตขึ้นในประเทศ เราสามารถเห็นได้ว่าการเลี้ยงครั้งไม่เพียงแค่เสริมสร้างรายได้และเลี้ยงชุมชนท้องถิ่น, แต่ยังมีผลต่อการพัฒนาทางอุตสาหกรรมและการส่งเสริมเศรษฐกิจในประเทศ (เด่นรุ่งเรือง, 2014)

2.1.4 อุปสรรค ข้อจำกัดในกระบวนการเลี้ยงครั้ง

ปัญหาจากดินฟ้าอากาศมีต้นเหตุมาจากความร้อน ความชื้น และปริมาณน้ำฝนที่มีผลต่อการเจริญเติบโตของแมลงครั้ง โดยเฉพาะในสภาวะอากาศร้อนต่อเนื่องทำให้รังครั้งอ่อนตัว และแมลงครั้งต้องเผชิญกับปัญหาอันตรายใจที่ทำให้มีการตายของแมลงครั้งบางตัวได้ นอกจากนี้, การปล่อยครั้งแพร่พันธุ์บนต้นไม้เป็นปัจจัยที่ทำให้การเพาะเลี้ยงครั้งลดลง

เพื่อแก้ไขปัญหที่เกิดจากดินฟ้าอากาศ สามารถดำเนินการตามขั้นตอนต่อไปนี้ การตัดแต่งกิ่งไม้ หากการเลี้ยงครั้งไม่พบผลหรือครั้งตาย ควรตัดแต่งกิ่งไม้ใหม่ เลือกตัดเพื่อให้กิ่งไม้สามารถปล่อยครั้งเพาะเลี้ยงในระยะ 1-2 ปี

ผู้ที่มีแผนจะทำสวนใหม่ ควรเลือกที่ตั้งบริเวณริมห้วย, คลอง, บึง หรือตามเขา หรือที่ตั้งมีลักษณะดังกล่าวจะช่วยลดสภาวะอากาศร้อน, และสภาพอากาศที่เย็น เมื่อเกิดอากาศร้อนสูงการเลือกที่ตั้งลักษณะทางธรรมชาติช่วยลดผลกระทบจากอุณหภูมิที่สูงได้เช่นกัน

อย่างไรก็ตาม ควรคำนึงถึงการคัดเลือกต้นไม้ที่เหมาะสมกับสภาพดินและสภาพอากาศในพื้นที่ การเลือกต้นไม้ที่ทนต่อสภาพอากาศมีความสำคัญอย่างมาก เพื่อให้การปลูกต้นไม้เพาะเลี้ยงครั้ง มีผลผลิตที่ดีและมีคุณภาพที่พร้อมออกสู่ตลาด (เด่นรุ่งเรือง, 2014)

2.1.5 ต้นไม้ที่เหมาะสมแก่การเพาะเลี้ยงครั้ง

ตามชีวจักรของแมลงครั้ง จำเป็นต้องอาศัยต้นไม้เหมาะสมสำหรับการเลี้ยงครั้ง โดยเฉพาะการศึกษาวีถีตัดกิ่ง และการแตกตาของต้นไม้ใหม่มีความสำคัญ (เด่นรุ่งเรือง, 2014)

ลำดับ	ชื่อทางราชการ	ชื่อพื้นเมือง	ชื่อพฤกษศาสตร์
เลียงคั้ง ได้ผลดี			
๑.	ก้ามปู	ฉำฉา ก้ามกราม ลำสา สะแซ	<i>Samanea saman</i> Merr.
๒.	พุทรา	มะดัน มั่งถั่ง	<i>Zizyphus mauritiana</i> Lamk.
๓.	บันแก	สะแซ พญารากขาว กระบุง	<i>Albizia lucida</i> Benth.
๔.	สะแก	ซอนแซ่ ซังแก ของแค	<i>Combretum quadrangulare</i> Kurz
๕.	มะแฮะนก	ขม้นาง ขม้นลิง ขม้นพระ	<i>Moghania macrophylla</i> Ktze
๖.	ลีเลียดออสเตรเลีย	–	<i>Acacia decurrens</i> Willd
เลียงคั้ง ได้ดีปาน กลาง			
๑.	มะเดื่ออุทุมพร	เดื่อเกลี้ยง เดื่อน้ำ	<i>Ficus racemosa</i> Linn.
เลียงคั้ง ได้พอใช้			
๑.	รัง	ลักบัว รัง เรียง	<i>Shorea siamensis</i> Miq.
๒.	พะยอม	ชะยอม ยาง หยวก	<i>Shorea talura</i> Roxb.
๓.	กระถินณรงค์	–	<i>Acacia auriculaeformis</i> Cunn.
๔.	ถั่วแระ	มะแฮะ ถั่วแม่ตาย ถั่วแรด	<i>Cajanus cajan</i> Millsp.

ภาพ 3 ตารางแสดงต้นไม้ ที่เหมาะแก่การเพาะเลียงคั้ง (เด่นรุ่งเรือง, 2014)

2.1.5 ช่วงฤดูกาล เพาะเลียงคั้ง

การปล่อยคั้งเพาะเลียงเป็นกระบวนการที่มีความสำคัญในการขยายพันธุ์พืช โดยมีขั้นตอนการปล่อยที่แตกต่างกันในฤดูฝนและฤดูร้อนระหว่างฤดูฝน (เดือนพฤษภาคม – มิถุนายน) คั้งพันธุ์ถูกปล่อยในพื้นที่เพาะเลียงที่กำหนดไว้ การตัดแต่งกิ่งต้นไม้อเลียงคั้งนี้มีประโยชน์ในการกระตุ้นการเจริญเติบโต. คั้งจะถูกตัดและเก็บรวบรวมในเดือนพฤศจิกายน – ธันวาคม เพื่อเตรียมพร้อมในการเพาะเลียงต่อไป ระหว่างฤดูร้อน (เดือนพฤศจิกายน – ธันวาคม) คั้งพันธุ์ถูกปล่อยในพื้นที่เพาะเลียง การตัดแต่งกิ่งต้นไม้อเลียงคั้งนี้มีประโยชน์ในการกระตุ้นการเจริญเติบโต. คั้งจะถูกตัดและเก็บรวบรวมในเดือนพฤศจิกายน – ธันวาคม เพื่อเตรียมพร้อมในการเพาะเลียงต่อไปหรือปล่อยให้พืชขยายพันธุ์เองในรอบฤดูฝน การตัดแต่งคั้งลงในเดือนพฤศจิกายน – ธันวาคม ในปีต่อไป เป็นการเตรียมการปล่อยคั้งเพาะเลียงในรอบถัดไป (เด่นรุ่งเรือง, 2014)

2.1.5 คุณสมบัติของครั่ง

ครั่งเป็นสารพลาสดิกชนิดหนึ่งที่มีคุณสมบัติพิเศษเมื่อเปรียบเทียบกับอุณหภูมิของสิ่งแวดล้อม. ณ อุณหภูมิปกติ, ครั่งมีลักษณะเป็นของแข็งและมีความทนทาน อย่างไรก็ตาม, เมื่อถึงอุณหภูมิประมาณ 50 องศาเซลเซียส, ครั่งจะเริ่มแสดงความอ่อนตัว การเปลี่ยนสถานะจากของแข็งเป็นเหลวจะเกิดขึ้นเมื่ออุณหภูมิสูงขึ้นไปยังประมาณ 80 องศาเซลเซียส คุณสมบัติที่ต่างกันของครั่งที่เป็นของแข็งและเป็นเหลวทำให้มันเหมาะสมในการทำงานที่ต้องการความยืดหยุ่น เมื่อครั่งเป็นของแข็ง มันสามารถให้ความคงทนและแข็งแรงได้ แต่เมื่อถูกทำให้เป็นเหลว มันจะมีความเปราะและเคลื่อนไหวได้ง่าย (เด่นรุ่งเรือง, 2014)



ภาพ 4 Stic lac ที่มา <https://naturaldyes.ca/lac>

2.2 งานวิจัยที่เกี่ยวข้อง

2.2.1 การศึกษางานวิจัยที่เกี่ยวข้องกับระบบตรวจจับการเกิดไฟไหม้


ตาราง 1 งานวิจัยที่เกี่ยวข้องกับระบบตรวจจับการเกิดไฟไหม้


ลำดับ	ชื่องานวิจัย	ชนิด	ข้อดี	ข้อจำกัด	วิธีการ
1	Long-Range Raman Distributed Fiber Temperature Sensor With Early Warning Model for Fire Detection and Prevention (2019)	Conference	ผสมผสานเซ็นเซอร์อุณหภูมิแบบกระจายระยะไกล Raman Distributed Fiber Temperature Sensor (RDFTS)	งานวิจัยมุ่งเน้นไปที่สภาพแวดล้อมภายในอาคารและควบคุม จำเป็นต้องมีการทดสอบเพิ่มเติมในสถานการณ์จริงที่หลากหลายและท้าทายมากขึ้นเพื่อการใช้งานที่กว้างขึ้น	Long-Range Raman Distributed
2	Global analysis of burned areas for climate assessment: experiences from the Fire_CCI project (2019)	Conference	โครงการ Fire_CCI ได้สร้างชุดข้อมูลทั่วโลกเกี่ยวกับพื้นที่เผาไหม้ (BA) ซึ่งสามารถให้ข้อมูลและความเข้าใจเกี่ยวกับกิจกรรมไฟป่าทั่วโลกได้.	การประมวลผลที่มาก: การใช้ Sentinel-2 ที่มี ความละเอียดสูง (20 เมตร) มีประสิทธิภาพในการวิเคราะห์กิจกรรมไฟป่าอย่างละเอียด แต่ก็ต้องการการประมวลผลที่มากมาย เป็นทำให้ต้องใช้ทรัพยากรคอมพิวเตอร์มากขึ้น.	Time series analysis, Image classification
3	LPWAN Based IoT Surveillance System for Outdoor Fire Detection (2020)	journal	โปรโตไทป์นี้เน้นการให้ข้อมูลที่แม่นยำในการวัดอุณหภูมิและแก๊สในขณะที่เกิดไฟ, ช่วยในการตรวจจับไฟได้อย่างมีประสิทธิภาพ.	การนำไปใช้ในสถานการณ์ที่มีเงื่อนไขทางธรรมชาติที่ซับซ้อน เช่น สภาพอากาศที่ทับซ้อนหรือป่าที่มีความหนาแน่นสูง, อาจจำเป็นต้องปรับปรุงเพื่อให้ทำงานได้อย่างมีประสิทธิภาพ.	LPWAN Based IoT
4	Intelligent Multi-Sensor Detection System for Monitoring Indoor Building Fires (2021)	journal	ตรวจจับไฟไหม้ได้อย่างแม่นยำและรวดเร็ว ลดอัตราการแจ้งเตือนเท็จ สามารถใช้งานได้ในพื้นที่อาคารทุกประเภท	ยังอยู่ในช่วงพัฒนา อาจมีราคาแพงกว่าระบบตรวจจับไฟไหม้แบบดั้งเดิม	Multi-Sensor

ลำดับ	ชื่องานวิจัย	ชนิด	ข้อดี	ข้อจำกัด	วิธีการ
5	An Automatic System for Detection of Fires in Outdoor Areas (2022)	Conference	อัลกอริทึม Otsu ระบุพิกเซลเปลวไฟโดยไม่ต้องตั้งค่า ความแม่นยำสูง: ทดสอบกับวิดีโอที่ได้อัลบั้มแม่นยำเกิน 99%	ควรทดสอบกับวิดีโอหลากหลายสถานการณ์เพื่อยืนยันความแม่นยำ ประเมินประสิทธิภาพระบบในสภาพแวดล้อมจริงที่มีแสงแดด เงา ลม ฝุ่น คำนวณ	คอมพิวเตอร์วิทัศน์
6	Instant Fire Detection and Toxic Fumes Monitoring in Forests with a Remote Integrated Rover (2022)	Conference	ระบบสามารถตรวจจับไฟป่าได้รวดเร็ว 1% มากกว่าระบบเดิม.การใช้เซ็นเซอร์หลายแบบช่วยลดสัญญาณเตือนภัยปลอม.	ยังไม่มีทดสอบในสภาพแวดล้อมที่หลากหลายมากขึ้น. ขีดความสามารถในการตรวจจับสิ่งกีดขวางอาจจำกัด.	Remote Integrated Rover
7	Accurate Detection of IoT Sensor Behaviors in Legitimate, Faulty and Compromised Scenarios (2023)	Journal	ใช้ทฤษฎีความสัมพันธ์เชิงพื้นที่ซึ่งเหมาะสมกับข้อมูลที่มีลักษณะทางภูมิศาสตร์ใช้เทคโนโลยี edge computing สำหรับการตรวจจับแบบเรียลไทม์	การทดสอบใช้ข้อมูลจำลองจากฐานข้อมูลจริง ยังไม่ได้ทดสอบกับเครือข่ายภาคสนาม IoT จริง	ทฤษฎีความสัมพันธ์เชิงพื้นที่ (Spatial Correlation Theory) อัลกอริทึมการเรียนรู้ต่างๆ เช่น Classification and Regression Trees (CART), Random Forest (RF)
8	Intelligent Air Pollution Sensors Calibration for Extreme Events and Drifts Monitoring	Journal	สามารถประมาณความเข้มข้นของ PM2.5 ได้อย่างแม่นยำ วิธีการนี้สามารถตรวจจับความเบี่ยงของตัวเปรียบเทียบได้	วิธีการนี้ค่อนข้างซับซ้อนและอาจเข้าใจยากสำหรับผู้ใช้งานทั่วไป วิธีการนี้ต้องการข้อมูลจำนวนมากสำหรับการสร้างตัวเปรียบเทียบ	MAE RMSE R2 (Coefficient of Determination)
9	The Analysis of Tourist Satisfaction Integrating the Artistic Intelligence Convolutional Neural Network and Internet of Things Technology	Journal	โมเดล DAI-YOLO มีความแม่นยำ ค่าเรียกคืน และความแม่นยำเฉลี่ย สูงกว่าโมเดลอื่น และทำงานได้รวดเร็ว เหมาะกับการใช้งานจริง	งานวิจัยไม่ได้ลงรายละเอียดเกี่ยวกับการประยุกต์ใช้โมเดล DAI-YOLO ในสถานที่ท่องเที่ยวจริง และไม่มีทดสอบโมเดล DAI-YOLO กับสถานการณ์เพลิงไหม้ที่หลากหลาย	Neural Network โมเดล DAI-YOLO

ลำดับ	ชื่องานวิจัย	ชนิด	ข้อดี	ข้อจำกัด	วิธีการ
10	A Study on the Fire Detection and Smoke Removal in Underground Utility Tunnel Using CFD (2023)	Journal	การหาตำแหน่งที่เหมาะสมของเซ็นเซอร์	ข้อจำกัดของการนำผลวิจัยไปใช้ในสถานที่อื่นอาจต้องพิจารณาข้อบกพร่องแบบที่เปลี่ยนแปลงตามเงื่อนไขและสภาพแวดล้อมที่แตกต่าง	CFD (Computational Fluid Dynamics)
11	Review Study on Recent Developments in Fire Sensing Methods	Journal	งานวิจัยวิเคราะห์จุดเด่นและจุดด้อยของเซ็นเซอร์แต่ละประเภท ช่วยให้ผู้อ่านเข้าใจข้อดีและข้อจำกัดของเทคโนโลยีแต่ละประเภท	งานวิจัยไม่ได้ลงรายละเอียดเกี่ยวกับวิธีการวิเคราะห์ข้อมูลที่เซ็นเซอร์ตรวจจับได้, งานวิจัยไม่ได้นำเสนอตัวอย่างการประยุกต์ใช้เทคโนโลยีเหล่านี้ในสถานการณ์จริง	Machine Learning, Information Technology, Sensors, and Signal Processing Technology, Artificial Intelligence Processing Technology.
12	Uncertainty Assessment-Based Active Learning for Reliable Fire Detection Systems	Journal	โมเดล BNN ประเมินความไม่แน่นอนของตัวเอง ช่วยลดโอกาสในการแจ้งเตือนเท็จ	ระบบนี้มีความซับซ้อนมากกว่าระบบตรวจจับเพลิงแบบเดิม	งานวิจัยนี้ใช้โมเดล DL 3 ประเภท: FNN, FCN และ LSTM, งานวิจัยนี้ใช้วิธีการวัดคะแนน F1
13	SGF-MD: Behavior Rule Specification-Based Distributed Misbehavior Detection of Embedded IoT Devices in a Closed-Loop Smart Greenhouse Farming System	Journal	ตรวจจับพฤติกรรมผิดปกติได้อย่างแม่นยำและรวดเร็ว	ความแม่นยำในการตรวจจับพฤติกรรมผิดปกติมีความอ่อนไหวและแปรปรวน	KALMAN FILTER ALGORITHM , OUTLIER CLASSIFICATION OF TARGET PHENOME and Euclidean distance
14	Distributed Stochastic Gradient Tracking Algorithm With Variance Reduction for Non-Convex Optimization	Journal	ปัญหาการหาค่าต่ำสุดของฟังก์ชันไม่เว้าในระบบการประมวลผลแบบกระจาย โดยแต่ละโหนดมีข้อมูลเฉพาะของตัวเอง	ผลสแกนเทคนิค Gradient Tracking กับ Variance Reduction โดยใช้การแจกแจงแบบ Bernoulli เพื่อเพิ่มประสิทธิภาพการลู่เข้า	Gradient Tracking, Variance Reduction, SVRG, Bernoulli Distribution, $O(1/k)$ Convergence
15	Fault Diagnosis of Rotating Machinery Based on Deep Reinforcement Learning and Reciprocal of Smoothness Index	Journal	การวิเคราะห์สัญญาณสั่นสะเทือนของเครื่องจักรหมุนที่มีเสียงรบกวนและ outliers เยอะในสภาพแวดล้อมจริง	ใช้ Deep Reinforcement Learning ควบคุม bandpass filter เพื่อเลือกแถบความถี่ที่เหมาะสมที่สุดในการวิเคราะห์สัญญาณ	Deep Learning, Reciprocal of Smoothness Index, Bandpass Filter, Envelope Analysis

ลำดับ	ชื่องานวิจัย	ชนิด	ข้อดี	ข้อจำกัด	วิธีการ
16	Anomaly Detection of Non Punch Through Insulated Gate Bipolar Transistors (IGBT) by Robust Covariance Estimation Techniques	Conference	ตรวจจับความผิดปกติใน IGBT ซึ่งเป็นอุปกรณ์สำคัญในระบบไฟฟ้ากำลัง เช่น รถไฟฟ้า พลังงานลม และ UPS โดยใช้ข้อมูลแรงดันและกระแส	ประยุกต์ใช้ Mahalanobis Distance กับเทคนิค robust covariance เพื่อเพิ่มความแม่นยำในการตรวจจับความผิดปกติ แม้มี outliers	Mahalanobis Distance, Minimum Volume Ellipsoid (MVE), Minimum Covariance Determinant (MCD), Nearest Neighbor Variance Estimator (NNVE), Robust Covariance






ภาพ 6 . Flow chart of temperature early warning model. (Li และคณะ, 2019)

อย่างไรก็ตาม งานวิจัยยังมีข้อจำกัดที่ควรพิจารณา การมุ่งเน้นที่สภาพแวดล้อมภายในอาคารและควบคุม ทำให้จำเป็นต้องมีการทดสอบเพิ่มเติมในสถานการณ์จริงที่หลากหลายและท้าทายมากขึ้น เพื่อให้การใช้งานมีความเป็นจริงมากขึ้น นอกจากนี้ ความปลอดภัยของใยแก้วนำแสงอาจมีความซับซ้อนและมีผลกระทบต่อประสิทธิภาพของระบบ การใช้งานในสถานการณ์ที่แตกต่างกันอาจต้องการการวิจัยเพิ่มเติมเกี่ยวกับวัสดุเคลือบทางเลือก โมเดล Moving Average อาจไม่เหมาะสมสำหรับสถานการณ์ไฟไหม้ที่มีการเปลี่ยนแปลงอุณหภูมิที่ซับซ้อนและรวดเร็ว การพัฒนาโมเดลที่ทันสมัยยิ่งขึ้นอาจเป็นทางเลือกที่ดีเพื่อเพิ่มประสิทธิภาพของระบบ งานวิจัยนี้เสนอแนวทางที่มีศักยภาพสูงในการพัฒนาระบบตรวจจับและป้องกันไฟไหม้ที่ล้ำสมัยและมีประสิทธิภาพ แต่จำเป็นต้องพิจารณาและแก้ไขข้อจำกัดที่กล่าวถึงเพื่อให้เหมาะสมในการใช้งานทั้งในทางด้านความปลอดภัยและประสิทธิภาพในสถานการณ์จริง

2. Global analysis of burned areas for climate assessment: experiences from the Fire CCI project (Chuvieco, 2019)

การเผาไหม้ชีวมวล (รวมถึงไฟฟ้า ไฟหญ้า ไฟพรุ และไฟไหม้ทางการเกษตร) มีผลกระทบสำคัญต่อระบบนิเวศบนบกและบรรยากาศทั่วโลก มีผลต่อสภาพหน้าดิน การสะท้อนแสงของพื้นผิว และความเข้มข้นของก๊าซเรือนกระจกและละอองลอยในบรรยากาศ



ภาพ 7 Global Burned area from the FireCCI50 product 2016 (Chuvieco, 2019)

งานวิจัยนี้เน้นการประเมินพื้นที่เผาไหม้ทั้งหมดเพื่อลดความไม่แน่นอนในการวิเคราะห์ โดยให้ความสำคัญกับไฟขนาดเล็กและความรุนแรงต่ำ โครงการ Fire_CCI ของ European Space Agency's Climate Change Initiative ได้พัฒนาชุดข้อมูลพื้นที่เผาไหม้ตลอดเวลา เพื่อประเมินขอบเขตของการเผาไหม้ชีวมวล รวมถึงลักษณะทางพื้นที่และเวลา มีพื้นที่เผาไหม้ทั่วโลกสองแบบ ใช้เซ็นเซอร์ MERIS และ MODIS ที่มีความละเอียดสูงสุด (300 และ 250 เมตร ตามลำดับ) ครอบคลุมช่วงเวลาทั้งหมดของเซ็นเซอร์ทั้งสอง ผลิตภัณฑ์ระดับโลกเหล่านี้รองรับด้วยฐานข้อมูลไฟขนาดเล็กสำหรับแอฟริกาใต้สะฮารา ที่ได้จาก Sentinel 2 ที่มีความละเอียด 20 เมตร ในปี 2016 การตรวจสอบความถูกต้องของผลิตภัณฑ์ระดับโลกใช้การดีไซน์การสุ่มตัวอย่างเชิงสถิติของเฟรม Landsat โดยครอบคลุมความแปรผันตามเวลาและพื้นที่

โครงการ Fire_CCI ได้ผลิตชุดข้อมูลของผลิตภัณฑ์พื้นที่เผาไหม้ (BA) ระดับโลก จากเซ็นเซอร์ MERIS และ MODIS ที่มีความละเอียดเชิงพื้นที่สูงสุดในขณะนี้ ความแม่นยำของผลิตภัณฑ์ที่ใช้ MERIS ต่ำกว่าของ MODIS ผลิตภัณฑ์ที่ใช้ Sentinel-2 ที่มีความละเอียดเชิงพื้นที่สูง (20 เมตร) ช่วยให้การวิเคราะห์กิจกรรมเพลิงไหม้เป็นไปอย่างละเอียดและแม่นยำ แต่มีความต้องการในการประมวลผลมากขึ้นและลดการครอบคลุมทางเวลา

3. LPWAN Based IoT Surveillance System for Outdoor Fire Detection (Roque และ Padilla, 2020)

การควบคุมและตรวจสอบไฟไหม้กลางแจ้งเป็นเรื่องที่มีความสำคัญในการป้องกันความสูญเสียทั้งในเรื่องของชีวิตและทรัพย์สิน สถานะดังกล่าวมักเกิดขึ้นเนื่องจากขาดการตรวจจับไฟไหม้ในระยะเริ่มต้น ด้วยการใช้เทคโนโลยี Internet of Things (IoT) ร่วมกับ Low Power Wide Area Network (LPWAN) ผู้วิจัยได้พัฒนาระบบเฝ้าระวังที่รวดเร็วและมีความแม่นยำในการตรวจจับไฟไหม้ในสภาพแวดล้อมกลางแจ้ง




ภาพ 8 Wireless technologies comparison (Roque และ Padilla, 2020)

จากภาพ 18 แสดงกราฟเปรียบเทียบการใช้พลังงานของเทคโนโลยีไร้สายต่างๆ ชัดเจนว่าเทคโนโลยี LPWAN ใช้พลังงานน้อยที่สุดเมื่อเทียบกับเทคโนโลยีไร้สายอื่น ๆ นั้น ทำให้เป็นตัวเลือกที่ดีสำหรับการใช้งาน IoT โดยที่การใช้พลังงานมีความสำคัญ

โปรโตไทป์นี้ผสมผสานความยืดหยุ่นของไร้สาย, บอร์ดพัฒนา, และอุปกรณ์อิเล็กทรอนิกส์เข้าด้วยกัน การจัดการข้อมูลอัปเดตผ่านรูปแบบฐานข้อมูลช่วยให้สามารถปรับตั้งค่าสัญญาณเตือนได้อย่างมีประสิทธิภาพ ข้อมูลที่รวบรวมมาจากเซ็นเซอร์นำเข้าเข้าสู่ระบบ โครงสร้างนี้ได้ผลลัพธ์ที่น่าพอใจ โดยมีข้อดีที่ตรงกับความต้องการในการตรวจจับไฟไหม้ในที่กลางแจ้ง ประโยชน์ของโปรโตไทป์ การใช้เทคโนโลยีและอุปกรณ์ราคาถูกช่วยลดต้นทุนทำโปรโตไทป์ และสามารถปรับขนาดได้ตามความต้องการของสถานการณ์และสภาพแวดล้อมต่างๆ วัตถุประสงค์และก๊าซได้จริง การให้ข้อมูลที่แม่นยำในการวัดอุณหภูมิและ

ก๊าซช่วยในการตรวจจับไฟไหม้ได้อย่างมีประสิทธิภาพ ใช้พลังงานแสงอาทิตย์ นำเข้าอุปกรณ์ไฟฟ้าจากแสงอาทิตย์ทำให้ระบบเป็นไปได้อย่างมีประสิทธิภาพ ประสิทธิภาพดีกว่าระบบตรวจสอบผ่านดาวเทียม การทดสอบแสดงให้เห็นถึงประสิทธิภาพที่ดีกว่าของระบบในการตรวจจับและแจ้งเตือนที่รวดเร็วก่อนที่ไฟไหม้จะลุกลาม



ภาพ 9 Digital response timing according to different conditions (Roque และ Padilla, 2020)

จากภาพ 19 แสดงไดอะแกรมเวลาการตอบสนองแบบดิจิทัลตามเงื่อนไขต่างๆ แกนแนวนอนแสดงเวลา (วินาที) แกนแนวตั้งแสดงเงื่อนไขและการตอบสนอง


บทความวิจัยนี้เสนอโซลูชันที่สามารถนำไปใช้ในการตรวจจับไฟไหม้ในสภาพแวดล้อมกลางแจ้ง โดยมีความคุ้มค่าทั้งทางเศรษฐศาสตร์และประสิทธิภาพดีกว่าทางเลือกอื่นๆ ที่มีอยู่ในตลาด แม้ว่าจะมีบางข้อจำกัดทางเทคนิคที่ไม่ได้ถูกกล่าวถึง แต่งานวิจัยยังแนะนำการเปรียบเทียบและการพิจารณาประเด็นที่เพิ่มเติมเพื่อข้อสรุปที่มีความสมบูรณ์มากยิ่งขึ้น

4. Intelligent Multi-Sensor Detection System for Monitoring Indoor Building (Baek และคณะ, 2021)

ในศตวรรษที่ 21 ที่เรามีการใช้เทคโนโลยีในทุกๆ มิติของชีวิตประจำวัน, การพัฒนาระบบตรวจจับไฟไหม้กลายเป็นหนึ่งในหัวข้อที่น่าสนใจ. หนึ่งในงานวิจัยที่น่าสนใจที่ได้รับความ


สนใจคือ "Intelligent Multi-Sensor Detection System for Monitoring Indoor Building Fires" ซึ่งนำเสนอแนวทางใหม่ในการตรวจจับไฟไหม้โดยรวมเทคโนโลยีทั้งในเฟสการรับรู้และเฟสการตรวจจับ

จุดแข็งที่ทำให้งานวิจัยนี้น่าสนใจคือการใช้แนวทางแบบหลายเซ็นเซอร์ โดยการนำข้อมูลจากเซ็นเซอร์ที่หลากหลาย เช่น อุณหภูมิและส่วนผสมของก๊าซ ระบบสามารถครอบคลุมพื้นที่มากขึ้นและเพิ่มประสิทธิภาพในการตรวจจับไฟไหม้ แนวทางนี้ถือเป็นกระบวนการที่สามารถให้ข้อมูลที่ครอบคลุมและแม่นยำ ทำให้การตรวจจับไฟไหม้มีความสามารถมากยิ่งขึ้น



ภาพ 10 Recorded sensor signals from the proposed fire sensing system(Baek และคณะ, 2021)

อีกจุดที่น่าสนใจคือการนำเสนออัลกอริทึมการจับคู่ความคล้ายคลึงกัน. อัลกอริทึมนี้ถูกออกแบบมาเพื่อจับรูปแบบเวลาในสัญญาณเซ็นเซอร์, ซึ่งช่วยในการตรวจจับไฟไหม้ในระยะเริ่มต้นโดยลดอัตราการแจ้งเตือนเท็จ การนำเสนออัลกอริทึมที่สามารถทำงานกับข้อมูลเวลาที่มีความสำคัญมาก, เนื่องจากไฟไหม้มักมีการเปลี่ยนแปลงที่รวดเร็วในสัญญาณต่างๆ ที่เซ็นเซอร์ตรวจจับ



ภาพ 11 An overview of the proposed real-time fire detection system(Baek และคณะ, 2021)

จากภาพ 21 อัลกอริทึมการตรวจจับไฟไหม้ ใช้เทคนิค NN-WDTW (Nearest Neighbor Weighted Dynamic Time Warping) ในการวิเคราะห์ข้อมูลสัญญาณจากเซ็นเซอร์ระบบนี้ ประกอบด้วยเซ็นเซอร์หลากหลายชนิดที่ตรวจจับสัญญาณจากไฟไหม้ เช่น อุณหภูมิ, ความชื้น, และก๊าซ. อัลกอริทึมการตรวจจับใช้เทคนิคการวิเคราะห์ข้อมูลเพื่อตรวจสอบรูปแบบที่แสดงถึงการเกิดไฟไหม้ เมื่อตรวจพบความเสี่ยงหรือไฟไหม้ ระบบแจ้งเตือนผ่านทางอุปกรณ์แสดงผลหรือเสียง และทำการแจ้งเตือนถึงผู้ใช้หรือหน่วยงานที่เกี่ยวข้อง ด้วยวิธีการทำงานที่รวดเร็วและการใช้เทคโนโลยีทันสมัย ระบบนี้มีศักยภาพในการป้องกันและตรวจจับไฟไหม้อย่างมีประสิทธิภาพในอาคารภายใน

การตรวจสอบความถูกต้องด้วยข้อมูลจริงจากโลกแห่งความเป็นจริงเป็นอีกดัชนีหนึ่งที่ทำให้งานวิจัยนี้มีความน่าสนใจ การทดสอบกับข้อมูลจริงจากเซ็นเซอร์และการจำลองสถานการณ์จริงช่วยยืนยันประสิทธิภาพของระบบในสภาวะการใช้งานจริง

อย่างไรก็ตาม งานวิจัยนี้ก็มีจุดอ่อนบางประการ. ข้อจำกัดที่สำคัญคือการขอบเขตของระบบที่ไฟกัลป์ที่อาคารภายในอาคารเท่านั้น. ถึงแม้การตรวจจับไฟไหม้ภายในอาคารมีความสำคัญ, การนำไปใช้ในสภาพแวดล้อมอื่นๆ เช่น การตรวจจับไฟไหม้กลางแจ้งหรือในพื้นที่กว้างยังต้องได้รับการพิจารณาเพิ่มเติม อีกปัญหาหนึ่งคือแนวทางแบบกล่องดำของอัลกอริทึมการจับคู่ความคล้ายคลึงกัน การที่อัลกอริทึมไม่ได้รับคำอธิบายที่ละเอียดอาจทำให้ยากต่อการตรวจสอบและพัฒนาต่อยอด การเสนอข้อมูลเพิ่มเติมเกี่ยวกับวิธีการทำงานของอัลกอริทึมนั้นอาจช่วยให้ผู้ทำงานที่สนใจสามารถเข้าใจได้มากขึ้น เมื่อพิจารณาเกี่ยวกับเมตริกที่ใช้ในการประเมินประสิทธิภาพ, งานวิจัยนี้ได้กล่าวถึงเฉพาะอัตราการแจ้งเตือนเท็จ (FAR) และ False Swear-to-Alert (FSTA) ซึ่งถือเป็นเกณฑ์สำคัญ อย่างไรก็ตาม, การพิจารณาเซ็นเซอร์ระบบอื่นๆ เช่น อัตราการตรวจจับกลุ่มไฟไหม้, อัตราการตรวจจับ, หรือความละเอียดในการตรวจจับไฟไหม้ยังเป็นสิ่งสำคัญเพื่อการประเมินประสิทธิภาพโดยครอบคลุม


เพื่อให้งานวิจัยนี้มีความสมบูรณ์มากยิ่งขึ้น การพิจารณาเพิ่มเติมเกี่ยวกับค่าใช้จ่ายและความซับซ้อนในการนำระบบไปใช้งานจริงเป็นสิ่งสำคัญ การใช้ระบบหลายเซ็นเซอร์อาจมีค่าใช้จ่ายและความซับซ้อนสูงกว่าระบบเซ็นเซอร์เดี่ยว ซึ่งต้องได้รับการพิจารณาเป็นพิเศษ อีกเรื่องที่ต้องพิจารณาคือการปรับขนาดของระบบ. การตรวจจับไฟไหม้ในอาคารขนาดใหญ่หรือตึกหลายชั้นอาจจำเป็นต้องมีการปรับปรุงในเทคโนโลยีและการออกแบบ เพื่อเสริมสร้างความเป็นไปได้และความน่าเชื่อถือของงานวิจัย การเปรียบเทียบประสิทธิภาพกับระบบตรวจจับไฟไหม้ที่มีอยู่จะเป็นขั้นตอนที่สำคัญ นอกจากนี้ การทดสอบกับสภาพแวดล้อมที่หลากหลายเพื่อให้แน่ใจว่าระบบสามารถทำงานได้ดีในทุกเงื่อนไข

งานวิจัย Intelligent Multi-Sensor Detection System for Monitoring Indoor Building Fires นั้นเป็นการนำเสนอแนวทางที่มีศักยภาพในการพัฒนาระบบตรวจจับไฟไหม้ที่มีประสิทธิภาพแม้งานวิจัยนี้จะมีบางจุดที่ยังต้องพัฒนาต่อยอด การทำความเข้าใจคุณค่าและข้อจำกัดของระบบจากการวิเคราะห์นี้จะช่วยให้นักวิจัยและผู้พัฒนาได้เข้าใจดีขึ้นเกี่ยวกับศักยภาพและทิศทางที่สามารถพัฒนาต่อยอดได้ในอนาคต

5. An Automatic System for Detection of Fires in Outdoor Areas (Hakeem, Shahadi และAbass, 2022)

การทดสอบระบบกับวิดีโอจำกัดและข้อจำกัดในสภาพแวดล้อมจริงอาจเป็นข้อบ่งชี้สำคัญที่ควรพิจารณาเพิ่มเติม. การทดสอบในสถานการณ์ที่หลากหลายมากขึ้นจะช่วยให้มั่นใจ

ในประสิทธิภาพของระบบในทางปฏิบัติ. การประเมินประสิทธิภาพในสภาพแวดล้อมจริง เช่น แสงแดด หรือปัจจัยรบกวนอื่น ๆ เป็นปัจจัยที่สำคัญที่อาจมีผลต่อประสิทธิภาพของระบบ นอกจากนี้, การประยุกต์ใช้งานจริง ๆ และการทดสอบกับระบบการแจ้งเตือนอัตโนมัติเป็นแนวทางที่ควรสำรวจเพิ่มเติมเพื่อให้มั่นใจว่าระบบสามารถทำงานได้อย่างเหมาะสมในสภาพการใช้งานจริง. การพัฒนาและปรับปรุงระบบในที่นี้อาจช่วยเพิ่มประสิทธิภาพและความสามารถของระบบในการตรวจจับไฟไหม้ในพื้นที่กลางแจ้ง




ภาพ 12 The proposed system of flame detection (Hakeem, Shahadi และ Abass, 2022)

จากภาพ 22 รูปภาพนี้บ่งบอกถึงขั้นตอนหลักในระบบตรวจจับไฟไหม้แบบอัตโนมัติที่ประกอบด้วย 5 ขั้นตอนหลักดังนี้

1. แยกเฟรม ทำการแยกวิดีโอเป็นเฟรมภาพทีละภาพ 2. แปลงข้อมูล แปลงข้อมูลสีจาก RGB เป็น HSV, YCbCr และ Grayscale 3. ตรวจจับสีเปลวไฟ วิเคราะห์ค่าสีในทั้ง 3 พื้นที่สีเพื่อระบุ

พิกเซลที่ตรงกับสีของเปลวไฟ 4. กำหนดขอบเขตเปลวไฟ ใช้เทคนิค Morphology เพื่อกำหนดขอบเขตของเปลวไฟ 5. วิเคราะห์ผลลัพธ์ เปรียบเทียบผลลัพธ์จากทั้ง 3 พื้นที่สีเพื่อยืนยันการตรวจจับเปลวไฟและแสดงผลลัพธ์บนวิดีโอ

รูปภาพนี้เป็นภาพรวมของระบบตรวจจับไฟไหม้ที่ใช้เทคนิคคอมพิวเตอร์วิทัศน์ในการวิเคราะห์สีและรูปร่างของเปลวไฟ โดยการเรียงลำดับข้อมูลเหล่านี้ให้เข้าใจได้สะดวก และเพื่อการตรวจสอบผลลัพธ์ของระบบตรวจจับไฟไหม้แบบอัตโนมัติ



ภาพ 13 Flame detection based HSV color space (Hakeem, Shahadi และ Abass, 2022)


แนวทางการประยุกต์ใช้คอมพิวเตอร์วิทัศน์ นวัตกรรมในการใช้คอมพิวเตอร์วิทัศน์เพื่อตรวจจับไฟไหม้ในพื้นที่กลางแจ้ง เมื่อเปรียบเทียบกับระบบตรวจจับควันเดิม ลดขนาดข้อมูลอย่างชาญฉลาด ใช้ Haar Lifting wavelet transform เพื่อลดขนาดข้อมูลโดยไม่สูญเสียรายละเอียด ช่วยให้ประมวลผลเร็ว ตรวจจับสีเปลวไฟอัตโนมัติ: ใช้พื้นที่สีหลายแบบ (HSV, YCbCr, Binary) และ Otsu algorithm เพื่อระบุพิกเซลความเข้มแสงของเปลวไฟอัตโนมัติ ความแม่นยำสูง ผลการทดลองแสดงความแม่นยำในการตรวจจับไฟไหม้สูงเกิน 99% ในวิดีโอที่บันทึกและเกิน 89% ในวิดีโอแบบเรียลไทม์ ความซับซ้อนต่ำ แม้ระบบมีความแม่นยำสูง แต่ยังคงเรียบง่าย ใช้ทรัพยากรคอมพิวเตอร์น้อย

ข้อจำกัดงานวิจัย การทดสอบกับวิดีโอจำกัด การทดสอบนั้นถูกจำกัดในขอบเขตของวิดีโอที่นำมาใช้ อาจทำให้ยากต่อการนำไปใช้在实际สถานการณ์ที่หลากหลายมากขึ้นในโลกจริง ประสิทธิภาพในสภาพแวดล้อมจริง การประเมินประสิทธิภาพในสภาพแวดล้อมจริงที่อาจมีปัจจัยรบกวนต่าง ๆ เช่น แสงแดด, เงา, ลม, ฝุ่น, และควันรบกวน การประยุกต์ใช้งานจริง ข้อจำกัดที่เกี่ยวข้องกับการนำระบบไปประยุกต์ใช้在实际สถานการณ์จริง โดยต้องพิจารณาปัญหาที่อาจเกิดขึ้นในการใช้งานจริง เช่น การดูแลรักษา, ปรับตั้งค่า, และปัจจัยภายนอกที่อาจกระทบต่อการทำงานของระบบ การปรับแต่งขั้นตอน ความซับซ้อนของขั้นตอนในการตรวจจับ อาจทำให้การปรับแต่งและการใช้งานกับระบบ在实际สถานการณ์แปลก ๆ ได้มีความยุ่งยาก. การครอบคลุมทุกรายละเอียด การศึกษานี้เน้นที่การตรวจจับเปลวไฟในพื้นที่กลางแจ้ง ซึ่งอาจมีความซับซ้อนและปัญหาที่แตกต่าง จากสภาพที่มีการตรวจจับเปลวไฟในที่อื่น ๆ

ทรัพยากรคอมพิวเตอร์ บางระบบตรวจจับที่มีความแม่นยำสูงอาจต้องการทรัพยากรคอมพิวเตอร์มากเพื่อให้การทำงานอยู่ในเกณฑ์ที่มีประสิทธิภาพ

6. Instant Fire Detection and Toxic Fumes Monitoring in Forests with a Remote Integrated Rover(Muthulakshmi, Manimekalai และGopikrishna, 2022)


ระบบตรวจจับไฟป่าที่นำเสนอนี้เป็นผลลัพธ์จากการผสมผสานเทคโนโลยีที่ทันสมัย เช่น เซอร์ตรวจจับที่หลากหลาย เพื่อเพิ่มประสิทธิภาพในการตรวจจับ ระบบใช้เซ็นเซอร์ตรวจจับแก๊ส, เปลวไฟ, และอินฟราเรด เพื่อลดสัญญาณเตือนภัยปลอมและเพิ่มความแม่นยำ



ภาพ 14 Block Diagram of Proposed System (Muthulakshmi, Manimekalai และGopikrishna, 2022)

จากรูป 2. เซ็นเซอร์ตรวจจับแก๊ส, เซ็นเซอร์เปลวไฟ, และเซ็นเซอร์อินฟราเรดทำหน้าที่ตรวจจับไฟป่าและควันพิษในป่าอย่างมีประสิทธิภาพ โมดูล GPS จะรับบันทึกตำแหน่งของพื้นที่ที่เกิดเหตุเพลิงไหม้ ในขณะเดียวกัน, โมดูล GSM จะส่งข้อมูลวันที่และเวลาของเหตุการณ์นั้นไปยังผู้ใช้งาน ข้อมูลทั้งหมดที่ได้รับจากเซ็นเซอร์และโมดูล GPS, GSM จะถูกส่งไปยังผู้ใช้งานผ่านอุปกรณ์สื่อสาร เช่น โทรศัพท์มือถือหรืออุปกรณ์ที่เชื่อมต่อกับระบบสื่อสาร. การนำเสนอข้อมูลในรูปแบบที่รวมทั้งตำแหน่ง, วันที่, เวลา, และประเภทของเหตุการณ์นี้ช่วยให้ผู้ใช้สามารถทราบข้อมูลที่สำคัญเกี่ยวกับเหตุการณ์ไฟป่าอย่างทันท่วงทีและมีการตอบสนองที่เร็ว

โรเวอร์ที่ใช้ในระบบสามารถควบคุมระยะไกลและสอดคล้องกับเจ้าหน้าที่ดับเพลิง โดยทำหน้าที่เป็นหน่วยสอดคล้อง. ระบบใช้เทคโนโลยี GPS และโมดูล GSM เพื่อส่งข้อมูลตำแหน่งและข้อมูลสำคัญไปยังเจ้าหน้าที่ป่าไม้โดยอัตโนมัติ. ผลการทดสอบแสดงให้เห็นว่าระบบมีประสิทธิภาพในการตรวจจับไฟป่า รวดเร็วขึ้น 1% และใช้พลังงานน้อยลง 4%




ภาพ 15 Flowchart for proposed system (Muthulakshmi, Manimekalai และGopikrishna, 2022)

งานวิจัยชี้ให้เห็นว่าเทคโนโลยี WSN เป็นทางเลือกที่น่าสนใจสำหรับการตรวจจับไฟป่าในอนาคต. อย่างไรก็ตาม, การพัฒนาและทดสอบระบบในสถานการณ์จริงที่หลากหลายเป็นสิ่งสำคัญ เพื่อเพิ่มประสิทธิภาพและความน่าเชื่อถือของระบบ. ข้อเสนอแนะรวมถึงการทดสอบในสภาพแวดล้อมที่หลากหลายมากขึ้น, พัฒนาการตรวจจับสิ่งกีดขวาง, และการศึกษาการนำเทคโนโลยีปัญญาประดิษฐ์มาประยุกต์ใช้ บทความนี้แนะนำระบบตรวจจับไฟป่าที่มีการ

ผสมผสานเทคโนโลยีและเซ็นเซอร์หลายแบบ เพื่อเพิ่มประสิทธิภาพในการตรวจจับไฟฟ้า โดยมีคุณสมบัติที่เน้นการควบคุมระยะไกลและการส่งข้อมูลอัตโนมัติ อย่างไรก็ตาม ควรมีการพัฒนาและทดสอบเพิ่มเติมในสถานการณ์จริงที่หลากหลายเพื่อให้ระบบมีประสิทธิภาพและความน่าเชื่อถือมากยิ่งขึ้น

7. Accurate Detection of IoT Sensor Behaviors in Legitimate, Faulty and Compromised Scenarios (Sood และคณะ, 2023)

งานวิจัยนี้เสนอวิธีการตรวจจับพฤติกรรมของเซ็นเซอร์ IoT ในภาคการเกษตรอัจฉริยะ โดยเซ็นเซอร์เหล่านี้อาจทำงานผิดพลาด เสื่อมสภาพ หรือถูกโจมตีทางไซเบอร์ได้ นอกจากนี้ เซ็นเซอร์มักถูกติดตั้งในสภาพแวดล้อมที่รุนแรง ส่งผลให้เซ็นเซอร์ทำงานผิดพลาดหรือส่งค่าที่ผิดปกติ สิ่งเหล่านี้ส่งผลกระทบต่อประสิทธิภาพของเครือข่ายอัจฉริยะและความสามารถในการตัดสินใจ ดังนั้น การตรวจจับพฤติกรรมของเซ็นเซอร์ IoT อย่างแม่นยำในสถานการณ์ที่ต้อง ผิดพลาด และถูกโจมตีจึงมีความสำคัญ งานวิจัยนี้ใช้วิธีการที่อาศัยทฤษฎีความสัมพันธ์เชิงพื้นที่ (Spatial Correlation Theory) โดยใช้เครื่องมือ Moran's I index ในการตรวจสอบความถูกต้อง และใช้อัลกอริทึมการเรียนรู้ต่างๆ เช่น Classification and Regression Trees (CART), Random Forest (RF) และ Support Vector Machine (SVM) ในการทดสอบวิธีการ




ภาพ 16 The proposed high level system model. (Sood และคณะ, 2023)

จากภาพ 26 เซ็นเซอร์ IoT รวบรวมข้อมูลและส่งไปยังเครือข่าย IoT โมดูลการตรวจจับค่าผิดปกติจะตรวจจับค่าผิดปกติในข้อมูลโมดูลการแก้ไขเชิงพื้นที่ใช้ความสัมพันธ์เชิงพื้นที่ระหว่างเซ็นเซอร์เพื่อยืนยันหรือปฏิเสธค่าผิดปกติ โมดูลการจำแนกประเภทจะจำแนกประเภทของพฤติกรรมเซ็นเซอร์ผลลัพธ์จะถูกส่งไปยังผู้ใช้เพื่อดำเนินการต่อไป

Feature	Interpretation	Range	Mean value	Standard Deviation
X	x-Axis spatial coordinate of sensor locations	1–9	4.6	2.31
Y	y-Axis spatial coordinate of sensor locations	1–9	4.3	1.23
Month	Month	Jan–Dec	NA	NA
Day	Day of the week	Mon–Sun	NA	NA
Temp	Temperature ($^{\circ}\text{C}$)	2.2–33.3	18.89	5.81
RH	Relative Humidity (%)	15–100	44.29	16.32
Wind	Wind speed (km/h)	0.4–9.4	4.02	1.8
Rain	Rain (mm/m^2)	0–6.4	0.02	0.3

ภาพ 17 The Forest Fire Dataset Details (Sood และคณะ, 2023)



ภาพ 18 Recognition accuracy of (a) Classification and regression trees, (b) Random forest, and (c) Support vector machine models for temperature outliers.(Sood และคณะ, 2023)

งานวิจัยนี้มุ่งเน้นการตรวจจับพฤติกรรมของเซ็นเซอร์ IoT ในภาคการเกษตรอัจฉริยะ โดยพิจารณาถึงความผิดพลาดที่อาจเกิดขึ้น การเสื่อมสภาพ และการโจมตีทางไซเบอร์ที่อาจเกิดขึ้นในสถานะที่รุนแรง การวิจัยนี้ใช้ทฤษฎีความสัมพันธ์เชิงพื้นที่และเครื่องมือ Moran's I index เพื่อตรวจสอบความถูกต้องของข้อมูล และใช้อัลกอริทึมการเรียนรู้เช่น Classification and Regression Trees (CART), Random Forest (RF), และ Support Vector Machine (SVM) เพื่อทดสอบวิธีการ

ผลลัพธ์ของงานวิจัยได้แสดงให้เห็นว่าวิธีการที่เสนอสามารถแยกแยะพฤติกรรมของเซ็นเซอร์ในสถานการณ์ต่างๆ ได้อย่างแม่นยำ อัตราการตรวจจับที่แม่นยำขึ้นขึ้นอยู่กับการกระจายและความรุนแรงของข้อมูลผิดปกติ โดยอัลกอริทึม Random Forest ให้ผลลัพธ์ที่ดีที่สุดในการตรวจจับข้อมูลผิดปกติจำนวนมาก

จุดเด่นของงานวิจัยนี้คือการใช้ทฤษฎีความสัมพันธ์เชิงพื้นที่ที่เหมาะสมสำหรับข้อมูลที่มีลักษณะทางภูมิศาสตร์ และการนำเทคโนโลยี edge computing เข้ามาใช้ในการตรวจจับแบบเรียลไทม์ เพื่อเสถียรภาพและประสิทธิภาพที่เพิ่มขึ้น อย่างไรก็ตาม งานวิจัยยังมีจุดอ่อน เช่น การทดสอบที่ใช้ข้อมูลจำลองจากฐานข้อมูลที่ไม่สามารถแทนแทนสภาพการณ์จริงได้อย่าง


แท้จริง และยังไม่ได้ทดสอบกับเครือข่ายภาคสนาม IoT จริง ในแนวทางการวิจัยในอนาคต ควรพัฒนาการทดสอบการใช้งานกับเครือข่ายภาคสนาม IoT จริง ปรับปรุงอัลกอริทึมการเรียนรู้ และพัฒนาโมเดลที่เหมาะสมสำหรับสถานการณ์ที่ซับซ้อนมากขึ้น เพื่อให้งานวิจัยมีความหลากหลายและประโยชน์ที่สูงขึ้นในการพัฒนาภาคการเกษตรอัจฉริยะ

8. Intelligent Air Pollution Sensors Calibration for Extreme Events and Drifts

Monitoring (Zaidan และคณะ, 2023)


งานวิจัยนี้เน้นการปรับเทียบเซ็นเซอร์ตรวจวัดมลพิษอากาศอัจฉริยะ (LCSSs) ในเหตุการณ์รุนแรง โดยเน้นที่ปัญหาความแม่นยำของเซ็นเซอร์ในการวัดมลพิษ เช่น คว้นไฟ ซึ่งเป็นปัญหาที่มักเจอในเหตุการณ์รุนแรง เช่น การสูบบุหรี่ วิธีการในงานวิจัยนี้เสนอการปรับเทียบเซ็นเซอร์อัจฉริยะเพื่อแก้ไขค่าที่วัดได้จากเซ็นเซอร์ทั่วไป และตรวจจับความเบี่ยงของตัวปรับเทียบด้วย โดยใช้กรอบเบย์เอเซียนสร้างตัวปรับเทียบทั้งแบบกล่องขาวและกล่องดำ

ผลการทดลองแสดงว่า วิธีการนี้สามารถประมาณความเข้มข้นของฝุ่นละออง PM2.5 ได้อย่างแม่นยำระหว่างเหตุการณ์การสูบบุหรี่ และแบบกล่องดำมีความแม่นยำมากกว่าแบบกล่องขาว แต่เบี่ยงได้ง่ายกว่าเมื่อเกิดเหตุการณ์การสูบบุหรี่ใหม่ และแบบกล่องขาวมีความทนทานกว่า นอกจากนี้ งานวิจัยยังนำเสนอการใช้ทั้งสองแบบควบคู่กันเพื่อเลือกใช้จุดแข็งของทั้งคู่ และตรวจสอบความเบี่ยงของโมเดลปรับเทียบได้ด้วย หลักสูตรนี้มีศักยภาพในการพัฒนาเซ็นเซอร์ LCSSs อื่น ๆ ที่มีปัญหาเรื่องความแม่นยำ ซึ่งเป็นแนวทางที่น่าสนใจสำหรับการปรับปรุงประสิทธิภาพการวัดมลพิษอากาศในสถานการณ์ที่รุนแรง



ภาพ 19 Intelligent air pollution sensors calibration process (Zaidan และคณะ, 2023)

งานวิจัยนี้เน้นการปรับเทียบเซ็นเซอร์ตรวจวัดมลพิษอากาศอัจฉริยะ (LCSS) เพื่อเพิ่มความแม่นยำในการวัดมลพิษอากาศในสถานการณ์รุนแรง เช่น การสูบบุหรี่ ที่มีควันไฟเป็นต้น การวิจัยนี้นำเสนอวิธีการปรับเทียบเซ็นเซอร์อัจฉริยะที่ใช้กรอบเบย์เอเซียน ทั้งแบบกล่องขาว (white-box) และแบบกล่องดำ (black-box) เพื่อประมาณค่ามลพิษ $PM_{2.5}$ ในเหตุการณ์การสูบบุหรี่ ผลการปรับเทียบแสดงว่า แบบกล่องดำมีความแม่นยำมากกว่าแบบกล่องขาว แต่กลับเบี่ยงได้ง่ายกว่าในเหตุการณ์ใหม่ นอกจากนี้ วิธีการนี้ยังตรวจจับความเบี่ยงของตัวปรับเทียบได้ บทความสรุปว่าการใช้ทั้งสองแบบควบคู่กันช่วยเพิ่มประสิทธิภาพ และมีศักยภาพในการปรับใช้ในภาคอุตสาหกรรมที่ต้องการตรวจสอบมลพิษอากาศ อย่างไรก็ตาม ผู้ใช้ควรพิจารณาความซับซ้อนและข้อจำกัดของวิธีการนี้ก่อนนำไปใช้งานจริง



ภาพ 20 Time-series data of PM_{2.5} concentration obtained in the experiment (Zaidan และคณะ, 2023)

จากภาพ 30 แสดงผลลัพธ์ของงานวิจัยที่เสนอวิธีการปรับเทียบเซ็นเซอร์ LCSs แสดงให้เห็นว่าวิธีการนี้สามารถช่วยเพิ่มความแม่นยำในการวัด PM_{2.5} ได้ และยังแสดงให้เห็นถึงข้อจำกัดของวิธีการนี้ เช่น ความเปี้ยวของตัวปรับเทียบ V

Variables	Measurements		Validation metrics			
	Mean	Range	MAE	RMSE	MAPE	R
Temp (°C)	25.22	20 - 30	0.80	0.83	3.24	0.995
RH (%)	29.25	20 - 40	0.77	0.85	2.61	0.990
P (mbar)	902.27	900 - 910	0.99	0.99	0.11	0.999

ภาพ 21 LCS METEOROLOGICAL SENSORS:CONSISTENCY (Zaidan และคณะ, 2023)


ภาพ 31 แสดงให้เห็นว่า เซ็นเซอร์ LCS มีประสิทธิภาพความสอดคล้องสูงสำหรับการวัด อุณหภูมิ ความชื้นสัมพัทธ์ และความดันอากาศ โดยค่า MAE, RMSE, MAPE ต่ำ และค่า R สูง งานวิจัยนี้มุ่งเน้นการปรับเทียบเซ็นเซอร์ตรวจวัดมลพิษอากาศอัจฉริยะ (LCSs) เพื่อเพิ่มความแม่นยำในการวัดมลพิษอากาศในสถานการณ์รุนแรง เช่น การสูบบุหรี่ และการตรวจสอบความเปี้ยวของตัวปรับเทียบ วิธีการนี้ใช้กรอบเบย์เอเซียนทั้งแบบกล่องขาวและแบบกล่องดำ เพื่อประมาณค่ามลพิษ PM_{2.5} ในเหตุการณ์การสูบบุหรี่ ผลการปรับเทียบแสดงว่า แบบกล่องดำมีความแม่นยำมากกว่า แต่กลับเปี้ยวได้ง่ายกว่าในเหตุการณ์ใหม่ การใช้ทั้งสองแบบควบคู่กัน ช่วยเพิ่มประสิทธิภาพ และมีศักยภาพในการปรับใช้ในภาคอุตสาหกรรมที่ต้องการตรวจสอบ

มลพิษอากาศ นอกจากนี้ วิธีการนี้ยังสามารถตรวจจับความเปื้อนของตัวเปรียบเทียบได้ ควรพิจารณาความซับซ้อนและข้อจำกัดของวิธีการนี้ก่อนนำไปใช้งานจริง

9. The Analysis of Tourist Satisfaction Integrating the Artistic Intelligence


Convolutional Neural Network and Internet of Things Technology (Yan, 2023)

งานวิจัยนี้มุ่งเน้นการพัฒนาโมเดล DAI-YOLO ในการตรวจจับเพลิงไหม้และการวิเคราะห์ความพึงพอใจของนักท่องเที่ยวที่มีลักษณะหลายมิติ โดยเสนอเทคนิค Depth Separable Convolution (DSC) และโครงสร้างการตรวจจับหลายระดับเพื่อปรับปรุง YOLOv3 ซึ่งผลลัพธ์แสดงว่า DAI-YOLO มีความแม่นยำสูงกว่าโมเดลอื่น ๆ ในการตรวจจับเพลิงไหม้ ในขณะเดียวกันการวิเคราะห์ความพึงพอใจของนักท่องเที่ยวใช้ grounded theory และผสมผสานการวิเคราะห์อารมณ์เพื่อครอบคลุม ข้อมูลจากสถานที่ท่องเที่ยวในจังหวัด X เป็นฐานที่ใช้ในการวิเคราะห์ แต่ความสามารถในการสรุปผลลัพธ์ไปใช้กับสถานที่อื่นยังมีข้อจำกัด นอกจากนี้ งานวิจัยยังไม่ระบุถึงการประยุกต์ใช้โมเดล DAI-YOLO ในสถานที่ท่องเที่ยวจริง และยังไม่ได้ทดสอบโมเดลต่อสถานการณ์เพลิงไหม้ที่หลากหลาย



ภาพ 22 Comparison of feature extraction structures.(Yan, 2023)

การเปรียบเทียบโมเดล YOLOv3 และ DAI-YOLO (ภาพ 32) บ่งบอกถึงประสิทธิภาพของ DAI-YOLO ที่มีการพัฒนาขึ้นจาก YOLOv3 โดยใช้เทคนิค DSC และโครงสร้าง Residual block ทำให้ DAI-YOLO มีความแม่นยำในการตรวจจับเพลิงไหม้ที่สูงกว่า YOLOv3 และมีการทำงานได้รวดเร็วด้วยทรัพยากรที่น้อยกว่า YOLOv3 ที่ใช้ Convolution 3x3, Max pooling, และ Darknet-53 เป็น backbone ในขณะที่ DAI-YOLO ใช้ Depth Separable Convolution (DSC), Residual block, และ MobileNet-V2 เป็น backbone ทำให้เป็นทางเลือกที่มีประสิทธิภาพสูงในการตรวจจับและประมวลผลที่มีประสิทธิภาพ




ภาพ 23 Comparison of improvement effects of different strategies. (Yan, 2023)

ภาพ 23 แสดงผลลัพธ์การเปรียบเทียบประสิทธิภาพของโมเดล DAI-YOLO กับโมเดล YOLOv3 และ YOLOv3-Net ในการตรวจจับเพลิงไหม้ ผลลัพธ์ โมเดล DAI-YOLO มีประสิทธิภาพในการตรวจจับเพลิงไหม้สูงสุด

10. A Study on the Fire Detection and Smoke Removal in Underground Utility Tunnel Using CFD (Cho และคณะ, 2023)


งานวิจัยเรื่องการตรวจจับไฟไหม้และการกำจัดควันในอุโมงค์สาธารณูปโภคใต้ดินโดยใช้ CFD มุ่งเน้นที่การปรับปรุงความปลอดภัยจากอัคคีภัยในอุโมงค์สาธารณูปโภคใต้ดิน โดยกระทำการหาตำแหน่งที่เหมาะสมสำหรับเซ็นเซอร์เพื่อตรวจจับแหล่งกำเนิดไฟได้อย่างมีประสิทธิภาพ และการพัฒนาแผนสำหรับการใช้พัดลมดูดควันเพื่อกำจัดควันออกจากพื้นที่ที่ไฟไหม้เกิดขึ้น เพื่อลดการแพร่กระจายของควันและช่วยให้การอพยพและการดับเพลิงเป็นไปได้ง่ายขึ้น



ภาพ 24 Flowchart of the research procedure.(Cho และคณะ, 2023)

การออกแบบโมเดล CFD 3 มิติ (ภาพ 24) สร้างโมเดลเสมือนจริงของอุโมงค์ รวมถึงรายละเอียดทางเรขาคณิต วัสดุ และคุณสมบัติทางอุณหพลศาสตร์ การป้อนข้อมูลสภาพการทำงาน ข้อมูลจำเป็นสำหรับการจำลองพฤติกรรมของไฟและควันการจำลองซอฟต์แวร์ CFD จะคำนวณการไหลของอากาศ การกระจายความร้อน และการแพร่กระจายของควันการวิเคราะห์ผลลัพธ์ ประเมินประสิทธิภาพของระบบระบายอากาศ การแพร่กระจายของควันและตำแหน่งเซ็นเซอร์ตรวจจับไฟไหม้ การวัดภาคสนาม เก็บข้อมูลจริงจากอุโมงค์ การเปรียบเทียบ ปรับแต่งโมเดล CFD ให้มีความแม่นยำ ใช้การจำลอง Computational Fluid Dynamics (CFD) เพื่อจำลองการไหลของอากาศ การกระจายควัน และพฤติกรรมของไฟ

ภายใต้สถานการณ์ต่างๆ และมีการทดลองภาคสนามเพื่อประเมินประสิทธิภาพการระบายอากาศจริง ๆ และอุณหภูมิพื้นผิวในอุโมงค์สาธารณูปโภคใต้ดิน



ภาพ 25 Internal ceiling core temperature in case of fire source at 7-0: (a) Winter, fans working (b) Winter, fans (Cho และคณะ, 2023)


ภาพ 35 แสดงกราฟอุณหภูมิภายในเพดานอุโมงค์สาธารณูปโภคใต้ดินในสถานการณ์จำลองไฟไหม้ โดยมีตัวแปรหลักคืออุณหภูมิ (°C) และความยาวของอุโมงค์ (m) กราฟแบ่งเป็น 2 กรณี กรณีที่ 1 อุณหภูมิพัฒนาตามงาน เส้นสีแดงแสดงอุณหภูมิสูงสุดที่เพดานอุโมงค์ เส้นสีน้ำเงินแสดงอุณหภูมิเฉลี่ยที่เพดานอุโมงค์ เส้นสีเขียวแสดงอุณหภูมิที่ปลายอุโมงค์ (จุดระบายอากาศ) กรณีที่ 2 อุณหภูมิพัฒนาตามงาน เส้นสีแดงแสดงอุณหภูมิสูงสุดที่เพดานอุโมงค์ เส้นสีน้ำเงินแสดงอุณหภูมิเฉลี่ยที่เพดานอุโมงค์ แกน X แสดงความยาวของอุโมงค์ ตั้งแต่ 0 ถึง 15 เมตร แบ่งเป็น 15 จุด แกน Y แสดงอุณหภูมิ (°C) ตั้งแต่ 0 ถึง 45 °C

ผลการศึกษาที่สำคัญอัตราการไหลเวียนของอากาศที่วัดได้ต่ำกว่าที่ออกแบบไว้ ซึ่งอาจเกิดจากพัดลมเก่าและสิ่งกีดขวางในช่องระบายอากาศ ผลกระทบของการระบายอากาศต่อการแพร่กระจายของควัน โดยการกระจายควันได้รับอิทธิพลมาจากโครงสร้างที่เอียงของอุโมงค์เมื่อพัดลมดูดควันไม่ทำงาน แต่เมื่อพัดลมทำงาน ความจุของพัดลมโดยรอบใกล้เคียงแหล่งกำเนิดไฟมีความสำคัญ การตรวจจับไฟไหม้โดยใช้การเปลี่ยนแปลงอุณหภูมิ แนะนำว่าความแตกต่างของอุณหภูมิ 40°C หรือมากกว่าเมื่อเทียบกับอุณหภูมิพื้นฐานสามารถใช้เป็นตัวบ่งชี้สำหรับการตรวจจับไฟไหม้ และพื้นที่ที่มีโครงสร้างซับซ้อนต้องใช้เครือข่ายเซ็นเซอร์ที่หนาแน่นมากขึ้น

งานวิจัยนี้มีความสำคัญในการปรับปรุงความปลอดภัยในอุโมงค์สาธารณะภาคใต้ดิน และสามารถนำผลการศึกษาไปใช้ในการพัฒนาคู่มือการตอบสนอง กลยุทธ์การจัดวางเซ็นเซอร์ และการออกแบบระบบระบายอากาศ เพื่อลดความเสียหายจากไฟไหม้ ช่วยให้งานอพยพและการแทรกแซงการดับเพลิงเป็นไปอย่างปลอดภัย


11. Review Study on Recent Developments in Fire Sensing Methods (Sulthana และคณะ, 2023)

งานวิจัยนี้สำรวจเทคโนโลยีเซ็นเซอร์และวิธีการตรวจจับไฟไหม้ที่พัฒนาขึ้นใหม่ โดยใช้ความก้าวหน้าในด้านต่างๆ machine learning, information technology, sensors, and signal processing technology ช่วยลดระยะเวลาในการตรวจจับและลดสัญญาณเตือนภัยปลอมจากเซ็นเซอร์ นอกจากนี้ ยังพูดถึงความท้าทายที่ระบบตรวจจับไฟไหม้ขณะปัจจุบันเผชิญอยู่



ภาพ 26 Fire sensing method.(Sulthana และคณะ, 2023)

แผนภาพวิธีการตรวจจับไฟไหม้ (ภาพ 36) วิธีการตรวจจับไฟไหม้ เริ่มต้นจากการตรวจจับ พารามิเตอร์ทางกายภาพ เช่น อุณหภูมิ ความร้อน และควัน โดยใช้ เทคนิคการตรวจจับไฟ เช่น เซ็นเซอร์ตรวจจับเปลวไฟ เซ็นเซอร์ตรวจจับควัน เซ็นเซอร์ตรวจจับอุณหภูมิ และเซ็นเซอร์ตรวจจับก๊าซ ข้อมูลจากเซ็นเซอร์ จะถูกส่งไปยัง อุปกรณ์ประมวลผล เพื่อวิเคราะห์และตรวจจับไฟไหม้ หากตรวจพบไฟไหม้ อุปกรณ์ประมวลผลจะส่ง สัญญาณเตือนแจ้งเตือนผู้คนที่ทราบ เทคโนโลยีการตรวจจับไฟไหม้ มีการพัฒนาอย่างต่อเนื่อง เทคโนโลยีใหม่ ๆ มีความแม่นยำ รวดเร็ว และยืดหยุ่นมากขึ้น ช่วยเพิ่มประสิทธิภาพในการตรวจจับไฟไหม้ ช่วยลดความสูญเสียชีวิตและทรัพย์สินจากอัคคีภัย



ภาพ 27 Fire detection techniques.(Sulthana และคณะ, 2023)

ระบบตรวจจับควันไฟแบบอัจฉริยะ ประกอบด้วย เซ็นเซอร์ตรวจจับควัน โมดูลประมวลผล โมดูลควบคุม และอุปกรณ์แจ้งเตือน เมื่อเซ็นเซอร์ตรวจพบควันไฟ จะส่งสัญญาณไปยังโมดูลประมวลผล โมดูลประมวลผลจะวิเคราะห์สัญญาณและส่งสัญญาณไปยังโมดูลควบคุม โมดูลควบคุมจะสั่งให้อุปกรณ์แจ้งเตือนทำงาน เช่นไซเรน ไฟฉุกเฉิน และระบบส่งข้อความ เพื่อแจ้งเตือนผู้คน ระบบนี้มีข้อดีคือ แม่นยำ รวดเร็ว ยืดหยุ่น และแจ้งเตือนได้หลากหลาย ช่วยเพิ่มประสิทธิภาพในการตรวจจับไฟไหม้ ช่วยลดความสูญเสียชีวิตและทรัพย์สินจากอัคคีภัย

ควันท่อเป็นสัญญาณเตือนเพลิงไหม้ที่ดีกว่าตัววัดอื่น ๆ บทความนี้กล่าวถึงเทคนิคการตรวจจับควันท่อ 2 แบบ ได้แก่ เทคนิคการตรวจจับด้วยแสงและการตรวจสอบด้วยภาพ เทคนิคการตรวจจับด้วยแสงมีเซ็นเซอร์ตรวจจับควันท่อที่ไวต่อแสงเพลิง ทำงานได้ในช่วงอุณหภูมิที่กว้าง ไม่ค่อยได้รับผลกระทบจากอุณหภูมิแวดล้อม แต่มีข้อจำกัดคืออาจมีการแจ้งเตือนผิดพลาดจากฝุ่นและละออง งานวิจัยที่เกี่ยวข้องได้เสนอวิธีการลดการแจ้งเตือนผิดพลาดและเพิ่มความไวของการตรวจจับควันท่อ บทความนี้เน้นย้ำถึงความสำคัญของการตรวจจับควันท่อในระยะเริ่มต้นเพื่อเพิ่มประสิทธิภาพในการควบคุมเพลิงไหม้และช่วยชีวิตผู้คน

เซ็นเซอร์ตรวจจับความร้อนเป็นอีกชนิดของเซ็นเซอร์ตรวจจับไฟไหม้ เซ็นเซอร์เหล่านี้ทำงานโดยตรวจจับการเปลี่ยนแปลงของความร้อนหรืออุณหภูมิ เซ็นเซอร์ตรวจจับความร้อนแบ่งเป็น 2 ประเภทคือ เซ็นเซอร์ตรวจจับความร้อนแบบคงที่ และเซ็นเซอร์ตรวจจับอัตราการเพิ่มขึ้นของความร้อน

เซ็นเซอร์ตรวจจับเปลวไฟ มีบทบาทสำคัญในหลายอุตสาหกรรม เซ็นเซอร์เหล่านี้ทำงานโดยตรวจจับแสงที่ปล่อยออกมาจากเปลวไฟ เซ็นเซอร์แบบผสม UV-IR ช่วยลดการแจ้งเตือนผิดพลาด บทความนี้กล่าวถึงงานวิจัยเกี่ยวกับการพัฒนาเซ็นเซอร์ตรวจจับเปลวไฟแบบใหม่

วิธีการตรวจจับเพลิงไหม้หลายแบบ แต่ละแบบมีข้อดีและข้อเสียต่างกัน เซ็นเซอร์ความร้อนมีความเสถียรและเกิดสัญญาณเตือนผิดพลาดน้อย แต่ตอบสนองช้า เซ็นเซอร์ควันท่อตอบสนองเร็ว แต่มีโอกาสเกิดสัญญาณเตือนผิดพลาดสูง เซ็นเซอร์ความร้อนแบบฮอปติคัลตรวจจับการเปลี่ยนแปลงของอุณหภูมิได้ไวมาก แต่ยังอยู่ในช่วงเริ่มต้นของการพัฒนา ระบบตรวจจับเพลิงไหม้แบบวิดีโอใช้งานง่าย เหมาะสำหรับการติดตามสถานการณ์เพลิงไหม้ แต่ต้องมีกล้องวงจรปิดอยู่แล้ว การใช้เซ็นเซอร์แก๊สต้องควบคุมอุณหภูมิให้คงที่จึงจะทำงานได้อย่างมีประสิทธิภาพ หน่วยงานกำลังถูกพัฒนาเพื่อใช้ในการตรวจจับเพลิงไหม้ แต่ปัจจุบันยังไม่สามารถทดแทนการทำงานของเจ้าหน้าที่ดับเพลิงได้ ยังมีงานวิจัยเกี่ยวกับสัญญาณเตือนเบื้องต้นของเพลิงไหม้ และการใช้เครือข่ายเซ็นเซอร์ไร้สายสำหรับพื้นที่ห่างไกล การเลือกใช้ระบบตรวจจับเพลิงไหม้ขึ้นอยู่กับสภาพแวดล้อม จำนวนผู้อยู่อาศัย และระดับความปลอดภัยที่ต้องการโดยทั่วไป ควรใช้ระบบผสมผสาน เช่น เซ็นเซอร์ตรวจจับควันท่อ เซ็นเซอร์ความร้อน และสัญญาณเตือนภัยแบบกด

การประมวลผลและการตรวจสอบข้อมูลจากหลายเซ็นเซอร์สำหรับตรวจจับเพลิงไหม้ ระบบตรวจจับเพลิงไหม้ส่วนใหญ่ในปัจจุบันมีความสามารถจำกัด พวกมันจะทำงานโดยอาศัยการตั้งค่าธรณีประตู (threshold) เมื่อค่าที่วัดได้เกินกว่านี้ ระบบจะส่งสัญญาณเตือน แต่ระบบเหล่านี้ไม่ได้ให้ข้อมูลที่แม่นยำเกี่ยวกับสภาพแวดล้อมและสถานการณ์ของเพลิงไหม้

การประมวลผลและคาดการณ์สถานการณ์จึงมีความสำคัญมากในการช่วยเหลือเจ้าหน้าที่ดับเพลิงตัดสินใจ ระบบประมวลผลภาพจากกล้องวิดีโอแตกต่างจากระบบตรวจจับเพลิงไหม้แบบเดิม เนื่องจากไม่เพียงแต่ช่วยให้ตรวจจับเพลิงได้เร็วขึ้นเท่านั้น แต่ยังสามารถวิเคราะห์และคาดการณ์เพลิงไหม้ได้อีกด้วย

ระบบตรวจจับเพลิงไหม้แบบอัจฉริยะมี 2 แบบ

1. เซ็นเซอร์อัจฉริยะ ประมวลผลและตัดสินใจภายในตัวเซ็นเซอร์
2. อุปกรณ์ผสมผสานอัจฉริยะ ระบบควบคุมจะเป็นผู้วิเคราะห์ข้อมูลและตัดสินใจ

ระบบผสมผสานอัจฉริยะเหมาะสำหรับระบบตรวจจับเพลิงขนาดใหญ่ เนื่องจากไม่ต้องติดตั้งวงจรที่ซับซ้อนภายในเซ็นเซอร์

งานวิจัยส่วนใหญ่มุ่งเน้นไปที่การพัฒนาวิธีการประมวลผลข้อมูลเกี่ยวกับเพลิงไหม้ ตัวอย่างเช่น การวิเคราะห์ฟิสิกส์ของภาพจากวิดีโอเพื่อหาทิศทางของไฟ

เทคโนโลยี "อินเทอร์เน็ตของสิ่ง" (IoT) และ "เครือข่ายเซ็นเซอร์ไร้สาย" (WSN) ช่วยเพิ่มความสามารถในการแยกแยะระหว่างเพลิงไหม้กับสัญญาณรบกวน นอกจากนี้ การเรียนรู้ของเครื่อง (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning) ยังเป็นกรอบแนวคิดที่มีศักยภาพในการวิเคราะห์ข้อมูลจากเซ็นเซอร์ IoT

การใช้เซ็นเซอร์หลายตัวร่วมกันในการตรวจจับเพลิงไหม้ มีความแม่นยำมากกว่าการใช้เซ็นเซอร์ตัวเดียว โดยแบ่งเป็น 2 แนวทาง


1. แนวทางทางสถิติและความน่าจะเป็น งานวิจัยบางชิ้นเสนอการใช้เครือข่ายเบย์เซียน (Bayesian network) เพื่อวิเคราะห์ความสัมพันธ์ระหว่างระบบตรวจจับเพลิงไหม้กับคุณสมบัติทางกายภาพและเคมีที่เกิดขึ้นระหว่างการเผาไหม้
2. แนวทางปัญญาประดิษฐ์ งานวิจัยบางชิ้นเสนอการใช้ฟิลเตอร์คาลมานแบบฟัซซี่ (Fuzzy Kalman filter) และเครือข่ายประสาทเทียม (Neural network) ในการประมวลผลข้อมูลจากเซ็นเซอร์หลายตัวเพื่อตรวจจับและคาดการณ์เพลิงไหม้

บทความนี้สรุปการวิจัยเกี่ยวกับเทคโนโลยีเซ็นเซอร์ตรวจจับเพลิง เนื่องจากชุมชนในชนบทอยู่ห่างไกล ทำให้หน่วยดับเพลิงเข้าถึงพื้นที่เกิดเหตุได้ช้า ดังนั้น การตรวจจับเพลิงไหม้

แต่เนิ่น ๆ และการป้องกันอัคคีภัยจึงมีความสำคัญอย่างยิ่งในพื้นที่เหล่านี้ บทความได้ประเมินลักษณะสำคัญของสัญญาณเพลิงไหม้ เช่น เปลวไฟ ควัน อุณหภูมิแวดล้อม และระดับก๊าซ โดยรอบ รวมถึงข้อดีข้อเสียของแต่ละลักษณะตามเกณฑ์ต่างๆ การดับเพลิงเป็นงานที่ทำทนายเนื่องจากลักษณะเพลิงไหม้ที่เปลี่ยนแปลงไปตามวัสดุที่ติดไฟ สี สเปกตรัมการปล่อยแสง และสถานที่ ดังนั้น บทความเสนอแนะให้ปรับปรุงระบบตรวจจับเพลิงไหม้ด้วยฟuzzyลอจิกและอัลกอริทึมการเรียนรู้เชิงลึก นอกจากนี้ ควรพัฒนาเทคนิคการปรับแต่งเพื่อลดสัญญาณเตือนผิดพลาด

12. Uncertainty Assessment-Based Active Learning for Reliable Fire Detection Systems (Kim และKim, 2022)

งานวิจัยนี้นำเสนอระบบตรวจจับเพลิงไหม้ที่มีความน่าเชื่อถือสูงผลิตเครื่องมือด้วยกระบวนการการเรียนรู้แบบ Active Learning และโมเดล BNN เพื่อประเมินความไม่แน่นอนของข้อมูล โมเดล BNN ถูกออกแบบให้สามารถรับมือกับความไม่แน่นอนน้อยอย่างมีประสิทธิภาพ และข้อมูลที่มีความไม่แน่นอนสูงจะถูกเก็บรวบรวมในหน่วยความจำประสบการณ์ของระบบ ขั้นตอนต่อไป ข้อมูลที่มีความไม่แน่นอนสูงจะถูกนำเสนอให้ผู้เชี่ยวชาญเพื่อการวิเคราะห์และกำหนดความสำคัญ การกำหนดค่าที่สำคัญ ข้อมูลที่ผ่านการกำหนดลำดับหรือกำหนดค่าที่สำคัญจะถูกนำมาปรับปรุงโมเดล BNN เพื่อเพิ่มประสิทธิภาพในการตรวจจับเพลิง



ภาพ 28 Overall active learning framework for continuous improvement of fire detection performance. (Kim และ Kim, 2022)

รูปภาพ (28) แสดงโครงสร้างของระบบ Active Learning Framework สำหรับการยกระดับประสิทธิภาพการตรวจจับไฟไหม้ต่อเนื่อง ประกอบด้วย 3 องค์ประกอบหลัก คือ แหล่งข้อมูล ส่วนประกอบ และกระบวนการ

- แหล่งข้อมูล ประกอบด้วยข้อมูลไฟไหม้ ข้อมูลไม่ใช่ไฟไหม้ ข้อมูลเชิงข้อมูลที่มีป้ายกำกับ และข้อมูลเชิงข้อมูลที่ไม่มีการป้ายกำกับ
- ส่วนประกอบ ประกอบด้วยเซ็นเซอร์ตรวจจับไฟไหม้ เกตเวย์ IoT เซิร์ฟเวอร์การจัดการ โมเดล AI และผู้ใช้ปลายทาง
- กระบวนการ ประกอบด้วย การสุ่มตัวอย่าง การบันทึก การตัดสินใจ การฝึกอบรม โมเดล AI การปรับใช้ และการตรวจจับไฟไหม้

ระบบนี้ทำงานโดยเก็บรวบรวมข้อมูลจากเซ็นเซอร์ตรวจจับไฟไหม้ผ่านเกตเวย์ IoT และจัดเก็บข้อมูลบนเซิร์ฟเวอร์ ผู้ใช้ปลายทางจะตัดสินใจข้อมูลบางส่วนว่าเป็นไฟไหม้หรือไม่ไฟไหม้ โมเดล AI เรียนรู้จากข้อมูลที่มีป้ายกำกับและถูกปรับใช้บนเซิร์ฟเวอร์ โมเดล AI วิเคราะห์ข้อมูลใหม่เพื่อตรวจจับไฟไหม้ ระบบนี้มีวงจรการปรับปรุงอย่างต่อเนื่อง ข้อมูลใหม่จะถูกเก็บรวบรวมและตัดสินใจ โมเดล AI ได้รับการฝึกอบรมใหม่ และโมเดล AI ที่ได้รับการฝึกอบรมใหม่จะถูกปรับใช้ ระบบนี้ช่วยเพิ่มประสิทธิภาพการตรวจจับไฟไหม้ ลดจำนวนการแจ้งเตือนที่ผิดพลาด และปรับปรุงความปลอดภัยของระบบ

13. : Behavior Rule Specification–Based Distributed Misbehavior Detection of Embedded IoT Devices in a Closed–Loop Smart Greenhouse Farming System (Astillo และคณะ, 2020)

งานวิจัย SGF–MD นอกจากจะใช้การกำหนดกฎพฤติกรรมเพื่อตรวจจับความผิดปกติของอุปกรณ์ IoT ในระบบเกษตรกรรมอัจฉริยะแล้ว ยังมีโอกาสสูงที่จะนำเทคนิคอื่น ๆ มาเสริมประสิทธิภาพในการตรวจจับอีกด้วย หนึ่งในเทคนิคที่น่าสนใจและเกี่ยวข้องกับการประมวลผลสัญญาณและการวิเคราะห์ข้อมูลเชิงอนุกรม คือ Kalman Filter Algorithm และ Outlier Classification

Kalman Filter Algorithm เป็นอัลกอริทึมที่ใช้ในการประมาณค่าสถานะของระบบในปัจจุบันจากการวัดที่ได้มา ซึ่งมีความไม่แน่นอน โดย Kalman Filter สามารถนำมาประยุกต์ใช้ในการกรองสัญญาณรบกวนจากเซ็นเซอร์ต่างๆ ในระบบเกษตรกรรมอัจฉริยะ ช่วยให้ได้ค่าการวัดที่แม่นยำยิ่งขึ้น และทำให้การตรวจจับความผิดปกติมีความแม่นยำมากขึ้น

สมการ

$$\text{การทำนาย (Prediction)} \quad \hat{x}_{t|t} = A\hat{x}_{t-1} + Bu_t \quad (1)$$

$$P_{t|t} = AP_{t-1}A^T + Q \quad (2)$$

$$\text{คาลมานเกน (Kalman Gain)} \quad K_t = \frac{P_{t|t-1}(H^T)}{HP_{t|t-1}(H^T+R)} \quad (3)$$

$$\text{อัปเดตการประมาณค่า (Update estimate)} \quad x_t = \hat{x}_{t|t-1} + K_t(z_t - H\hat{x}_{t|t-1}) \quad (4)$$

$$\text{อัปเดตความแปรปรวน (Update co-variance)} \quad P_t = (I - K_tH)P_{t|t-1} \quad (5)$$

คำอธิบายสมการ

$\hat{x}_{t|t}$ = ค่าประมาณของสถานะที่ t หลังจากการอัปเดตด้วยการวัดล่าสุด

$P_{t|t}$ = ความแปรปรวนของการประมาณสถานะก่อนที่จะได้รับการวัดใหม่

K_t = Kalman Gain ณ เวลา t

x_t = ค่าประมาณสถานะใหม่หลังจากการวัด

P_t = ความแปรปรวนในการประมาณหลังจากการอัปเดต

z_t = ค่าการวัดล่าสุดที่ได้จากเซ็นเซอร์

Bu_t = เป็นส่วนที่แสดงผลของอินพุตการควบคุมต่อสถานะระบบ

A = ใช้ในการทำนายสถานะถัดไปจากสถานะปัจจุบัน

H = มาทริกซ์การสังเกต เปลี่ยนแปลงสถานะประมาณเป็นข้อมูลที่เกี่ยวข้องกับการวัด

I = มาทริกซ์เอกลักษณ์ มีขนาดเท่ากับมิติของสถานะ

สมการ มหาลาโนบิส(Mahalanobis Distance)

$$MD = \sqrt{(z_t - \hat{x}_{t|t-1})^T S^{-1} (z_t - \hat{x}_{t|t-1})} \quad (6)$$

คำอธิบายสมการ

z_t = คือข้อมูลการวัดจริงที่ได้จากเซ็นเซอร์ในขณะเวลา t

$\hat{x}_{t|t-1}$ = คือการประมาณค่าสถานะก่อนรับข้อมูลการวัดใหม่ที่ t

ได้จากการคำนวณขั้นตอนการคาดการณ์ในตัวกรองคาลมัน

S^{-1} = แมทริกซ์ความแปรปรวนร่วมที่คาดการณ์ก่อนรับข้อมูลการวัดใหม่

อัปเดตพารามิเตอร์ทางสถิติ (Update statistical parameters)

$$N_t = N_{t-1} + 1 \quad (7)$$

$$DT_t = DT_{t-1} + D_t \quad (8)$$

$$\mu_t = \frac{D^T t}{N_t} \quad (9)$$

$$DE_t = DE_{t-1} + (D_t - \mu_t)^2 \quad (10)$$

$$\sigma_t = 2 \sqrt{\frac{DE_t}{N_t}} \quad (11)$$

$$\beta_c = \beta_c + \alpha_R \frac{\partial J(\beta)}{\partial \beta} \quad (12)$$

$$J(\beta) = (D_t - (\mu_t + \beta c \sigma_t)) \quad (13)$$

คำอธิบายสมการ

μ_t = ค่าเฉลี่ยของมหาลาโนบิส

σ_t = การประมาณค่าความเบี่ยงเบนมาตรฐานของมหาลาโนบิส

β_c = ค่าพารามิเตอร์ที่ใช้ในการปรับค่าของแบบจำลอง

สมการ ยูคลิเดียน (Euclidean Distance)

$$ED = \sqrt{\sum_{i=1}^n (z_{t,i} - \hat{x}_{t|t-1,i})^2} \quad (14)$$


คำอธิบายสมการ

z_t = คือข้อมูลการวัดจริงที่ได้จากเซ็นเซอร์ในขณะเวลา t

$\hat{x}_{t|t-1}$ = คือการประมาณค่าสถานะก่อนรับข้อมูลการวัดใหม่ที่ t

Outlier Classification หรือการจำแนกข้อมูลนอกกลุ่ม เป็นเทคนิคที่ใช้ในการระบุข้อมูลที่เบี่ยงเบนไปจากรูปแบบปกติของข้อมูลส่วนใหญ่ ในบริบทของงานวิจัยนี้ Outlier Classification สามารถนำมาใช้ในการระบุค่าการวัดที่ผิดปกติ หรือพฤติกรรมที่ไม่เป็นไปตามรูปแบบปกติของอุปกรณ์ IoT ซึ่งอาจบ่งบอกถึงความผิดปกติของระบบ

การนำ Kalman Filter และ Outlier Classification มาใช้ร่วมกัน จะช่วยให้การตรวจจับความผิดปกติในระบบเกษตรกรรมที่ไร้คนดูแลมีความแม่นยำยิ่งขึ้น โดย Kalman Filter จะช่วยปรับปรุงคุณภาพของข้อมูลที่ได้จากเซ็นเซอร์ และ Outlier Classification จะช่วยระบุค่าที่ผิดปกติหรือพฤติกรรมที่ไม่เป็นไปตามรูปแบบปกติ ซึ่งอาจเป็นสัญญาณบ่งบอกถึงความผิดปกติของระบบ



ภาพ 29 Overall active learning framework for continuous improvement of fire detection performance. (Astillo และคณะ, 2020)

14. Distributed Stochastic Gradient Tracking Algorithm With Variance Reduction for Non-Convex Optimization (Jiang และคณะ, 2023)

เพื่อพัฒนาอัลกอริทึมสำหรับ distributed non-convex optimization โดยใช้เทคนิค Gradient Tracking (GT) ร่วมกับ Variance Reduction (VR) ซึ่งสามารถปรับใช้กับ machine learning, signal processing และระบบ multi-agent ที่มีข้อมูลกระจาย (distributed setting)

แนวคิดดังกล่าวมีความสำคัญอย่างยิ่งต่อการพัฒนาอัลกอริทึมที่สามารถลดผลกระทบจากความแปรปรวนของข้อมูลสุ่ม ซึ่งเป็นปัญหาหลักในระบบ distributed learning โดยเฉพาะในงานวิจัยนี้ ได้นำเทคนิค Variance Reduction มาประยุกต์ผ่านการคำนวณ ค่า Variance Ratio (VR) เพื่อประเมินประสิทธิภาพของอัลกอริทึมที่พัฒนาขึ้น โดยพิจารณาว่าอัลกอริทึมสามารถลดค่าความแปรปรวนได้มากน้อยเพียงใดเมื่อเปรียบเทียบกับค่า baseline

สูตรของ Variance Ratio มีรูปแบบดังนี้

$$VR = \frac{\frac{1}{n} \sum_{i=1}^n (x_i^{\text{before}} - \bar{x}_{\text{before}})^2}{\frac{1}{n} \sum_{i=1}^n (x_i^{\text{after}} - \bar{x}_{\text{after}})^2} \quad (16)$$

x_i^{before} คือข้อมูลชุดก่อนการประยุกต์ใช้เทคนิคที่ต้องการประเมิน

x_i^{after} คือข้อมูลชุดหลัง

$\bar{x}_{\text{before}}, \bar{x}_{\text{after}}$ คือค่าเฉลี่ยของข้อมูลแต่ละชุด

n คือจำนวนตัวอย่างข้อมูล

ค่าของ VR ที่มากกว่า 1 บ่งชี้ว่าอัลกอริทึมสามารถลดความแปรปรวนของข้อมูลได้อย่างมีนัยสำคัญ ซึ่งส่งผลให้ระบบมีความเสถียรและความแม่นยำเพิ่มขึ้นในการตรวจจับเหตุการณ์ผิดปกติ

15. Fault Diagnosis of Rotating Machinery Based on Deep Reinforcement Learning and Reciprocal of Smoothness Index (Dai และคณะ, 2020)

งานวิจัยนี้นำเสนอวิธีการวินิจฉัยความผิดปกติของเครื่องจักรหมุน โดยใช้การเรียนรู้แบบเสริมแรงเชิงลึก (Deep Reinforcement Learning: DRL) ร่วมกับตัวชี้วัดทางสัญญาณที่เรียกว่า ค่ากลับของดัชนีความเรียบ หรือ Reciprocal of Smoothness Index (RS) ซึ่งทำหน้าที่เป็นค่ารางวัล (reward) สำหรับการเลือกย่านความถี่ที่มีความสำคัญในการแยกแยะสัญญาณความผิดปกติ โดย RS จะมีค่ามากเมื่อสัญญาณมีลักษณะไม่เรียบ ซึ่งเป็นลักษณะที่มักพบในสัญญาณความผิดปกติของเครื่องจักร

ค่าความเรียบของสัญญาณหรือ Smoothness Index (SI) ถูกคำนวณโดยใช้สูตรดังนี้

$$SI = \frac{1}{n-1} \sum_{i=2}^n |x_i - x_{i-1}| \quad (17)$$

x_i = คือข้อมูลลำดับที่ i

n = คือจำนวนข้อมูลทั้งหมด

$|x_i - x_{i-1}|$ = คือค่าความแตกต่างสัมบูรณ์ระหว่างจุดข้อมูลที่ติดกัน

จากสูตรดังกล่าวจะเห็นว่า หากสัญญาณมีการเปลี่ยนแปลงระหว่างจุดข้อมูลที่ติดกันมาก (เช่น การเกิด peak หรือ outlier) ค่า SI จะสูงตามไปด้วย ซึ่งในงานนี้ $RS = \frac{1}{SI}$ จึงใช้เพื่อเน้นลักษณะสัญญาณที่มีความเปลี่ยนแปลงสูงและมีแนวโน้มบ่งชี้ถึงความผิดปกติ

16. Anomaly Detection of Non Punch Through IGBT by Robust Covariance Estimation Techniques (Patil และคณะ, 2010)

งานวิจัยของ Patil et al. (2010) นำเสนอวิธีการตรวจจับค่าผิดปกติของทรานซิสเตอร์ชนิด IGBT โดยใช้ระยะทางมหาลาโนบิส (Mahalanobis Distance) เพื่อเปรียบเทียบข้อมูลจากสถานะปกติกับข้อมูลระหว่างการทำงานจริง พร้อมประยุกต์เทคนิคการประมาณค่าความแปรปรวนร่วมแบบทนทานต่อค่าผิดปกติ ได้แก่ MVE, MCD และ NNVE เพื่อให้การคำนวณมีความแม่นยำมากยิ่งขึ้น โดยกำหนดเส้นเกณฑ์ (Threshold) สำหรับการตัดสินใจว่าข้อมูลใดเข้าข่ายผิดปกติหรือไม่ โดยอ้างอิงจากการแจกแจงไค-สแควร์ (Chi-square distribution) ที่ระดับความเชื่อมั่น 97.5% สำหรับกรณีที่ใช้พารามิเตอร์สองตัว ซึ่งเทียบเท่ากับค่าเบี่ยงเบนมาตรฐานระดับสูงในรูปแบบทางสถิติ แนวทางนี้สะท้อนหลักการทั่วไปในการใช้ค่าเฉลี่ยบวกด้วยค่าเบี่ยงเบนมาตรฐานคูณค่าคงที่ เพื่อสร้างขอบเขตสำหรับจำแนกค่าที่เบี่ยงเบนจากพฤติกรรมปกติ โดยงานวิจัยพบว่า แม้ MVE และ MCD จะสามารถตรวจจับค่าผิดปกติได้เร็วกว่าวิธีแบบคลาสสิก แต่ NNVE ให้ผลแม่นยำสูงกว่าและลดการแจ้งเตือนผิดพลาดได้ดีกว่า โดยเฉพาะในกรณีที่ข้อมูลไม่ได้กระจายแบบปกติ (non-normal distribution)

บทที่ 3


การดำเนินงาน

3.1 จากการศึกษางานวิจัยที่เกี่ยวข้อง

จากการวิเคราะห์งานวิจัยที่เกี่ยวข้อง พบว่างานวิจัยควรแบ่งการดำเนินงานเป็น 2 ส่วน ส่วนที่ 1 คืองานระบบฮาร์ดแวร์ ที่ดำเนินงานในการเลือก และออกแบบเซ็นเซอร์ให้เหมาะสมกับฟาร์มเพาะเลี้ยงครั่ง

ส่วนที่ 2 วิธีการในการวิเคราะห์ข้อมูล และตรวจจับไฟไหม้ลูกกลาม

3.1.1 การออกแบบเซ็นเซอร์ เพื่อติดตั้งในฟาร์มเพาะเลี้ยงครั่ง



ภาพ 30 ภาพรวมโครงสร้างของอุปกรณ์ ตรวจจับไฟไหม้

ภาพ 30 นี้แสดงถึงการทำงานของระบบตรวจจับและการแจ้งเตือนโดยใช้อุปกรณ์เซ็นเซอร์และคอนโทรลเลอร์หลายชิ้นที่ทำงานร่วมกันเพื่อตรวจสอบคุณภาพอากาศ เซ็นเซอร์วัดอุณหภูมิ ความชื้น (SHT20) ทำหน้าที่วัดอุณหภูมิและความชื้น ในขณะที่เซ็นเซอร์วัดค่าฝุ่น (PMS3003) วัดค่า ควันในอากาศ (PM2.5) ข้อมูลที่ได้จากเซ็นเซอร์จะถูกส่งไปยังบอร์ดคอนโทรลเลอร์ (ESP32) ซึ่งจะส่งต่อข้อมูลที่เก็บได้ไปยัง เซิร์ฟเวอร์ (ThingSpeak) ภาพ 31 โดยใช้ API Key และนำข้อมูลเข้าสู่การวิเคราะห์ข้อมูล MATLAB Analysis ภาพ 32 สำหรับการรวมข้อมูลและวิเคราะห์ ระบบจะใช้ GSM GPRS SIM800 สำหรับการสื่อสารข้อมูลผ่านเครือข่ายมือถือและส่งแจ้งเตือนผ่านแอปพลิเคชัน LINE เมื่อพบสภาวะที่ผิดปกติ ทั้งหมดนี้ได้รับพลังงานจากแบตเตอรี่ Li-ion Lithium 3.7V 20Ah ที่ให้แหล่งพลังงานในการทำงานอย่างต่อเนื่อง



ภาพ 31 หน้าแดชบอร์ด ของ ThingSpeak

The screenshot shows the MATLAB Visualizations page in ThingSpeak, titled "Fire detection By Mahal and Notify". The MATLAB code is as follows:

```

1 % Channel ID และ Field IDs
2 readChannelID = 2456050;
3 temperatureFieldID = 1;
4 humidityFieldID = 2;
5 pm25FieldID = 3;
6
7 % Channel Read API Key
8 readAPIKey = 'xxxxxxxx'; % ใส่ Read API Key
9
10 % LINE Notify Token
11 lineToken = 'xxxxxx'; % ใส่ LINE Notify Token
12
13 % Specify the date range for the past few days (change the number of days as needed)
14 startDate = datetime('now') - days(7);
15 endDate = datetime('now');
16
17 % Read data for the past few days
18 [data, timeStamps] = thingSpeakRead(readChannelID, 'Fields', [temperatureFieldID humidityFieldID pm25FieldID]
19 'DateRange', [startDate, endDate], ...
20 'ReadKey', readAPIKey);
21
22 % Convert timeStamps to minutes since startDate
23 timeMinutes = minutes(timeStamps - startDate);
24
25 % Extract data for each parameter
26 temperatureData = data(:,1);
27 humidityData = data(:,2);
28 pm25Data = data(:,3);
29

```


ภาพ 32 แสดงการวิเคราะห์ข้อมูล เพื่อตรวจหาความผิดปกติ โดย MatLab ออนไลน์



ภาพ 33 อุปกรณ์ตรวจจับไฟไหม้ที่ถูกติดตั้งบนต้นไม้ ในสถานที่จริง

อุปกรณ์นี้ ภาพ 33 ถูกออกแบบมาเพื่อการติดตั้งที่ความสูง 1.5 เมตรจากพื้น (Association, 2019) ทำให้มีความสะดวกสำหรับการบำรุงรักษาและการเข้าถึงอย่างง่ายดาย โดยไม่ต้องใช้เครื่องมือช่วยเพิ่มเติมเช่นบันได การออกแบบโครงสร้างของอุปกรณ์นี้เน้นความเรียบง่ายและความเป็นระเบียบเพื่อให้สามารถติดตั้งและซ่อมแซมได้ง่าย โดยวัสดุภายนอกเป็นกล่องพลาสติก (Waterproof Plastic box) มีกันสาดเพื่อกันน้ำจากฝนตก (Awning) แต่ละเซ็นเซอร์และคอนโทรลเลอร์ถูกเชื่อมต่ออย่างชัดเจนและมีการจัดวางที่ช่วยให้สามารถตรวจสอบและเข้าถึงอุปกรณ์แต่ละชิ้นได้อย่างง่ายดายเมื่อต้องการทำการตรวจสอบหรือแก้ไขบอร์ดคอนโทรลเลอร์ (ESP32) ทำหน้าที่เป็นจุดกลางที่รวบรวมข้อมูลจากเซ็นเซอร์อุณหภูมิและความชื้น (Temp. & Humidity Sensor) และเซ็นเซอร์ตรวจจับควัน (PM2.5 Sensor) ซึ่งตั้งอยู่ใกล้เคียงกันเพื่อลดความซับซ้อนของการเดินสายและลดความเสี่ยงของการขัดข้อง การติดตั้งอุปกรณ์ที่ความสูงนี้ยังช่วยให้มั่นใจได้ว่าเซ็นเซอร์สามารถเก็บข้อมูลสภาพแวดล้อมได้ที่ระดับที่เกิดปฏิกิริยัมพันธ์เหตุการณ์ ซึ่งเป็นตัวชี้วัดที่มีความสำคัญในการวิเคราะห์คุณภาพอากาศในพื้นที่จริง

3.1.2 ภาพรวมของระบบตรวจจับสภาวะวิกฤต



ภาพ 34 ไดอะแกรม กระบวนการทำงานของระบบตรวจจับสภาวะวิกฤต

ระบบตรวจจับไฟไหม้สำหรับฟาร์มเพาะเลี้ยงครึ่งแบบอัจฉริยะ กระบวนการเริ่มต้นด้วยการรวบรวมข้อมูลสิ่งแวดล้อมจาก ตัวรวบรวมข้อมูลจากเซ็นเซอร์ ที่ติดตั้งในพื้นที่เพาะเลี้ยง เซ็นเซอร์เหล่านี้จะวัดค่าต่าง ๆ เช่น PM2.5 (ซึ่งบ่งชี้ถึงการมีอยู่ของควัน), ความชื้น, และ อุณหภูมิ ซึ่งการเปลี่ยนแปลงของอุณหภูมิที่เพิ่มขึ้นอย่างฉับพลันหรือการมีควันอาจเป็นสัญญาณของไฟไหม้ ข้อมูลที่รวบรวมได้จะถูกส่งไปยังขั้นตอนการ กรองข้อมูล เพื่อกำจัดสัญญาณรบกวนและข้อมูลที่ไม่เกี่ยวข้อง เพื่อให้แน่ใจว่ามีเพียงข้อมูลที่แม่นยำเท่านั้นที่ใช้ในการตรวจจับไฟ เมื่อข้อมูลผ่านการกรองแล้ว ระบบจะทำการประเมินข้อมูลโดยใช้เกณฑ์ที่กำหนดไว้ล่วงหน้าเพื่อตรวจจับไฟ มีการวิเคราะห์เงื่อนไขสำคัญ 2 ประการ

1. การแจ้งเตือนสภาวะวิกฤต หากทั้ง อุณหภูมิ (Temp) และ ความชื้น (Hum) ถูกตรวจจับว่าเกินค่าเกณฑ์วิกฤต (Th) เป็นระยะเวลาสั้น ระบบจะทำการแจ้งเตือนว่าอยู่ในสภาวะวิกฤตของอุณหภูมิและความชื้น ซึ่งบ่งชี้ถึงสภาวะที่อาจนำไปสู่การเกิดไฟไหม้
2. การตรวจจับไฟไหม้ หากเกณฑ์วิกฤตของ อุณหภูมิ (Temp), ความชื้น (Hum) และ PM2.5 (ตรวจจับควัน) ถูกตรวจจับว่าเกินค่าเกณฑ์วิกฤตพร้อมกันในเวลาเดียวกัน ระบบจะทำการ แจ้งเตือนการตรวจจับไฟไหม้ ซึ่งบ่งชี้ถึงความเป็นไปได้สูงที่จะมีไฟไหม้เกิดขึ้น

เมื่อระบบตรวจพบเงื่อนไขใด ๆ ดังกล่าว ระบบจะส่ง การแจ้งเตือน ผ่านช่องทางการสื่อสาร เช่น แอปพลิเคชันไลน์ ไปยังเกษตรกรหรือผู้เกี่ยวข้อง เพื่อให้สามารถดำเนินการแก้ไขสถานการณ์ได้ทันที สุดท้าย ระบบจะสร้าง การแจ้งเตือนภัย ที่ให้ข้อมูลเกี่ยวกับตำแหน่งและความรุนแรงของไฟ ซึ่งช่วยให้สามารถตัดสินใจและตอบสนองได้อย่างรวดเร็วเพื่อป้องกันความเสียหาย

3.2 เทคนิคและวิธีการ

3.2.1 ตัวเก็บข้อมูลเซ็นเซอร์

ตัวเก็บข้อมูลเซ็นเซอร์ในระบบตรวจจับไฟไหม้สำหรับการเพาะเลี้ยงครึ่งกลางแจ้งทำหน้าที่รวบรวมข้อมูลสิ่งแวดล้อมจากเซ็นเซอร์หลายประเภท ได้แก่ เซ็นเซอร์วัดค่าฝุ่นและควัน (PM2.5) ที่ตรวจจับฝุ่นละอองในอากาศซึ่งอาจเกิดจากควันไฟ เซ็นเซอร์วัดความชื้นที่ประเมินระดับความชื้นในอากาศซึ่งมีผลต่อความเสี่ยงในการเกิดไฟไหม้ และเซ็นเซอร์วัดอุณหภูมิที่ตรวจสอบการเปลี่ยนแปลงของอุณหภูมิอย่างรวดเร็ว ข้อมูลที่ได้จะถูกส่งไปยังหน่วยประมวลผลเพื่อลดสัญญาณรบกวนโดยใช้คาลมาน ฟิลเตอร์ (Kalman Filter) และจากนั้นจะถูกวิเคราะห์โดยใช้มหาลาโนบิส (Mahalanobis Distance) เพื่อตรวจจับความผิดปกติที่บ่งชี้ถึงการเกิดไฟไหม้ หากพบความผิดปกติ ระบบจะส่งการแจ้งเตือนไปยังเกษตรกรผ่านแอปพลิเคชันมือถือหรือการแจ้งเตือนในรูปแบบอื่นๆ เพื่อให้สามารถตอบสนองต่อเหตุการณ์ได้อย่างรวดเร็วและมีประสิทธิภาพ

3.2.2 การกรองข้อมูล

การกรองข้อมูลในระบบตรวจจับไฟไหม้สำหรับการเพาะเลี้ยงครั้งกลางแจ้งเป็นกระบวนการสำคัญที่ช่วยปรับปรุงคุณภาพและความน่าเชื่อถือของข้อมูลที่ได้จากเซ็นเซอร์ต่างๆ ขั้นตอนแรกเริ่มด้วยการรวบรวมข้อมูลจากเซ็นเซอร์หลายประเภท เช่น เซ็นเซอร์วัดค่าฝุ่น (PM2.5) ที่ตรวจจับปริมาณฝุ่นละอองและควันในอากาศ เซ็นเซอร์วัดความชื้นที่ประเมินระดับความชื้นในอากาศ และเซ็นเซอร์วัดอุณหภูมิที่ตรวจสอบการเปลี่ยนแปลงของอุณหภูมิ ข้อมูลดิบที่รวบรวมได้จากเซ็นเซอร์เหล่านี้จะถูกส่งไปยังหน่วยประมวลผลกลาง (Sensor Data Collector) เพื่อดำเนินการประมวลผลเบื้องต้น โดย คาลมาน ฟิลเตอร์ (Kalman Filter) จะถูกใช้ในขั้นตอนนี้เพื่อกรองและลดสัญญาณรบกวน การประมวลผลด้วย คาลมาน ฟิลเตอร์ ประกอบด้วยสองขั้นตอนหลัก คือการทำนาย (Prediction Step) ที่ใช้ข้อมูลจากช่วงเวลาก่อนหน้าเพื่อทำนายค่าปัจจุบัน และการแก้ไข (Correction Step) ที่ปรับค่าทำนายโดยใช้ข้อมูลจริงจากเซ็นเซอร์ในช่วงเวลาปัจจุบัน เพื่อลดความคลาดเคลื่อนระหว่างค่าทำนายและค่าจริง

อัลกอริทึม 1 คาลมานฟิเตอร์ (Algorithm Kalman Filter)


อินพุต : $Z_t, x_{t-1}, P_{t-1}, R_{t-1}$

เอาพุต : x_t, P_t, R_t

ประมาณค่าล่วงหน้า $\hat{x}_{t|t-1}$ และความแปรปรวนล่วงหน้า $P_{t|t-1}$ สมการ (1) และ (2)

คำนวณการเพิ่มขึ้นของตัวกรองคาลมาน (Kalman gain) K_t สมการ (3)

อัปเดตการประมาณค่า (Update estimate) x_t สมการที่ (4)



ภาพ 35 แสดงการเปรียบเทียบระหว่าง ข้อมูลดิบจากเซ็นเซอร์ และข้อมูลที่ถูกฟิเตอร์ด้วย คาลมาน ฟิเตอร์

ประโยชน์ของการกรองข้อมูลด้วย คาลมาน ฟิเตอร์ (Kalman Filter) ได้แก่ การลดสัญญาณรบกวน ทำให้ข้อมูลที่ได้มีคุณภาพสูงขึ้นและลดโอกาสเกิดการแจ้งเตือนเท็จ ข้อมูลที่ผ่านการกรองแล้วจะมีความแม่นยำมากขึ้น ช่วยให้การวิเคราะห์และการตรวจจับความผิดปกติ เช่น ไฟไหม้ มีประสิทธิภาพมากขึ้น นอกจากนี้ การกรองข้อมูลยังช่วยปรับปรุงความน่าเชื่อถือของระบบ ทำให้สามารถตอบสนองต่อเหตุการณ์ไฟไหม้ได้อย่างรวดเร็วและมีประสิทธิภาพ การเตรียมข้อมูลที่มีคุณภาพสำหรับการวิเคราะห์เป็นขั้นตอนสำคัญในการตรวจจับและแจ้งเตือนไฟไหม้ในพื้นที่เพาะเลี้ยงกุ้ง

3.2.3 ระบบตรวจจับสภาวะวิกฤต

ในระบบตรวจจับไฟไหม้สำหรับการเพาะเลี้ยงกุ้งกลางแจ้ง เงื่อนไขที่จะแจ้งเตือนว่าเกิดไฟไหม้จะต้องมีการตรวจพบการลุกลามของไฟไหม้ที่เกิดขึ้นจริงในพื้นที่ โดยการแจ้งเตือนจะเกิดขึ้นเมื่อทั้งสามพารามิเตอร์หลัก ได้แก่ ควัน, ความชื้น, และอุณหภูมิ ตรวจพบค่าที่ผิดปกติหรือเอาต์ไลเออร์ในเวลาใกล้เคียงกัน กระบวนการตรวจจับเอาต์ไลเออร์นี้ใช้เทคนิค มหาลาโนบิส (Mahalanobis Distance) ซึ่งเป็นการวัดระยะทางทางสถิติระหว่างจุดข้อมูลปัจจุบันกับค่าเฉลี่ยของข้อมูลประวัติในหลายมิติ เพื่อให้สามารถระบุได้ว่าค่าที่วัดได้เบี่ยงเบนจากค่าปกติอย่างมีนัยสำคัญ

นอกจากนี้ ระบบยังมีการแจ้งเตือน สภาวะวิกฤต ซึ่งจะเกิดขึ้นเมื่อทั้ง อุณหภูมิ (Temp) และ ความชื้น (Hum) ถูกตรวจจับว่าเกินค่าเกณฑ์วิกฤต (Th) เป็นระยะเวลานาน ระบบจะใช้

เทคนิค ค่าเฉลี่ยเคลื่อนที่อย่างง่าย (SMA) ในการวิเคราะห์ข้อมูล เพื่อระบุสถานะที่อาจนำไปสู่การเกิดไฟไหม้และทำการแจ้งเตือนให้ผูู้้งานทราบถึงสภาวะวิกฤตนี้

การประเมินมหาลาโนบิส(Mahalanobis Distance) และ สมการ ยูคลิเดียน (Euclidean Distance)

ในการศึกษาเกี่ยวกับการตรวจจับไฟไหม้ในพื้นที่เพาะเลี้ยงครึ่งกลางแจ้ง เราได้ทำการเปรียบเทียบสองวิธีการคำนวณระยะทางที่ใช้ในการประเมินความผิดปกติของข้อมูล ได้แก่ มหาลาโนบิส (Mahalanobis Distance) และ ยูคลิเดียน (Euclidean Distance) ซึ่งทั้งสองวิธีมีลักษณะการทำงานและข้อดีข้อเสียที่แตกต่างกันออกไป

มหาลาโนบิส เป็นวิธีการวัดระยะทางที่ได้รับการยอมรับอย่างกว้างขวางในงานที่ต้องการความแม่นยำสูง โดยเฉพาะอย่างยิ่งในกรณีที่ข้อมูลมีความสัมพันธ์เชิงเส้นระหว่างตัวแปรหลายตัว การคำนวณระยะทางโดยใช้ มหาลาโนบิส คำนึงถึงการกระจายตัวของข้อมูลในแต่ละมิติ รวมถึงความสัมพันธ์ระหว่างตัวแปรเหล่านั้น ซึ่งแสดงออกมาในรูปของเมทริกซ์ความแปรปรวนร่วม การใช้ มหาลาโนบิส ช่วยให้เราสามารถตรวจจับความผิดปกติที่มีลักษณะเป็นมัลติ-มิติได้อย่างแม่นยำมากยิ่งขึ้น การคำนึงถึงการกระจายตัวของข้อมูลในแต่ละมิติทำให้สามารถแยกแยะระหว่างข้อมูลปกติและข้อมูลผิดปกติได้ดีเยี่ยม ส่งผลให้ลดโอกาสในการเกิด การเตือนที่ผิดพลาด และเพิ่มโอกาสในการตรวจจับเหตุการณ์จริงอย่างมีประสิทธิภาพ นอกจากนี้ มหาลาโนบิส ยังสามารถปรับตัวเข้ากับสถานการณ์ที่มีการเปลี่ยนแปลงในข้อมูลและสภาพแวดล้อมได้ดี อย่างไรก็ตาม การคำนวณ มหาลาโนบิส ต้องการข้อมูลจำนวนมากเพื่อให้การประเมินความแปรปรวนร่วมมีความแม่นยำสูง ซึ่งอาจเป็นข้อจำกัดในกรณีที่ข้อมูลน้อย

ยูคลิเดียน เป็นวิธีการวัดระยะทางที่มีพื้นฐานง่าย โดยการใช้ทฤษฎีบทพีทาโกรัสในการคำนวณระยะทางระหว่างจุดข้อมูลในหลายมิติ วิธีการนี้ไม่พิจารณาความสัมพันธ์ระหว่างตัวแปร และคำนวณระยะทางในรูปแบบที่ตรงไปตรงมา ข้อได้เปรียบหลักของ ยูคลิเดียน (Euclidean Distance) คือความเรียบง่ายและความรวดเร็วในการคำนวณ ไม่จำเป็นต้องประเมินเมทริกซ์ความแปรปรวนร่วม ทำให้สามารถใช้กับข้อมูลขนาดเล็กหรือสถานการณ์ที่ไม่ซับซ้อนได้อย่างมีประสิทธิภาพ

อย่างไรก็ตาม ความเรียบง่ายของ ยุคไลเดียน อาจทำให้ความสามารถในการแยกแยะความผิดปกติในข้อมูลที่มีหลายมิติและความสัมพันธ์ระหว่างตัวแปรไม่สูงนัก ส่งผลให้เกิด การเตือนที่ผิดพลาด(false positive) มากกว่าการใช้ มหาลาโนบิส(Mahalanobis Distance) โดยเฉพาะในสถานการณ์ที่ข้อมูลมีความซับซ้อน

สมการ ค่าเฉลี่ยเคลื่อนที่ (SMA- Simple Moving Average)

$$SMK_k = \frac{1}{n} \sum_{i=0}^{n-1} \hat{x}_k - i \quad (15)$$

คำอธิบายสมการ

SMK_k = ค่าเฉลี่ยเคลื่อนที่ในช่วงเวลา k

n = ขนาดของหน้าต่างค่าเฉลี่ยเคลื่อนที่

$\hat{x}_k - i$ = ค่าข้อมูลที่ผ่านการกรองด้วย Kalman Filter ในช่วงเวลา $k - i$

การใช้เทคนิค คาลมาน ฟิลเตอร์ (Kalman Filter) ร่วมกับค่าเฉลี่ยเคลื่อนที่ (SMA) เพื่อการตรวจจับความผิดปกติในระบบนี้ ช่วยลดผลกระทบจากสัญญาณรบกวนและทำให้ข้อมูลเรียบขึ้น ส่งผลให้การตรวจจับสภาวะวิกฤตมีความแม่นยำมากขึ้น โดยการกรองข้อมูลด้วย คาลมาน ฟิลเตอร์ ก่อน แล้วนำผลลัพธ์ที่ได้ไปคำนวณค่าเฉลี่ยเคลื่อนที่แบบ 3 จุด ช่วยลดการผันผวนระยะสั้น หลังจากนั้นข้อมูลที่ถูกทำให้เรียบจะถูกนำไปเปรียบเทียบกับค่าขีดจำกัดที่กำหนดไว้ เมื่อค่าที่ได้เกินขีดจำกัดนี้ ระบบจะระบุค่าดังกล่าวว่าเป็นค่าผิดปกติ (Outlier) ซึ่งชี้ถึงสภาวะวิกฤตที่อาจเกิดขึ้น

ในการวิเคราะห์ค่าความผิดปกติด้วยระยะทาง มหาลาโนบิส (Mahalanobis Distance, MD) ระบบจะต้องกำหนดเส้นเกณฑ์ (Threshold) เพื่อใช้เป็นขอบเขตในการตัดสินว่าเหตุการณ์หนึ่ง ๆ เข้าข่ายผิดปกติหรือไม่ ซึ่งในงานวิจัยนี้ การกำหนด Threshold ซึ่งเป็นหลักการที่ได้รับการยอมรับและถูกใช้อย่างแพร่หลายในงานวิเคราะห์ข้อมูลหลายมิติ (Patil และคณะ, 2010) ดังนั้น ในงานวิจัยนี้จึงสามารถนำแนวทางเดียวกันมาใช้ได้โดยการกำหนด Threshold ตาม

สมการ

$$Th_{temp} = \mu_{MD,temp} + k \cdot \sigma_{MD,temp} \quad (18)$$

Th_{temp} = คือค่าเกณฑ์ Threshold ของเซ็นเซอร์ ของอุณหภูมิ

$\mu_{MD,temp}$ = ค่าเฉลี่ยของค่าระยะทาง Mahalanobis จากข้อมูลเซ็นเซอร์ ของอุณหภูมิ

$\sigma_{MD,temp}$ = ส่วนเบี่ยงเบนมาตรฐานของค่าระยะทาง Mahalanobis ของอุณหภูมิ

k = ค่าคงที่ เท่ากับ 1 ในการทดลองนี้

$$Th_{hum} = \mu_{MD,hum} + k \cdot \sigma_{MD,hum} \quad (19)$$

Th_{hum} = คือค่าเกณฑ์ Threshold ของเซ็นเซอร์ ความชื้น

$\mu_{MD,hum}$ = ค่าเฉลี่ยของค่าระยะทาง Mahalanobis จากข้อมูลเซ็นเซอร์ ความชื้น

$\sigma_{MD,hum}$ = ส่วนเบี่ยงเบนมาตรฐานของค่าระยะทาง Mahalanobis ความชื้น

k = ค่าคงที่ เท่ากับ 1 ในการทดลองนี้

$$Th_{pm} = \mu_{MD,pm} + k \cdot \sigma_{MD,pm} \quad (20)$$

Th_{pm} = คือค่าเกณฑ์ Threshold ของเซ็นเซอร์ PM2.5

$\mu_{MD,pm}$ = ค่าเฉลี่ยของค่าระยะทาง Mahalanobis จากข้อมูลเซ็นเซอร์ PM2.5

$\sigma_{MD,pm}$ = ส่วนเบี่ยงเบนมาตรฐานของค่าระยะทาง Mahalanobis ของเซ็นเซอร์ PM2.5

k = ค่าคงที่ เท่ากับ 1 ในการทดลองนี้

ในงานนี้ เลือกใช้จากค่าเบี่ยงเบนมาตรฐานตามหลักการข้างต้นเพื่อสร้างเส้นเกณฑ์ที่ตอบสนองต่อพฤติกรรมของข้อมูลจริง โดยเฉพาะในสภาพแวดล้อมที่มีความแปรปรวนสูง เช่น พารามิเตอร์ PM2.5 ซึ่งช่วยลดอัตราการแจ้งเตือนผิดพลาดลงได้อย่างมีนัยสำคัญ

อัลกอริทึม 2 การตรวจจับข้อมูลที่ผิดปกติสำหรับปรากฏการณ์เป้าหมาย

(Outlier Detection for Target Phenomenon)

อินพุต : $x_t, x_{t-1}, N_{t-1}, \beta_C$

เอาพุต : $V = True/False(0/1), DT, DE_t, N_t, \beta_U$

กระบวนการ(process):

คำนวณ Mahalanobis Distance DT สมการ (6)

ปรับปรุงพารามิเตอร์ทางสถิติตามสมการ (7) ถึง (11)

จัดประเภทข้อมูลที่ผิดปกติ:

If ($D_t > Th_{temp}, Th_{hum}, Th_{pm}$)

$V = True$

Else $V = False$

ตรวจสอบเงื่อนไขสภาวะวิกฤต

คำนวณ SMA สำหรับ Temp และ Hum


If (Temp & Hum $> Th_{temp}, Th_{hum}$ เกิน 60 นาที)

Else $V = CrisisWarning$ (สภาวะวิกฤต)

ปรับปรุง β_C สมการ (12) และ (13)

3.2.4 การแจ้งเตือนสภาวะวิกฤต


ภาพ 36 แสดงการตรวจสอบอุณหภูมิและความชื้นในสภาพแวดล้อมการเพาะเลี้ยงครั้ง
กลางแจ้ง โดยใช้ คาลมาน ฟิลเตอร์ (Kalman Filter) ร่วมกับค่าเฉลี่ยเคลื่อนที่ (SMA) เพื่อระบุ
สภาวะวิกฤติเมื่อทั้งอุณหภูมิและความชื้นเกินค่าเกณฑ์ที่กำหนดเป็นระยะเวลานาน ในกราฟจะ
แสดงสภาวะแสงแดด (สีเหลือง) ที่ทำให้อุณหภูมิสูงขึ้นชั่วคราว และสภาวะวิกฤติ (สีน้ำเงิน) ซึ่ง
เป็นช่วงเวลาที่สภาวะเกินเกณฑ์เกิดขึ้นต่อเนื่อง ระบบจะแจ้งเตือนผู้ใช้งานเมื่อพบสภาวะวิกฤติ
ที่อาจส่งผลกระทบต่อ การเพาะเลี้ยงครั้ง ช่วยให้เกษตรกรสามารถจัดการความเสี่ยงได้อย่าง
ทันเวลาที่



ภาพ 36 ตัวอย่างเหตุการณ์ เพื่อแจ้งเตือนเหตุการณ์สภาวะวิกฤต

3.2.4 การแจ้งเตือนการเกิดเพลิงไหม้


การแจ้งเตือนในระบบตรวจจับไฟไหม้สำหรับการเพาะเลี้ยงครึ่งกลางแจ้งเป็นขั้นตอนสำคัญที่ช่วยให้ผู้ที่เกี่ยวข้องสามารถตอบสนองต่อเหตุการณ์ไฟไหม้ได้อย่างรวดเร็วและมีประสิทธิภาพ เมื่อระบบตรวจจับความผิดปกติในค่าพารามิเตอร์หลักทั้งสาม จะถูกนำเข้าสู่อัลกอริทึม 2 ได้แก่ คำนวณที่ถูกตรวจจับโดย เซ็นเซอร์ PM2.5 ความชื้น และอุณหภูมิ พร้อมกันในเวลาใกล้เคียงกัน ภาพ 37 หากเกิดเหตุการณ์ที่ทั้งสาม พารามิเตอร์ เกิดความผิดปกติของข้อมูล ระบบจะสรุปว่ามีโอกาสเกิดไฟไหม้และสร้างการแจ้งเตือนอัตโนมัติ



ภาพ 37 ตัวอย่างเหตุการณ์ เพื่อแจ้งเตือนเหตุการณ์ไฟไหม้

3.2.5 รูปแบบการเตือนภัยไปยังเกษตรกร

การเตือนภัยในระบบตรวจจับไฟไหม้สำหรับการเพาะเลี้ยงกุ้งกลางแจ้งเป็นขั้นตอนสำคัญที่ช่วยให้ผู้ที่เกี่ยวข้องสามารถตอบสนองต่อเหตุการณ์ไฟไหม้ได้อย่างรวดเร็วและมีประสิทธิภาพ การแจ้งเตือนที่คอนเฟิร์มโดยระบบตรวจจับไฟไหม้ชนิดลูกกลมและมีความรุนแรง จะส่งพิกัดตำแหน่งของเซ็นเซอร์ที่ตรวจพบความผิดปกติ และเวลาที่เกิดการตรวจพบ การแจ้งเตือนจะถูกส่งไปยังผู้ที่เกี่ยวข้องผ่านช่องทาง แอปพลิเคชันไลน์ (LINE) นอกจากนี้ การแจ้งเตือนที่ถูกต้องและทันเวลาจะช่วยลดความเสี่ยงและความเสียหายที่อาจเกิดขึ้นจากไฟไหม้ เกษตรกรและผู้ที่เกี่ยวข้องจะสามารถรับมือกับเหตุการณ์ไฟไหม้ในพื้นที่เพาะเลี้ยงกุ้งได้อย่างมีประสิทธิภาพ



ภาพ 38 แสดงตัวอย่างการแจ้งเตือนเกษตรกร และระบุตำแหน่งจุดเกิดเหตุ

บทที่ 4

ผลการทดลอง

4.1 บทนำ

การศึกษานี้มีเป้าหมายเพื่อพัฒนาระบบ ตรวจจับไฟไหม้อัจฉริยะสำหรับฟาร์มเลี้ยง ครึ่งกลางแจ้ง โดยใช้เทคนิค คาลมานฟิลเตอร์ (Kalman Filter) และระยะทางมาฮาลาโนบิส (Mahalanobis Distance) เพื่อ เพิ่มความแม่นยำ และ ลดอัตราการแจ้งเตือนผิดพลาด การทดลองนี้มุ่งเน้นไปที่ 4 ประเด็นหลัก ได้แก่

1. ศึกษาการลดสัญญาณรบกวนของข้อมูลจากเซ็นเซอร์โดยใช้คาลมานฟิลเตอร์
2. เปรียบเทียบประสิทธิภาพของคาลมานฟิลเตอร์กับค่าเฉลี่ยเคลื่อนที่ (Moving Average) ในการกรองข้อมูล
3. ใช้ระยะทางมาฮาลาโนบิสเพื่อตรวจจับค่าผิดปกติที่อาจบ่งชี้ถึงสถานการณ์ไฟไหม้
4. วิเคราะห์ผลกระทบของฤดูกาลที่มีต่อค่าผิดปกติและอัตราการแจ้งเตือน

ประเทศไทยมี 3 ฤดูกาลหลัก ซึ่งกำหนดโดย กรมอุตุนิยมวิทยา (Thai Meteorological Department, TMD) โดยสามารถแบ่งออกได้ดังนี้

1. ฤดูร้อน (Summer) กุมภาพันธ์ – พฤษภาคม
2. ฤดูฝน (Rainy Season) พฤษภาคม – ตุลาคม
3. ฤดูหนาว (Winter): ตุลาคม – กุมภาพันธ์

4.2 การกรองข้อมูล คาลมานฟิลเตอร์ (Kalman Filter) เทียบกับ ค่าเฉลี่ยเคลื่อนที่ (Moving Average)

คาลมานฟิลเตอร์ (Kalman Filter) ถูกเลือกใช้เป็น เทคนิคหลัก ในการกรองข้อมูลก่อน นำไปคำนวณ ระยะทางมาฮาลาโนบิส (Mahalanobis Distance) อย่างไรก็ตาม เพื่อให้เข้าใจถึง ประสิทธิภาพของคาลมานฟิลเตอร์ได้ดียิ่งขึ้น เราได้ทำการ เปรียบเทียบกับค่าเฉลี่ยเคลื่อนที่ (Moving Average) ซึ่งเป็น baseline model

4.2.1 ผลการเปรียบเทียบคาลมานฟิลเตอร์กับค่าเฉลี่ยเคลื่อนที่


ตารางที่ 4.1 แสดงผลการประเมินประสิทธิภาพของเทคนิคการกรองข้อมูล 2 วิธี ได้แก่ Kalman Filter และ Moving Average โดยพิจารณาจากดัชนีชี้วัด 3 ประการ คือ

- อัตราการเปลี่ยนแปลงของข้อมูล ค่าที่ต่ำแสดงถึงความสามารถในการลดความผันผวนของข้อมูล (ลด noise) ได้ดี
- ค่าความต่อเนื่องของข้อมูล ค่าที่สูงแสดงว่าข้อมูลมีความต่อเนื่องและราบเรียบมากขึ้น
- อัตราการแจ้งเตือนผิดพลาด ค่าต่ำแสดงว่าระบบมีความแม่นยำ


ตาราง 2 ผลการเปรียบเทียบระหว่างคาลมานฟิลเตอร์และค่าเฉลี่ยเคลื่อนที่

เทคนิคที่ใช้	อัตราการเปลี่ยนแปลง	ค่าความต่อเนื่อง
คาลมานฟิลเตอร์ (Kalman Filter)	2.4%	0.08
ค่าเฉลี่ยเคลื่อนที่ (Moving Average)	20.2%	1.14


จากผลการทดลองสามารถสรุปได้ว่า คาลมานฟิลเตอร์สามารถลดสัญญาณรบกวนได้ดีกว่าค่าเฉลี่ยเคลื่อนที่ โดยมีค่า VR และ FAR ต่ำกว่า



ภาพ 39 แสดงการเปรียบเทียบคาลมานฟิลเตอร์และค่าเฉลี่ยเคลื่อนที่สำหรับ อุณหภูมิ (Temperature)



ภาพ 40 แสดงการเปรียบเทียบคาลมานฟิลเตอร์และค่าเฉลี่ยเคลื่อนที่สำหรับ ความชื้น (Humidity)



ภาพ 41 แสดงการเปรียบเทียบคาลมานฟิลเตอร์และค่าเฉลี่ยเคลื่อนที่สำหรับ ค่าฝุ่นละออง PM2.5

4.2.2 ข้อสรุปของการกรองข้อมูล

จากการทดลองพบว่า คาลมานฟิลเตอร์ (Kalman Filter) สามารถลดสัญญาณรบกวนได้อย่างมีประสิทธิภาพ โดยมีอัตราการเปลี่ยนแปลงของข้อมูลต่ำกว่า Variance Ratio (VR) ต่ำ

กว่า และติดตามแนวโน้มของข้อมูลได้แม่นยำกว่าการใช้ค่าเฉลี่ยเคลื่อนที่ (Moving Average) ซึ่งแม้ว่าจะให้ค่าความต่อเนื่องของข้อมูลสูงกว่า แต่กลับมีข้อจำกัดด้านความหน่วงของสัญญาณ ที่อาจทำให้การตรวจจับเหตุการณ์ผิดปกติล่าช้า นอกจากนี้ อัตราการแจ้งเตือนผิดพลาด ของ ค่าเฉลี่ยเคลื่อนที่ สูงกว่าค่าลमानฟิลเตอร์อย่างมีนัยสำคัญ ส่งผลให้การเลือกใช้ ค่าลमानฟิลเตอร์ ควบคู่กับระยะทางมาฮาลานอบิส (Mahalanobis Distance) เป็นแนวทางที่เหมาะสมที่สุดสำหรับการตรวจจับความผิดปกติของสภาพแวดล้อมและการแจ้งเตือนไฟไหม้ที่แม่นยำและเชื่อถือได้ในสภาพแวดล้อมจริง

4.3 การตรวจจับค่าผิดปกติด้วยระยะทางมาฮาลานอบิส (Mahalanobis Distance)

การใช้ระยะทางมาฮาลานอบิส (Mahalanobis Distance) ในการตรวจจับค่าผิดปกติจากชุดข้อมูลสิ่งแวดล้อม เช่น อุณหภูมิ ความชื้นสัมพัทธ์ และฝุ่นละออง PM2.5 ในบริบทของระบบฟาร์มล็กอัจฉริยะ นั้นต้องอาศัยตัวชี้วัด ที่สามารถสะท้อนประสิทธิภาพของการจำแนกความผิดปกติได้อย่างแม่นยำและเสถียร เพื่อประเมินความน่าเชื่อถือของระยะทางที่ได้จากการกรองข้อมูลด้วยค่าลमानฟิลเตอร์ (Kalman Filter)

4.3.1 วิเคราะห์ผลการตรวจจับค่าผิดปกติจากกราฟระยะทางมาฮาลานอบิส (Mahalanobis) ทั้ง 3 ฤดูกาล

ระบบได้ทำการสุ่มเลือกข้อมูลตัวอย่างจากแต่ละฤดูกาล ได้แก่ ฤดูร้อน ฤดูฝน และฤดูหนาว เพื่อวิเคราะห์ลักษณะของข้อมูลและพฤติกรรมของระยะทางมาฮาลานอบิส (Mahalanobis Distance: MD) ภายหลังจากที่ผ่านการกรองสัญญาณรบกวนด้วย Kalman Filter โดยใช้เกณฑ์ Threshold แบบปรับตามค่าทางสถิติ (Adaptive Threshold) สำหรับแต่ละพารามิเตอร์ ได้แก่ อุณหภูมิ ความชื้นสัมพัทธ์ และค่าฝุ่น PM2.5


ฤดูร้อนจาก ภาพ 42 จากกราฟในภาพที่แสดงผลการวิเคราะห์ข้อมูลในฤดูร้อน (Summer) โดยใช้ระยะทาง Mahalanobis (MD) เพื่อประเมินค่าความผิดปกติจากพารามิเตอร์ 3 ประเภท ได้แก่ อุณหภูมิ (Temperature), ความชื้น (Humidity) และปริมาณฝุ่น PM2.5 พบว่าระบบสามารถแสดงความแตกต่างระหว่างค่าปกติและค่าที่เบี่ยงเบนจากสภาวะทั่วไปได้อย่างมีประสิทธิภาพ

สำหรับกราฟบนสุดซึ่งแสดงพารามิเตอร์ด้านอุณหภูมิ ค่า Mahalanobis Distance มีลักษณะที่เรียบและไม่ปรากฏ outlier เกินเกณฑ์ (Threshold) ตลอดช่วงเวลา แม้จะมีแนวโน้มของอุณหภูมิที่เปลี่ยนแปลงชัดเจน นั้นแสดงถึงความมั่นคงของอัลกอริทึมในการตรวจจับ และ

ไม่เกิดการแจ้งเตือนผิดพลาดโดยไม่จำเป็น ขณะที่ในกราฟค่าความชื้น ซึ่งแสดงในกรอบที่สอง ค่า MD แสดงแนวโน้มที่ต่อเนื่องเช่นกัน แม้จะมีลักษณะของความผันผวนเล็กน้อย แต่จำนวนจุดที่ถูกตรวจจับว่าเป็น outlier ยังอยู่ในระดับที่จำกัดและสอดคล้องกับแนวโน้มของข้อมูลจริง

สำหรับกราฟล่างสุดซึ่งแสดงค่าฝุ่น PM2.5 พบว่ามีหลายช่วงเวลาที่ค่าระยะทาง MD สูงเกิน Threshold อย่างชัดเจน โดยเฉพาะช่วงข้อมูล 1200–1250 ซึ่งเป็นช่วงที่สอดคล้องกับเหตุการณ์ที่เกิดควันไฟจริง การที่ MD สามารถแยกช่วงผิดปกติเหล่านี้ออกมาได้อย่างแม่นยำ และจำกัด outlier เฉพาะช่วงเวลาที่เบี่ยงเบนจริง จึงแสดงถึงความเหมาะสมของวิธีนี้ในการประยุกต์ใช้กับตัวแปรที่มีความผันผวนสูง เช่น ค่าควัน

โดยสรุป ภาพกราฟในฤดูร้อนนี้แสดงให้เห็นว่า Mahalanobis Distance สามารถลดการตรวจจับผิดพลาด และแสดงการแจ้งเตือนเฉพาะกรณีที่เบี่ยงเบนอย่างมีนัยสำคัญได้ดีกว่า โดยเฉพาะในพารามิเตอร์ PM2.5 ที่แสดงให้เห็นถึงประสิทธิภาพในการแยกแยะเหตุการณ์จริงออกจากข้อมูลรบกวนได้ชัดเจน จึงสนับสนุนข้อเสนอของงานวิจัยในการเลือกใช้วิธีนี้เป็นเกณฑ์หลักสำหรับการประเมินเหตุการณ์ไฟไหม้ในระบบจริง



ภาพ 42 แสดงผลการตรวจจับค่าผิดปกติด้วยระยะทาง Mahalanobis และอุณหภูมิ ความชื้น และ PM2.5 ในฤดูร้อน


ฤดูฝนเป็น จากภาพที่ 43 ซึ่งแสดงกราฟระยะทาง Mahalanobis (MD) ของ พารามิเตอร์ด้านอุณหภูมิ ความชื้นสัมพัทธ์ และ PM2.5 ในช่วงฤดูฝน พบว่า ระบบสามารถตรวจจับค่าผิดปกติได้อย่างมีประสิทธิภาพและสัมพันธ์กับแนวโน้มของข้อมูลจริง โดย พารามิเตอร์อุณหภูมิ (Temperature) มีการเปลี่ยนแปลงอย่างชัดเจนในบางช่วงเวลา

โดยเฉพาะช่วงข้อมูลที่ 500 และ 1000 ที่ค่าระยะทาง MD แสดงการพุ่งสูงเกิน Threshold และสามารถจำแนกเป็น outlier ได้ตรงกับการเปลี่ยนแปลงของอุณหภูมิจริงในสภาพแวดล้อม

ในส่วนของความชื้นสัมพัทธ์ (Humidity) ระบบยังสามารถตรวจจับค่าผิดปกติได้อย่างมีประสิทธิภาพ โดย outliers ที่ตรวจพบมีลักษณะเป็นกลุ่ม และเกิดขึ้นในช่วงที่ความชื้นมีความแปรปรวนสูง สะท้อนให้เห็นถึงความสามารถของ MD ในการกรองสัญญาณรบกวนที่เกิดจากการเปลี่ยนแปลงของสภาพอากาศที่ต่อเนื่องและไม่เป็นระเบียบ

สำหรับพารามิเตอร์ PM2.5 ซึ่งเป็นตัวแทนของฝุ่นและควันในอากาศ ระบบแสดงให้เห็นว่า ระยะทาง MD ยังคงรักษาเสถียรภาพได้ดี โดยไม่แสดงการกระโดดผิดปกติ แม้ว่าค่าฝุ่นจริงจะมีแนวโน้มเพิ่มขึ้นในบางช่วงเวลา ซึ่งบ่งชี้ว่าระบบสามารถควบคุมการแจ้งเตือนไม่ให้เกิดการผิดพลาดจากค่าที่เปลี่ยนแปลงเพียงเล็กน้อยหรือ noise ชั่วคราวได้อย่างเหมาะสม

จากผลการวิเคราะห์ ฤดูฝนเป็นช่วงที่สภาพแวดล้อมมีความชื้นสูงและมีการเปลี่ยนแปลงของอุณหภูมิที่ไม่รุนแรงมากนัก ระบบที่ใช้ระยะทาง Mahalanobis สามารถปรับตัวตามสภาวะดังกล่าวได้อย่างมีประสิทธิภาพ ช่วยลดการแจ้งเตือนที่ไม่จำเป็นและสามารถจำแนกค่าที่เบี่ยงเบนจริงได้แม่นยำในช่วงเวลาที่สำคัญ




ภาพ 43 แสดงผลการตรวจจับค่าผิดปกติด้วยระยะทาง Mahalanobis อุณหภูมิ ความชื้น และ PM2.5 ในฤดูฝน

จากภาพที่ 44 แสดงให้เห็นผลการวิเคราะห์ระยะทาง Mahalanobis (MD) สำหรับพารามิเตอร์ด้านอุณหภูมิ ความชื้นสัมพัทธ์ และ PM2.5 ในช่วงฤดูหนาว ซึ่งเป็นช่วงที่ข้อมูลมีความนิ่งและเสถียรมากกว่าฤดูอื่น อย่างไรก็ตาม ระบบยังสามารถตรวจพบความผิดปกติที่เกิดขึ้นเฉพาะช่วงเวลาได้อย่างแม่นยำ โดยในพารามิเตอร์อุณหภูมิ (Temperature) พบว่า MD ตรวจจับ outlier ได้อย่างต่อเนื่องและเป็นกลุ่มในช่วงข้อมูลที่ 600–800 ซึ่งสะท้อนให้เห็นถึงการเปลี่ยนแปลงของสภาพอากาศที่เกิดขึ้นจริงในระยะสั้น และยืนยันถึงความสามารถของ MD ในการแยกแยะค่าที่เบี่ยงเบนออกจากพฤติกรรมปกติ

พารามิเตอร์ด้านความชื้น (Humidity) ก็มีแนวโน้มลักษณะเดียวกัน โดยระยะทาง Mahalanobis ตรวจพบค่าผิดปกติในช่วงเวลาเดียวกันกับอุณหภูมิ ซึ่งบ่งชี้ถึงความสัมพันธ์เชิงสภาพแวดล้อมที่มีผลกระทบร่วมกัน และแสดงให้เห็นว่า MD สามารถตรวจจับข้อมูลผิดปกติได้สอดคล้องกับลักษณะจริงของปรากฏการณ์ โดยไม่ก่อให้เกิดการแจ้งเตือนที่กระจายเกินจำเป็น

สำหรับพารามิเตอร์ PM2.5 ระบบสามารถตรวจจับค่าระยะทางที่สูงเกิน Threshold ได้เฉพาะในบางช่วงเวลา เช่น ช่วงข้อมูลที่ 450, 700 และ 1000 ซึ่งแสดงให้เห็นว่า Mahalanobis Distance สามารถคัดกรองข้อมูลได้อย่างมีประสิทธิภาพ โดยไม่ไวเกินจนทำให้เกิด False Alerts ในช่วงที่ข้อมูลยังอยู่ในสภาวะปกติ จึงสามารถลดความถี่ของการแจ้งเตือนได้อย่างเหมาะสม

จากผลการวิเคราะห์ในฤดูหนาวเป็นช่วงที่ระบบสามารถคงความแม่นยำในการตรวจจับค่าผิดปกติได้ดี ด้วยการใช้ Mahalanobis Distance ในการประเมินค่าที่เบี่ยงเบนจากแนวโน้มหลักของข้อมูล ระบบแสดงให้เห็นถึงความสามารถในการควบคุมการแจ้งเตือนให้อยู่ในระดับที่เหมาะสม สอดคล้องกับพฤติกรรมของสภาพแวดล้อมในฤดูหนาว และตอบสนองต่อวัตถุประสงค์ของงานวิจัยในการลดการแจ้งเตือนที่ไม่จำเป็น



ภาพ 44 แสดงผลการตรวจจับค่าผิดปกติด้วยระยะทาง Mahalanobis อุณหภูมิ ความชื้น และ PM2.5 ในฤดูหนาว

4.3.2 เหตุผลในการเลือกใช้ VR และ SI เป็นตัวประเมินผล

1. แนวคิดเรื่องการประเมินระดับความแปรปรวนนี้สอดคล้องกับหลักการในงานของ Jiang et al. (2023) ที่เสนอว่า การลดความแปรปรวน (variance reduction) ในระบบการเรียนรู้แบบกระจายสามารถช่วยให้โมเดลมีความเสถียรและความแม่นยำที่ดีขึ้น แม้งานดังกล่าวจะมุ่งเน้นในบริบทของอัลกอริธึมการเรียนรู้แบบไม่เชิงนูน (non-convex optimization) แต่แนวคิดเรื่องความแปรปรวนต่ำสามารถประยุกต์ใช้ในการวิเคราะห์สัญญาณในระบบตรวจจับค่าผิดปกติได้เช่นกัน

แนวคิดเรื่องการประเมินระดับความแปรปรวนนี้สอดคล้องกับหลักการในงานของ (Jiang และคณะ, 2023) ที่เสนอว่า การลดความแปรปรวน (variance reduction) ในระบบการเรียนรู้แบบกระจายสามารถช่วยให้โมเดลมีความเสถียรและความแม่นยำที่ดีขึ้น แม้งานดังกล่าวจะมุ่งเน้นในบริบทของอัลกอริธึมการเรียนรู้แบบไม่เชิงนูน (non-convex optimization) แต่แนวคิดเรื่องความแปรปรวนต่ำสามารถประยุกต์ใช้ในการวิเคราะห์สัญญาณในระบบตรวจจับค่าผิดปกติได้เช่นกัน

ในงานวิจัยนี้ ค่า Variance Ratio (VR)(1) จึงถูกใช้เป็นตัวชี้วัดในการประเมินประสิทธิภาพของระยะทางมหาลาโนบิส (Mahalanobis) และระยะทางยูคลิด (Euclidean) เพื่อเปรียบเทียบความสม่ำเสมอของสัญญาณที่ได้ และสะท้อนถึงคุณลักษณะของระบบที่มีความไวต่อ noise

2. SI (Smoothness Index) เป็นตัวชี้วัดที่ประเมิน ความสม่ำเสมอหรือความเรียบของสัญญาณ ซึ่งสอดคล้องกับการวิเคราะห์เสถียรภาพของระยะทางมหาลาโนบิส หากค่า SI สูง (ใกล้ 1) แสดงว่าค่าระยะทางมีแนวโน้มเปลี่ยนแปลงต่อเนื่องและไม่เกิดการกระโดดอย่างรุนแรง งานวิจัยโดย (Dai และคณะ, 2020) ได้นำเสนอว่า reciprocal of smoothness index สามารถใช้ในการวิเคราะห์สัญญาณที่มี outliers ได้ดีกว่าตัวชี้วัดแบบดั้งเดิม เช่น kurtosis หรือ Gini index ซึ่งแสดงให้เห็นว่า SI มีความเหมาะสมในการใช้ในระบบตรวจจับสัญญาณผิดปกติในสภาพแวดล้อมที่มีสัญญาณรบกวนสูง

4.3.3 การแสดงผลการทดลองจำแนกค่าผิดปกติในแต่ละฤดูกาล

ในหัวข้อนี้ ได้ทำการประเมินผลการตรวจจับค่าผิดปกติจากข้อมูลสภาพแวดล้อม โดยใช้ระยะทางมหาลาโนบิส (Mahalanobis Distance ,MD) และระยะทางยูคลิด (Euclidean Distance ,ED) ร่วมกัน เพื่อศึกษาประสิทธิภาพของแต่ละวิธีในการลดการแจ้งเตือนที่ผิดพลาด ที่อาจเกิดขึ้นจากความแปรปรวนของข้อมูล เช่น noise หรือค่าที่เบี่ยงเบนชั่วคราว ซึ่งอาจไม่ใช่สัญญาณที่แท้จริงของเหตุการณ์ผิดปกติ

การประเมินผลถูกดำเนินการโดยแยกตามฤดูกาล ได้แก่ ฤดูร้อน ฤดูฝน และฤดูหนาว เพื่อสะท้อนถึงลักษณะการเปลี่ยนแปลงของข้อมูลที่แตกต่างกันตามช่วงเวลา ทั้งในพารามิเตอร์อุณหภูมิ ความชื้นสัมพัทธ์ และฝุ่นละออง PM2.5

ตัวชี้วัดที่ใช้ในการประเมิน ได้แก่ ค่าอัตราการแปรปรวน (Variance Ratio ,VR) ซึ่งใช้วัดระดับความสม่ำเสมอของสัญญาณระยะทาง และค่าความต่อเนื่องของข้อมูล (Smoothness Index ,SI) ซึ่งใช้ประเมินความต่อเนื่องของข้อมูลที่ตรวจพบ ค่าทั้งสองมีบทบาทสำคัญในการบ่งชี้ว่าวิธีใดสามารถลด การแจ้งเตือนที่ผิดพลาดได้อย่างมีประสิทธิภาพ

ตาราง 3 ผลการเปรียบเทียบค่าระยะทาง Mahalanobis และ Euclidean – ฤดูร้อน

ข้อมูลจากเซ็นเซอร์	ค่าเฉลี่ย ED	ค่าเฉลี่ย MD	ค่า VR ED	ค่า VR MD	ค่า SI ED	ค่า SI MD
อุณหภูมิ	0.109	0.891	0.0225	0.206	0.871	0.972
ความชื้น	0.310	0.888	0.1753	0.212	0.640	0.972
ฝุ่น PM2.5	-121.87	0.849	17016	0.171	-3.665	0.971

สำหรับฤดูร้อน ตารางที่ 3 ผลการประเมินพบว่า Mahalanobis Distance (MD) แสดงประสิทธิภาพที่เหนือกว่า Euclidean Distance (ED) อย่างชัดเจนในทุกพารามิเตอร์ โดยเฉพาะในฝุ่น PM2.5 ซึ่ง ED ให้ค่า VR สูงผิดปกติถึง 17,016 และค่า SI ติดลบ (-3.665) แสดงถึงสัญญาณที่มีความแปรปรวนสูงและขาดความเรียบ ขณะที่ MD มีค่า VR ต่ำ (0.171) และ SI สูง (0.971) ซึ่งบ่งชี้ถึงความเสถียรและความต่อเนื่องของการตรวจจับค่าผิดปกติอย่างมีประสิทธิภาพ ส่วนในพารามิเตอร์อุณหภูมิและความชื้น MD ก็ยังคงให้ค่า SI สูงกว่า ED อย่างมีนัยสำคัญ ซึ่งสะท้อนถึงความเหมาะสมในการติดตามพฤติกรรมของข้อมูลที่เปลี่ยนแปลงตามเวลา

ตาราง 4 ผลการเปรียบเทียบค่าระยะทาง Mahalanobis และ Euclidean – ฤดูฝน

ข้อมูลจากเซ็นเซอร์	ค่าเฉลี่ย ED	ค่าเฉลี่ย MD	ค่า VR ED	ค่า VR MD	ค่า SI ED	ค่า SI MD
อุณหภูมิ	0.933	0.839	0.0239	0.198	0.892	0.956
ความชื้น	0.416	0.836	0.2073	0.268	0.933	0.980
ฝุ่น PM2.5	2.580	0.837	23.172	0.266	-3.665	0.979

ในฤดูฝน ตารางที่ 4 MD ยังคงแสดงผลที่ดีกว่า ED โดยเฉพาะในความชื้นสัมพัทธ์และ PM2.5 ซึ่ง ED มีค่า VR สูง (23.172 สำหรับ PM2.5) และ SI ติดลบอีกครั้ง ขณะที่ MD ควบคุมระดับความแปรปรวนของข้อมูลให้อยู่ในช่วงต่ำ และสามารถรักษาค่า SI ให้อยู่ในระดับสูง (มากกว่า 0.95) ได้อย่างต่อเนื่อง การวิเคราะห์นี้สะท้อนว่า MD สามารถรับมือกับข้อมูลที่มีลักษณะไม่แน่นอนหรือแปรปรวนจากสภาพอากาศได้ดีกว่า โดยไม่ทำให้เกิดการแจ้งเตือนที่ผิดพลาดจาก noise

ตาราง 5 ผลการเปรียบเทียบค่าระยะทาง Mahalanobis และ Euclidean – ฤดูหนาว

ข้อมูลจากเซ็นเซอร์	ค่าเฉลี่ย ED	ค่าเฉลี่ย MD	ค่า VR ED	ค่า VR MD	ค่า SI ED	ค่า SI MD
อุณหภูมิ	0.247	0.896	0.1302	0.198	0.713	0.976
ความชื้น	1.308	0.847	0.1265	0.194	0.713	0.936
ฝุ่น PM2.5	1.916	0.768	8.1265	0.439	-1.742	0.806

ในฤดูหนาว ตารางที่ 5 ซึ่งเป็นช่วงที่ข้อมูลมีลักษณะต่อเนื่องและการเปลี่ยนแปลงเกิดขึ้นช้า MD ก็ยังคงรักษาความสม่ำเสมอของสัญญาณได้อย่างมีประสิทธิภาพ ค่า SI ของ MD อยู่ในช่วงสูง (0.806–0.976) ขณะที่ค่า SI ของ ED ในทุกพารามิเตอร์ต่ำกว่าอย่างเห็นได้ชัด โดยเฉพาะ PM2.5 ที่ยังคงแสดงค่าติดลบ (−1.742) ซึ่งหมายถึงการตรวจจับที่ไม่เสถียร และมีโอกาสนำไปสู่การแจ้งเตือนผิดพลาดแบบกระจายตัวจำนวนมาก

ระยะทางมหาลาโนบิส (Mahalanobis Distance) แสดงศักยภาพในการรักษาความเสถียรของระยะทางในเชิงเวลาได้ดีกว่า ระยะทางยูคลิด (Euclidean Distance) ในทุกฤดูกาลและทุกพารามิเตอร์ โดยเฉพาะในข้อมูลที่มีความแปรปรวนสูง เช่น PM2.5 ส่งผลให้ ระยะทางมหาลาโนบิส สามารถจำแนกค่าผิดปกติได้อย่างแม่นยำ และลดความเสี่ยงของ การแจ้งเตือนผิดพลาด ได้อย่างมีนัยสำคัญ เห็นได้จากค่าความต่อเนื่องของข้อมูล (SI) ที่อยู่ในระดับสูงอย่างต่อเนื่อง และค่า VR ที่อยู่ในช่วงต่ำ ซึ่งเหมาะสมต่อการประยุกต์ใช้ในระบบตรวจจับเหตุการณ์ผิดปกติในสภาพแวดล้อมจริง

4.3.4 การประเมินผลจากการทดลองไฟไหม้ระยะลุกลาม


นอกจากการเปรียบเทียบค่าความแปรปรวน (VR) และความเรียบของสัญญาณ (SI) การทดลองเปรียบเทียบการตรวจจับไฟไหม้ระหว่าง มหาลาโนบิส (Mahalanobis Distance) และ ยูคลิด (Euclidean Distance) ภายใต้การปรับ Threshold แบบ adaptive ใช้ค่าเฉลี่ยบวกหนึ่งเท่าของส่วนเบี่ยงเบนมาตรฐาน ($\text{mean} + 1 \text{ std}$) ดังตารางที่ 6



ภาพ 45 การทดสอบจุดไฟ

การทดลองจุดไฟจริง ภาพ 45 ในพื้นที่เพาะเลี้ยงครั้งตามภาพที่แสดง มีการบันทึกข้อมูลจากเซนเซอร์ทั้งหมดจำนวน 200 ข้อมูล โดยแบ่งเป็นช่วงก่อนเกิดไฟไหม้ ขณะเกิดไฟลุกลาม และช่วงไฟมอด ซึ่งข้อมูลชุดนี้ถูกนำมาใช้วิเคราะห์ด้วยวิธี Mahalanobis และ Euclidean

Distance เพื่อตรวจสอบประสิทธิภาพการจำแนกเหตุการณ์ผิดปกติและสร้าง Confusion Matrix ในการประเมินผลการแจ้งเตือน



ภาพ 46 เปรียบเทียบผลการจำแนกเหตุการณ์ด้วย Mahalanobis และ Euclidean Distance โดยใช้ Confusion Matrix

ภาพ 46 แสดงการจำแนกประเภทของข้อมูลผิดปกติที่ตรวจจับได้จากวิธี Mahalanobis และ Euclidean Distance โดยใช้เกณฑ์ Confusion Matrix ประกอบด้วย TP, FP, FN และ TN เพื่อประเมินประสิทธิภาพการตรวจจับเหตุการณ์ผิดปกติที่อาจบ่งชี้ถึงการเกิดไฟไหม้ โดยกราฟด้านบนเป็นผลจาก Mahalanobis Distance ซึ่งสามารถจำแนก TP ได้มากกว่าขณะที่มี FP น้อยกว่า เมื่อเทียบกับกราฟด้านล่างของ Euclidean Distance ที่มี FP และ FN สูงกว่าอย่างชัดเจน การเปรียบเทียบลักษณะนี้ช่วยให้เห็นถึงข้อได้เปรียบของ Mahalanobis ในการลดการแจ้งเตือนผิดพลาดและเพิ่มความแม่นยำในการตรวจจับเหตุการณ์จริง

		Actually Positive (1)	Actually Negative (0)			Actually Positive (1)	Actually Negative (0)
		Mahalanobis Confusion Matrix				Euclidean Confusion Matrix	
Predicted	Positive (1)	TP = 46	FP = 15	Predicted	Positive (1)	TP = 24	FP = 23
Predicted	Negative (0)	FN = 106	TN = 30	Predicted	Negative (0)	FN = 128	TN = 22

ภาพ 47 Confusion Matrix ระหว่าง Mahalanobis และ Euclidean ในการตรวจจับไฟไหม้

ค่าต่าง ๆ ในภาพ 47 Confusion Matrix มีความหมายโดยตรงต่อประสิทธิภาพของระบบตรวจจับไฟไหม้ในฟาร์มเพาะเลี้ยงกุ้ง โดย True Positive (TP) หมายถึงกรณีที่ระบบสามารถแจ้งเตือนได้อย่างถูกต้องเมื่อเกิดไฟไหม้จริง ขณะที่ True Negative (TN) หมายถึงระบบประเมินว่าไม่มีเหตุการณ์ผิดปกติ และในความเป็นจริงก็ไม่เกิดเหตุการณ์ดังกล่าว ซึ่งถือเป็นผลลัพธ์ที่ถูกต้องเช่นกัน ในทางกลับกัน False Positive (FP) คือการแจ้งเตือนที่เกินความเป็นจริง ซึ่งอาจสร้างความรำคาญและลดความเชื่อมั่นของผู้ใช้งาน ส่วน False Negative (FN) เป็นกรณีที่อันตรายที่สุด เพราะระบบไม่สามารถแจ้งเตือนเมื่อเกิดไฟไหม้จริง ทำให้เกิดความเสียหายต่อการสูญเสีย โดยเฉพาะในช่วงระยะลุกลามของไฟที่ควรได้รับการแจ้งเตือนอย่างแม่นยำและทันท่วงที

ตาราง 6 ผลการเปรียบเทียบประสิทธิภาพการตรวจจับเหตุการณ์ด้วยวิธี Mahalanobis และ Euclidean

ตัวชี้วัด	Euclidean	Mahalanobis
จำนวนแจ้งเตือนถูกต้อง (TP)	24	46
จำนวนแจ้งเตือนผิดพลาด (FP)	23	15
จำนวนที่ตรวจไม่พบ (FN)	128	106
จำนวนที่ไม่ใช่เหตุการณ์และไม่แจ้งเตือน (TN)	22	30
ความแม่นยำ (Precision, %)	51.06	75.41
อัตราการตรวจพบ (Recall, %)	15.80	30.20
คะแนน F1 (F1 Score, %)	24.08	43.17

ตารางที่ 6 แสดงการเปรียบเทียบประสิทธิภาพการตรวจจับเหตุการณ์ผิดพลาดระหว่างวิธี Mahalanobis และ Euclidean โดยใช้ข้อมูลจากการทดลองจุดไฟจริงจำนวน 200 ข้อมูล การวัดผลพิจารณาจากตัวชี้วัดทั้ง 4 ประเภท ได้แก่ จำนวนแจ้งเตือนถูกต้อง (TP), จำนวนแจ้งเตือนผิดพลาด (FP), จำนวนที่มีเหตุการณ์แต่ไม่แจ้งเตือน (FN) และจำนวนที่ไม่มีเหตุการณ์และไม่แจ้งเตือน (TN) โดยวิธี Mahalanobis สามารถแจ้งเตือนถูกต้องได้ 46 ครั้ง มากกว่า Euclidean ที่แจ้งถูกเพียง 24 ครั้ง และยังมีการแจ้งเตือนผิดพลาด (FP) น้อยกว่าที่ 15 ครั้ง ขณะที่ Euclidean มี FP มากถึง 23 ครั้ง

จากการวิเคราะห์เพิ่มเติมในด้านตัวชี้วัดด้านประสิทธิภาพ พบว่า Mahalanobis มีความแม่นยำ (Precision) อยู่ที่ 75.41% ซึ่งสูงกว่า Euclidean ที่มีเพียง 51.06% และมีค่าการครอบคลุม (Recall) ที่ 30.20% มากกว่า Euclidean ซึ่งอยู่ที่ 15.80% แสดงให้เห็นว่าวิธี Mahalanobis สามารถตรวจพบเหตุการณ์จริงได้มากกว่า แม้ว่าจะยังมีความท้าทายเรื่องจำนวน FN ที่ค่อนข้างสูงก็ตาม โดยคะแนน F1 Score ของ Mahalanobis อยู่ที่ 43.17% ซึ่งสูงกว่า Euclidean ที่ได้ 24.08% สะท้อนให้เห็นถึงความสมดุลระหว่าง Precision และ Recall ได้ดีกว่า

ผลการเปรียบเทียบนี้สนับสนุนว่าวิธี Mahalanobis เหมาะสมกว่าในงานตรวจจับเหตุการณ์ผิดปกติในระบบเกษตรอัจฉริยะของงานวิจัยนี้ เนื่องจากสามารถลดจำนวนการแจ้งเตือนผิดพลาด และเพิ่มอัตราการตรวจพบเหตุการณ์จริงได้มากขึ้น ส่งผลให้ระบบมีความน่าเชื่อถือและเหมาะสำหรับการแจ้งเตือนในสถานการณ์ที่ต้องการความแม่นยำในการตัดสินใจ

4.3.5 สรุปผลการประเมินประสิทธิภาพของระบบตรวจจับค่าผิดปกติ

จากการทดลองเปรียบเทียบระหว่างระยะทางมหาลาโนบิส (Mahalanobis Distance) และระยะทางยูคลิด (Euclidean Distance) โดยใช้ข้อมูลจากพารามิเตอร์สิ่งแวดล้อมทั้งสามประเภท ได้แก่ อุณหภูมิ ความชื้นสัมพัทธ์ และ PM2.5 ในแต่ละฤดูกาล พบว่า Mahalanobis Distance แสดงผลการตรวจจับค่าผิดปกติที่มีประสิทธิภาพและเสถียรมากกว่าในหลายด้าน (Tepmanee และคณะ, 2024)

ในด้าน อัตราการแปรปรวนของสัญญาณ Variance Ratio (VR) ค่า VR ของ ระยะทางมหาลาโนบิส อยู่ในระดับต่ำในทุกกรณี ซึ่งแสดงถึงความสม่ำเสมอของค่าระยะทางที่ใช้ในการวิเคราะห์ และสะท้อนถึงความสามารถในการลดความไวต่อ noise หรือค่าที่เปลี่ยนแปลงโดยไม่จำเป็น แนวคิดนี้สอดคล้องกับงานของ Jiang et al. (2023) ที่ชี้ให้เห็นว่า การลดความแปรปรวนของข้อมูลนำไปสู่ระบบที่มีความเสถียรและเชื่อถือได้มากขึ้นในการเรียนรู้หรือการวิเคราะห์ข้อมูลแบบกระจาย

ในด้าน ค่าความต่อเนื่องของข้อมูล (Smoothness Index, SI) ระยะทางมหาลาโนบิส ให้ค่า SI ในระดับสูง สะท้อนถึงความราบเรียบของสัญญาณ และแนวโน้มที่ตรวจพบมีความต่อเนื่องตามจริง ขณะที่ ระยะทางยูคลิด มักให้ค่า SI ต่ำ หรือแม้กระทั่งติดลบในหลายกรณี โดยเฉพาะในฤดูฝนและฤดูหนาว ซึ่งบ่งชี้ถึงความกระจัดกระจายของการแจ้งเตือนและมีแนวโน้มเกิด การผิดพลาดจาก noise ได้สูงกว่า ลักษณะเชิงพลวัตของ SI นี้สอดคล้องกับการประยุกต์ใช้ของ Fang et al. (2023) ซึ่งระบุว่า ดัชนีความเรียบสามารถใช้แยกแยะสัญญาณผิดปกติในระบบที่มีความซับซ้อนได้อย่างแม่นยำ

ในการทดสอบประสิทธิภาพของระบบ ผลการวิเคราะห์จากการจำแนกเหตุการณ์จริง แสดงว่า ระยะทาง Mahalanobis ตรวจพบเหตุการณ์จริงได้ 46 ครั้ง จากทั้งหมด 200 เหตุการณ์ มีค่าความแม่นยำ 75.41% และอัตราการตรวจพบ 30.20% ขณะที่ระยะทาง Euclidean ตรวจพบเหตุการณ์จริงได้ 24 ครั้ง มีค่าความแม่นยำเพียง 51.06% และอัตราการตรวจพบต่ำกว่า อยู่ที่ 15.80% ผลลัพธ์ดังกล่าวแสดงให้เห็นว่าวิธี Mahalanobis สามารถแยกแยะข้อมูลผิดปกติที่เกิดจากเหตุการณ์จริงได้แม่นยำและครอบคลุมมากกว่าวิธี Euclidean อย่างมีนัยสำคัญ

ระยะทางมหาลาโนบิส มีประสิทธิภาพในการตรวจจับค่าผิดปกติที่เหนือกว่า ระยะทางยูคลิด ทั้งในด้านความเสถียร ความราบเรียบของสัญญาณ และความแม่นยำในการลดการแจ้งเตือนผิดพลาด โดยเฉพาะเมื่อใช้งานร่วมกับ คาลมานฟิลเตอร์ (Kalman Filter) สำหรับการกรองข้อมูลล่วงหน้า วิธีการนี้จึงเหมาะสมอย่างยิ่งสำหรับระบบตรวจจับเหตุการณ์ผิดปกติใน

สภาพแวดล้อมจริงที่มีข้อมูลหลายมิติและความแปรปรวนสูง เช่น พื้นที่เกษตรกรรมกลางแจ้ง ซึ่งสอดคล้องกับแนวโน้มในงานวิจัยสมัยใหม่ด้านการวิเคราะห์ข้อมูลเชิงเวลาและการวินิจฉัยเหตุการณ์ (Jiang et al., 2023; Fang et al., 2023)

4.4 ระบบแจ้งเตือนอัตโนมัติ

4.4.1 เงื่อนไขการแจ้งเตือน

ระบบแจ้งเตือนถูกแบ่งออกเป็น สองระดับ ได้แก่

1. อุณหภูมิและความชื้นเกินเกณฑ์กำหนดเป็นระยะเวลานาน
2. ค่าระยะทางมาลาโนบิส (Mahalanobis Distance) เกินเกณฑ์ที่กำหนด

4.4.2 อัตราการแจ้งเตือนของระบบตรวจจับไฟไหม้ในแต่ละฤดูกาล

อัตราการแจ้งเตือนของระบบตรวจจับไฟไหม้ ซึ่งเป็นผลจากการวิเคราะห์ข้อมูลที่รวบรวมได้จาก เซ็นเซอร์ตรวจวัดอุณหภูมิ ความชื้นสัมพัทธ์ และค่าฝุ่นละอองขนาดเล็ก (PM2.5) ในช่วงระยะเวลาหนึ่งปี โดยแบ่งการวิเคราะห์ออกเป็นสามฤดูกาล ได้แก่ ฤดูร้อน , ฤดูฝน และฤดูหนาว

ข้อมูลที่น่ามาวิเคราะห์ประกอบด้วย จำนวนข้อมูลทั้งหมด 266,667 รายการต่อฤดูกาล ซึ่งเป็นการแบ่งข้อมูลออกเป็นสามส่วนเท่า ๆ กันจากชุดข้อมูลทั้งปี อัตราการแจ้งเตือนถูกคำนวณโดยเปรียบเทียบ จำนวนครั้งที่ระบบแจ้งเตือนภาวะวิกฤต และจำนวนครั้งที่ระบบแจ้งเตือนไฟไหม้ (Fire Alert) กับจำนวนข้อมูลทั้งหมดในแต่ละฤดูกาล เพื่อให้เห็นถึงแนวโน้มของระบบในการระบุภาวะเสี่ยงไฟไหม้ภายใต้เงื่อนไขแวดล้อมที่แตกต่างกัน

ตาราง 7 อัตราการแจ้งเตือนของระบบตรวจจับไฟไหม้ในแต่ละฤดูกาล

ฤดูกาล	จำนวนข้อมูลทั้งหมด	จำนวนครั้งแจ้งเตือนภาวะวิกฤต	จำนวนครั้งแจ้งเตือนไฟไหม้
ฤดูร้อน (Summer)	266,667	540	230
ฤดูฝน (Rainy)	266,667	80	20
ฤดูหนาว (Winter)	266,667	320	150

จากข้อมูลในตารางที่ 7 แสดงให้เห็นว่า ระบบตรวจจับไฟไหม้ที่ใช้ Kalman Filter ร่วมกับ Mahalanobis Distance มีประสิทธิภาพการทำงานที่แตกต่างกันในแต่ละฤดูกาล โดยฤดูร้อน (Summer) มีจำนวนการแจ้งเตือนภาวะวิกฤตสูงสุดที่ 540 ครั้ง และมีการแจ้งเตือนไฟไหม้จริง 230 ครั้ง ซึ่งสะท้อนให้เห็นถึงความเสี่ยงที่เพิ่มขึ้นจากสภาพอากาศที่ร้อนและแห้ง ทำให้เชื้อเพลิงในธรรมชาติติดไฟได้ง่าย ในขณะที่ฤดูฝน (Rainy) มีจำนวนการแจ้งเตือนต่ำที่สุด โดย

แจ้งเตือนภาวะวิกฤตเพียง 80 ครั้ง และไฟไหม้จริงเพียง 20 ครั้ง สอดคล้องกับสภาพอากาศที่ขึ้นและเย็นซึ่งลดโอกาสการเกิดเพลิงไหม้ได้อย่างชัดเจน

สำหรับฤดูหนาว (Winter) แม้จะมีอุณหภูมิต่ำกว่า แต่จำนวนการแจ้งเตือนก็ยังอยู่ในระดับปานกลาง โดยพบการแจ้งเตือนภาวะวิกฤต 320 ครั้ง และการแจ้งเตือนไฟไหม้จริง 150 ครั้ง ซึ่งอาจได้รับผลกระทบจากสภาพอากาศแห้ง ฝุ่นละอองสะสม และกระแสลมแรงที่สามารถกระตุ้นการลุกลามของไฟได้ จากแนวโน้มดังกล่าวสามารถสรุปได้ว่า ฤดูร้อนเป็นช่วงที่ระบบต้องทำงานอย่างเข้มข้นเพื่อเฝ้าระวังไฟฟ้า ขณะที่ฤดูฝนมีแนวโน้มปลอดภัยสูงสุด และฤดูหนาวยังคงต้องติดตามอย่างต่อเนื่องตามลักษณะเฉพาะของแต่ละฤดู

4.5 รวมต้นทุนอุปกรณ์ทั้งหมด

ตาราง 8 สรุปต้นทุนรวมอุปกรณ์และ ค่าแรง 1 ชุด

ลำดับ	อุปกรณ์	รุ่น/สเปก	จำนวน	ราคา	ราคารวม
1	Temp. & Humidity Sensor	SHT20	1	750	750
2	PM2.5 Sensor	PMS3003	1	990	990
3	Controller	ESP32	1	450	450
4	GSM GPRS Module	SIM808	1	250	250
5	Battery	Li-Ion 3.7V 20Ah	1	550	550
6	กล่องพลาสติกกันน้ำ	ขนาด 15x30 ซม.	1	150	150
7	Cloud Service	ThingSpeak (Free Tier)	1	0	0
8	ค่าแรง	1-2 วัน	1	2,100	2,100
9	รวมทั้งหมด	ค่าอุปกรณ์และค่าแรง	1	5,240 บาท	

บทที่ 5

สรุปผล

5.1 สรุปผลการศึกษา

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาระบบตรวจจับเหตุการณ์ผิดปกติ เช่น ไฟไหม้ ในฟาร์มเลี้ยงครึ่งกลางแจ้ง โดยอาศัยข้อมูลจากเซนเซอร์สิ่งแวดล้อม ได้แก่ อุณหภูมิ ความชื้นสัมพัทธ์ และค่าฝุ่นละออง PM2.5 ซึ่งมีแนวโน้มเปลี่ยนแปลงตามฤดูกาลและอาจเกิดความผิดปกติจากปัจจัยภายนอก เช่น เพลิงไหม้หรือสภาพอากาศ ระบบได้รับการออกแบบให้สามารถประมวลผลข้อมูลแบบเรียลไทม์ (real-time) และตรวจจับความผิดปกติด้วยเทคนิคการประมวลผลสัญญาณ Kalman Filter ร่วมกับการวิเคราะห์ระยะทาง Mahalanobis Distance ซึ่งเป็นเทคนิคทางสถิติที่สามารถประเมินความเบี่ยงเบนของข้อมูลเชิงหลายมิติได้อย่างแม่นยำ

ผลการทดลองแสดงให้เห็นว่า การกรองข้อมูลด้วย Kalman Filter ให้ผลลัพธ์ที่มีความราบเรียบและสอดคล้องกับพฤติกรรมของข้อมูลจริงมากกว่าค่าเฉลี่ยเคลื่อนที่ (Moving Average) โดยสามารถลดผลกระทบจากสัญญาณรบกวนที่เกิดจากสภาพแวดล้อมหรือความผันผวนชั่วคราวได้อย่างมีประสิทธิภาพ ในด้านการตรวจจับค่าผิดปกติ การใช้ระยะทาง Mahalanobis แสดงประสิทธิภาพที่เหนือกว่าระยะทาง Euclidean อย่างชัดเจน ทั้งในด้านความแม่นยำ ความสม่ำเสมอของการตรวจจับ และการลดจำนวนการแจ้งเตือนที่ไม่จำเป็น โดยเฉพาะอย่างยิ่งในกรณีของค่าฝุ่น PM2.5 ซึ่งมีความแปรปรวนสูงจากแหล่งกำเนิดหลายรูปแบบ

นอกจากนี้ เมื่อวิเคราะห์ผลลัพธ์แยกตามฤดูกาล พบว่าระบบสามารถรักษาความเสถียรของการตรวจจับได้ดีในทุกฤดู โดยเทคนิค Mahalanobis Distance สามารถตรวจจับค่าผิดปกติในลักษณะกลุ่ม (clustered outliers) ได้อย่างแม่นยำและสัมพันธ์กับพฤติกรรมของข้อมูลจริง ขณะที่ระยะทาง Euclidean มีแนวโน้มตรวจจับแบบกระจาย (scattered) และเกิดการแจ้งเตือนผิดพลาดมากกว่า โดยเฉพาะในช่วงเวลาที่ข้อมูลมีการเปลี่ยนแปลงต่อเนื่องอย่างเฉียบพลัน

จากผลการวิจัยสามารถสรุปได้ว่า ระบบที่พัฒนาขึ้นสามารถตอบโจทย์วัตถุประสงค์หลักของงานได้อย่างมีประสิทธิภาพ โดยเฉพาะการลดการแจ้งเตือนที่บ่อยจนเกินความจำเป็น และสามารถประมวลผลในสภาพแวดล้อมจริงได้อย่างสอดคล้องกับความต้องการของภาคเกษตรกรรมในพื้นที่เสี่ยงไฟป่า

5.2 อภิปรายผล

5.2.1 การเปรียบเทียบประสิทธิภาพของ คาลมาน ฟิลเตอร์ (Kalman Filter) และ ค่าเฉลี่ยเคลื่อนที่ (Moving Average)

ตัวกรองคาลมานฟิเตอร์ (Kalman Filter) มีความสามารถในการประเมินสถานะของข้อมูลสิ่งแวดล้อมได้อย่างต่อเนื่องแม่นยำ ลดความผันผวนจากสัญญาณรบกวนได้ดีกว่า ส่งผลให้การวิเคราะห์ข้อมูลในขั้นตอนถัดไปมีเสถียรภาพยิ่งขึ้น

5.2.2 การวิเคราะห์ผลตามฤดูกาลโดยใช้ ระยะทางมหาลาโนบิส (Mahalanobis Distance)

การประมวลผลข้อมูลจากเซนเซอร์ในแต่ละฤดูกาลแสดงให้เห็นว่า Mahalanobis Distance มีศักยภาพในการตรวจจับค่าผิดปกติที่แตกต่างกันตามลักษณะสภาพอากาศและพฤติกรรมของข้อมูลในแต่ละช่วงเวลาอย่างมีประสิทธิภาพ โดยเฉพาะเมื่อข้อมูลถูกรองด้วย Kalman Filter ก่อนการวิเคราะห์ ทำให้สามารถลดความผันผวนของสัญญาณรบกวนและเพิ่มความแม่นยำของการแจ้งเตือน

ในฤดูร้อน Mahalanobis Distance แสดงความสามารถในการควบคุมการแจ้งเตือนให้อยู่ในระดับที่เหมาะสม โดยระยะทางมีลักษณะราบเรียบและไม่เกิดการแจ้งเตือนผิดพลาด แม้ในช่วงที่อุณหภูมิสูงหรือค่าฝุ่น PM2.5 ผันผวน ซึ่งสะท้อนถึงเสถียรภาพของวิธีนี้ในการวิเคราะห์ข้อมูลที่มีการเปลี่ยนแปลงต่อเนื่อง และหลีกเลี่ยงการแจ้งเตือนเกิน (False Alerts) ได้อย่างมีประสิทธิภาพ

ในฤดูฝน ซึ่งมีความชื้นสัมพัทธ์สูงและความแปรปรวนของอุณหภูมิต่ำ ระบบ Mahalanobis Distance ยังคงสามารถตรวจจับค่าผิดปกติได้แม่นยำ โดยเฉพาะในช่วงที่เกิดการเปลี่ยนแปลงของข้อมูลจริง เช่น อุณหภูมิและความชื้นที่เบี่ยงเบนจากแนวโน้มปกติ ทำให้การแจ้งเตือนที่เกิดขึ้นมีความสัมพันธ์กับสภาพแวดล้อมจริง และสามารถลดการแจ้งเตือนผิดพลาดได้ดีกว่าการใช้ระยะทางแบบทั่วไป

สำหรับฤดูหนาว ซึ่งข้อมูลส่วนใหญ่มีลักษณะนิ่งและคงที่ Mahalanobis Distance สามารถแยกแยะค่าที่เบี่ยงเบนออกจากช่วงปกติได้อย่างแม่นยำ โดยตรวจจับกลุ่มของ outliers ที่ปรากฏเฉพาะช่วงเวลา เช่น นาฬิกา 600–800 ได้อย่างมีนัยสำคัญ ระบบสามารถรักษาความเสถียรของการวิเคราะห์ข้อมูลในพารามิเตอร์ทั้งอุณหภูมิ ความชื้น และ PM2.5 ได้อย่างต่อเนื่อง ไม่เกิดการแจ้งเตือนกระจัดกระจาย และลด false detection ได้อย่างมีประสิทธิภาพ

สรุป วิธี Mahalanobis Distance เมื่อใช้ร่วมกับ Kalman Filter ช่วยให้ระบบสามารถตรวจจับค่าผิดปกติได้แม่นยำ สอดคล้องกับพฤติกรรมจริงของข้อมูลในแต่ละฤดูกาล ลดการแจ้งเตือนที่ไม่จำเป็น และเพิ่มความน่าเชื่อถือของระบบตรวจจับไฟไหม้อัตโนมัติในบริบทของฟาร์มกลางแจ้งได้อย่างชัดเจน

5.2.3 ผลการเปรียบเทียบวิธี Mahalanobis และ Euclidean Distance ($k = 1.0$)

ในการทดลองพบว่า Mahalanobis Distance และ Euclidean Distance ให้ผลการตรวจจับที่ต่างกันอย่างมีนัยสำคัญ โดยวิธี Mahalanobis ตรวจจับเหตุการณ์ไฟไหม้ได้ถูกต้อง (True Positive) จำนวน 46 ครั้ง และมีการแจ้งเตือนผิดพลาด (False Positive) เพียง 15 ครั้ง ขณะที่ Euclidean ตรวจจับได้ถูกต้อง 24 ครั้ง แต่มีการแจ้งเตือนผิดพลาดสูงถึง 23 ครั้ง ส่งผลให้ค่า Precision ของ Mahalanobis สูงถึง 75.41% ขณะที่ Euclidean อยู่ที่ 51.06% นอกจากนี้ Mahalanobis ยังมีค่า Recall สูงกว่า คือ 30.20% เทียบกับ 15.80% ของ Euclidean แสดงให้เห็นว่าวิธี Mahalanobis มีความสามารถในการตรวจจับเหตุการณ์จริงได้แม่นยำกว่า และลดโอกาสการแจ้งเตือนที่ผิดพลาดได้ดีกว่าอย่างชัดเจน

ความแตกต่างของทั้งสองวิธีสะท้อนผ่านคะแนน F1 Score ซึ่งเป็นดัชนีวัดประสิทธิภาพแบบสมดุลระหว่าง Precision และ Recall โดย Mahalanobis ได้ค่า F1 เท่ากับ 43.17% ขณะที่ Euclidean ได้เพียง 24.08% แสดงให้เห็นว่าวิธี Mahalanobis มีประสิทธิภาพโดยรวมในการตรวจจับเหตุการณ์ผิดปกติได้เหนือกว่า

ดังนั้น จากผลการทดลองนี้สามารถสรุปได้ว่า Mahalanobis Distance เป็นวิธีที่มีความแม่นยำและมีเสถียรภาพสูงกว่า Euclidean Distance ในบริบทของระบบตรวจจับไฟไหม้อัตโนมัติ และมีศักยภาพในการใช้งานจริงได้ดีกว่า โดยเฉพาะในสถานการณ์ที่ข้อมูลมีความแปรปรวนสูง เช่น การตรวจจับไฟในพื้นที่กลางแจ้ง

5.3 ข้อเสนอแนะ

งานวิจัยนี้ชี้ให้เห็นถึงศักยภาพของการประยุกต์ใช้เทคนิคมหาลาโนบิส (Mahalanobis) Distance ร่วมกับเทคนิคคาลมาน ฟิลเตอร์ (Kalman Filter) ในการตรวจจับเหตุการณ์ที่มีความผิดปกติจากข้อมูลสิ่งแวดล้อมแบบหลายมิติ โดยสามารถลดความถี่ของการแจ้งเตือนได้อย่างมีประสิทธิภาพ ซึ่งสอดคล้องกับวัตถุประสงค์ของงานวิจัยที่มุ่งเน้นการลดปัญหาการแจ้งเตือนที่มากเกินไปจนสร้างความจำเป็น ได้อย่างเหมาะสม อย่างไรก็ตาม งานวิจัยนี้สามารถนำไปต่อยอดในอนาคต เช่น การขยายผลการประยุกต์ใช้งานในระบบติดตามสภาพอากาศ หรือการแจ้งเตือนภัยธรรมชาติในพื้นที่เกษตรกรรมที่มีความเสี่ยงสูง


The background of the page features a large, faint watermark of the University of Phayao logo. The logo is a shield-shaped emblem with a purple and gold color scheme. It contains a central white stupa-like structure with multiple flame-like elements on top. Below the shield is a banner with the university's name in Thai and English.

ภาคผนวก

ขั้นตอนการใช้งานแพลตฟอร์ม ThingSpeak
สำหรับการจัดเก็บและแสดงผลข้อมูลเซนเซอร์

ขั้นตอนการใช้งานแพลตฟอร์ม ThingSpeak สำหรับการจัดเก็บและแสดงผลข้อมูลเซนเซอร์

ThingSpeak เป็นแพลตฟอร์มออนไลน์ที่รองรับการเชื่อมต่อข้อมูลจากอุปกรณ์ IoT และสามารถเก็บ แสดงผล และวิเคราะห์ข้อมูลแบบ Real-time ได้อย่างมีประสิทธิภาพ โดยขั้นตอนการใช้งานประกอบด้วย




ขั้นตอนแรก ลงทะเบียนและเข้าสู่ระบบ

1. เข้าเว็บไซต์ <https://thingspeak.com>
2. คลิกปุ่ม Sign Up เพื่อสร้างบัญชีผู้ใช้งานใหม่
3. กรอกอีเมล รหัสผ่าน และยืนยันผ่านอีเมล
4. เมื่อสมัครเสร็จให้เข้าสู่ระบบด้วยบัญชีที่สมัครไว้

สร้าง Channel สำหรับจัดเก็บข้อมูล

1. คลิกที่เมนู Channels > My Channels เลือก New Channel
2. ตั้งชื่อ Channel เช่น "Lac Fire Monitoring")
3. กำหนดชื่อของแต่ละ Field (เช่น Field 1: Temperature, Field 2: Humidity, Field 3: PM2.5)
4. สามารถเลือกให้ Channel เป็น Public หรือ Private ได้ คลิก Save Channel



รับ API Key สำหรับเชื่อมต่อ

1. เข้าไปยัง Channel ที่สร้างไว้
2. คลิก API Keys
3. คัดลอกค่า **Write API Key** สำหรับส่งข้อมูลจาก ESP32 หรือ MATLAB ไปยัง ThingSpeak
4. คัดลอก **Read API Key** หากต้องการใช้เรียกดูข้อมูลผ่าน MATLAB หรือโปรแกรมอื่น

Fire Detection

Channel ID: 2
Author: mv99
Access: Public

Private View Public View Channel Settings Sharing API Keys Data Import / Export

Write API Key

Key 0HJXU

Generate New Write API Key

Read API Keys

Key 40M

Note

Save Note Delete API Key

Add New Read API Key

Help

API keys enable you to write data to a channel or read data from a private channel. API keys are auto-generated when you create a new channel.

API Keys Settings

- **Write API Key:** Use this key to write data to a channel. If you feel your key has been compromised, click **Generate New Write API Key**.
- **Read API Keys:** Use this key to allow other people to view your private channel feeds and charts. Click **Generate New Read API Key** to generate an additional read key for the channel.
- **Note:** Use this field to enter information about channel read keys. For example, add notes to keep track of users with access to your channel.

API Requests

Write a Channel Feed

GET https://api.thingspeak.com/update?api_key=&field1=0

Read a Channel Feed

GET https://api.thingspeak.com/channels//feeds.json?results=2

Read a Channel Field

GET https://api.thingspeak.com/channels//fields/1.json?results=2

Read Channel Status Updates

GET https://api.thingspeak.com/channels//status.json

ส่งข้อมูลจากอุปกรณ์หรือ MATLAB ไปยัง Thing Speak

1. ใช้ HTTP POST จาก ESP32 หรือ thingSpeakWrite() ใน MATLAB
2. https://api.thingspeak.com/update?api_key=YOUR_WRITE_API_KEY&field1=xx&field2=yy&field3=zz
3. MATLAB thingSpeakWrite(channelID, [temperature, humidity, pm25], 'WriteKey', 'YOUR_WRITE_API_KEY');

ดูข้อมูลแบบกราฟ Real-Time

1. ใช้ HTTP POST จาก ESP32 หรือ thingSpeakWrite() ใน MATLAB
2. คลิกแท็บ Private View หรือ Public View (หากตั้งค่าช่องเป็นสาธารณะ)
3. กราฟของข้อมูลที่จะแสดงอัตโนมัติตาม Field ที่กำหนดไว้



ตั้งค่าแจ้งเตือนหรือประมวลผลอัตโนมัติ (Optional)

1. ใช้ ThingSpeak Apps เช่น MATLAB Analysis, TimeControl, React
2. ตั้งเงื่อนไขให้ส่ง Line แจ้งเตือน หรือเขียน Script MATLAB เพื่อวิเคราะห์ข้อมูลแบบอัตโนมัติได้
3. กราฟโชว์ การทำงานของระบบให้ดูแบบ Real-time

ThingSpeak™ Channels Apps Devices Support Commercial Use

Apps / MATLAB Visualizations / Fire detection By Mahal / Edit

Name

Fire detection By Mahal

MATLAB Code

```
1 % Channel ID and Field IDs
2 readChannelID = 2457774;
3 temperatureFieldID = 1;
4 humidityFieldID = 2;
5 pm25FieldID = 3;
6
7 % Channel Read API Key
8 readAPIKey = '5SXXXXXXXXXXXX'; % ใส่ Read API Key ของคุณที่นี่
9
10 % Specify the date range for the past few days (change the number of days as needed)
11 startDate = datetime('now') - days(7);
```

Help


My Channels Documentation

New Channel

Most recent channels

Name: Fire Detection2
Channel ID: 2457774
Access: Public
Read API Key: 8LXXXXXXXXXXXX
Write API Key: 5SXXXXXXXXXXXX
Fields:
1: Temperature
2: Humidity
3: PM2.5

ThingSpeak™ Channels Apps Devices



ตั้งค่าแจ้งเตือนหรือประมวลผลอัตโนมัติ (Optional)

1. ไปที่แท็บ **Export Data**
2. เลือกรูปแบบเป็น .CSV และช่วงเวลา
3. ดาวน์โหลดไปใช้งานใน Excel หรือ MATLAB เพื่อการวิเคราะห์เพิ่มเติม

ThingSpeak™

Channels ▾ Apps ▾ Devices ▾ Support ▾

Commercial Use How to Buy JT

Private View

Public View

Channel Settings

Sharing

API Keys

Data Import / Export

Import

Upload a CSV file to import data into this channel.

File

เลือกไฟล์

ไม่ได้เลือกไฟล์ใด

Time Zone

(GMT+07:00) Bangkok

Upload

Help

The correct format for data import is provided in this [CSV Import Template File](#). Use the field names *field1*, *field2*, and so on, instead of custom field names.

CSV Import Format

created_at,field1,field3,field4,field8,elevation
2019-01-01T10:11:12-05:00,11,33,44,88,10

Other Import and Export Options

You can also use MATLAB, the REST API, or the MQTT API to import and export channel data.

[Read Data](#)

[Write Data](#)

Export

Download all of this Channel's feeds in CSV format.

Time Zone

(GMT+07:00) Bangkok

Download

AutoSave Off ↻ 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 🔍 <									
---	--	--	--	--	--	--	--	--	--

บรรณานุกรม

- Astillo, P. V., Kim, J., Sharma, V. และ You, I. (2020). SGF–MD: Behavior Rule Specification–Based Distributed Misbehavior Detection of Embedded IoT Devices in a Closed–Loop Smart Greenhouse Farming System. **IEEE Access**, 8, 196235–196252. doi:10.1109/ACCESS.2020.3034096.
- Baek, J. Alhindi, T. J. Jeong, Y. S. Jeong, M. K. Seo, S. Kang, J. และคณะ. (2021). Intelligent Multi–Sensor Detection System for Monitoring Indoor Building Fires. **IEEE Sensors Journal**, 21(24), 27982–27992. doi:10.1109/JSEN.2021.3124266.
- Bashir, N. H. Chen, H. Munir, S. Wang, W. Chen, H. Sima, Y. K. และคณะ. (2022). Unraveling the Role of Lac Insects in Providing Natural Industrial Products. **Insects**, 13(12). doi:10.3390/insects13121117. สืบค้นเมื่อ สืบค้นเมื่อ 23 ธันวาคม 2566, จาก <https://www.ncbi.nlm.nih.gov/pubmed/36555027>
- Cho, J. H., Lee, I. B., Jeong, W. S. และ Lee, B. J. (2023). A Study on the Fire Detection and Smoke Removal in Underground Utility Tunnel Using CFD. **IEEE Access**, 11, 104485–104504. doi:10.1109/ACCESS.2023.3316881.
- Chuvieco, E. (2019, 28 July–2 Aug. 2019). Global analysis of burned areas for climate assessment: experiences from the Fire_CCI project. In **IGARSS 2019 – 2019 IEEE International Geoscience and Remote Sensing Symposium** (pp 9950–9952).
- Dai, W., Mo, Z., Luo, C., Jiang, J., Zhang, H. และ Miao, Q. (2020). Fault Diagnosis of Rotating Machinery Based on Deep Reinforcement Learning and Reciprocal of Smoothness Index. **IEEE Sensors Journal**, 20(15), 8307–8315. doi:10.1109/JSEN.2020.2970747.
- Author (บรรณาธิการ). (2022). **Forest pathways for green recovery and building inclusive**. Rome, Italy.
- Hakeem, Z. S. A., Shahadi, H. I. และ Abass, H. H. (2022, 20–22 July 2022). An Automatic System for Detection of Fires in Outdoor Areas. In **2022 International Conference on Electrical, Computer and Energy Technologies (ICECET)** (pp 1–6).
- Jiang, X., Zeng, X., Sun, J. และ Chen, J. (2023). Distributed Stochastic Gradient Tracking

- Algorithm With Variance Reduction for Non-Convex Optimization. **IEEE Transactions on Neural Networks and Learning Systems**, 34(9), 5310–5321.
doi:10.1109/TNNLS.2022.3170944.
- Kim, Y. J. และ Kim, W. T. (2022). Uncertainty Assessment-Based Active Learning for Reliable Fire Detection Systems. **IEEE Access**, 10, 74722–74732.
doi:10.1109/ACCESS.2022.3190852.
- Li, J. Yan, B. Zhang, M. Zhang, J. Jin, B. Wang, Y. และคณะ. (2019). Long-Range Raman Distributed Fiber Temperature Sensor With Early Warning Model for Fire Detection and Prevention. **IEEE Sensors Journal**, 19(10), 3711–3717.
doi:10.1109/JSEN.2019.2895735.
- Muthulakshmi, K., Manimekalai, M. A. P. และ Gopikrishna, C. (2022, 21–22 April 2022). Instant Fire Detection and Toxic Fumes Monitoring in Forests with a Remote Integrated Rover. In **2022 6th International Conference on Devices, Circuits and Systems (ICDCS)** (pp 276–280).
- Patil, N., Menon, S., Das, D. และ Pecht, M. (2010, 14–16 Dec. 2010). Anomaly detection of non punch through insulated gate bipolar transistors (IGBT) by robust covariance estimation techniques. In **2010 2nd International Conference on Reliability, Safety and Hazard – Risk-Based Technologies and Physics-of-Failure Methods (ICRESH)** (pp 68–72).
- Reduction, U. N. O. f. D. R. (2022). *Our World at Risk: Transforming Governance for a Resilient Future*. Retrieved from จาก <https://www.undrr.org/gar/gar2022-our-world-risk-gar>
- Roque, G. และ Padilla, V. S. (2020). LPWAN Based IoT Surveillance System for Outdoor Fire Detection. **IEEE Access**, 8, 114900–114909. doi:10.1109/ACCESS.2020.3003848.
- Sood, K., Nosouhi, M. R., Kumar, N., Gaddam, A., Feng, B. และ Yu, S. (2023). Accurate Detection of IoT Sensor Behaviors in Legitimate, Faulty and Compromised Scenarios. **IEEE Transactions on Dependable and Secure Computing**, 20(1), 288–300.
doi:10.1109/TDSC.2021.3131991.
- Sulthana, S. F., Wise, C. T. A., Ravikumar, C. V., Anbazhagan, R., Idayachandran, G. และ

- Pau, G. (2023). Review Study on Recent Developments in Fire Sensing Methods. **IEEE Access**, 11, 90269–90282. doi:10.1109/ACCESS.2023.3306812.
- Tepmanee, J., Udomsripaiboon, T., Boonthep, N., Srisungsittisunti, B., Miyanaga, Y. และ Chaiwongsai, J. (2024, 14–15 Nov. 2024). Automatic Fire Detection and Positioning System for Outdoor Lac Cultivation. In **2024 8th International Conference on Information Technology (InCIT)** (pp 115–120).
- Author (บรรณานุกรม). (2024). **Compendium of WHO and other UN guidance on health and environment.**
- Yan, H. (2023). The Analysis of Tourist Satisfaction Integrating the Artistic Intelligence Convolutional Neural Network and Internet of Things Technology. **IEEE Access**, 11, 103628–103635. doi:10.1109/ACCESS.2023.3317251.
- Zaidan, M. A. Motlagh, N. H. Fung, P. L. Khalaf, A. S. Matsumi, Y. Ding, A. และคณะ. (2023). Intelligent Air Pollution Sensors Calibration for Extreme Events and Drifts Monitoring. **IEEE Transactions on Industrial Informatics**, 19(2), 1366–1379. doi:10.1109/TII.2022.3151782.
- เด่นรุ่งเรือง, น. (2014). การเพาะเลี้ยงครั้งและการใช้ประโยชน์ครั้ง (พิมพ์ครั้งที่). จาก สืบค้นจาก <https://forprod.forest.go.th/forprod/PDF/หนังสือครั้ง001.pdf>

ประวัติผู้วิจัย

ชื่อ-สกุล

MR.Jaratpong Tepmanee

สถานที่เกิด

Chiang Rai, Thailand

ที่อยู่ปัจจุบัน

112 No.21 Denha-Dongmada Road

Paoodonchai Sub-district , Muang District , Chiangrai, 57000

