

การพัฒนาระบบอัจฉริยะสำหรับตรวจจับการพกอาวุธของบุคคลในพื้นที่โดยเทคนิคการเรียนรู้ของเครื่องและเทคโนโลยีอินเทอร์เน็ตของสรรพสิ่ง

นายเอกคณิต ซุ้นสุวรรณ

การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตรมหาบัณฑิต
สาขาวิชาระบบสารสนเทศเพื่อการจัดการ
บัณฑิตวิทยาลัย มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
ปีการศึกษา 2568
ลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

การพัฒนาระบบอัจฉริยะสำหรับตรวจจับการพกอาวุธของบุคคลในพื้นที่โดยเทคนิคการเรียนรู้ของเครื่องและเทคโนโลยีอินเทอร์เน็ตของสรรพสิ่ง

นายเอกคณิต ซุ้นสุวรรณ



การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาหลักสูตร
วิทยาศาสตรมหาบัณฑิต
สาขาวิชาระบบสารสนเทศเพื่อการจัดการ
บัณฑิตวิทยาลัย มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
ปีการศึกษา 2568
ลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ



ใบรับรองการค้นคว้าอิสระ

บัณฑิตวิทยาลัย มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

เรื่อง การพัฒนาระบบอัจฉริยะสำหรับตรวจจับการพกอาวุธของบุคคลในพื้นที่โดยเทคนิคการเรียนรู้ของเครื่องและเทคโนโลยีอินเทอร์เน็ตของสรรพสิ่ง

โดย นายเอกคณิต ซุ้นสุวรรณ

ได้รับอนุมัติให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต
สาขาวิชาระบบสารสนเทศเพื่อการจัดการ

คณบดีคณะเทคโนโลยีสารสนเทศ
และนวัตกรรมดิจิทัล

.....

(ผู้ช่วยศาสตราจารย์ ดร.สุนันฑา สดสี)

คณะกรรมการสอบการค้นคว้าอิสระ

.....
ประธาน
(รองศาสตราจารย์ ดร.อลิสา ทรงศรีวิทยา)

.....
อาจารย์ที่ปรึกษา
(รองศาสตราจารย์ ดร.มหศักดิ์ เกตุฉ่ำ)

.....
กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.ศักดิ์ชาย ตั้งวรรณวิทย์)

ชื่อ : นายเอกคณิต ชุ้นสุวรรณ
ชื่อการค้นคว้าอิสระ : การพัฒนาระบบอัจฉริยะสำหรับตรวจจับการพกอาวุธของบุคคลในพื้นที่โดยเทคนิคการเรียนรู้ของเครื่องและเทคโนโลยีอินเทอร์เน็ตของสรรพสิ่ง
สาขาวิชา : ระบบสารสนเทศเพื่อการจัดการ
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
อาจารย์ที่ปรึกษาการค้นคว้าอิสระหลัก : รองศาสตราจารย์ ดร.มหศักดิ์ เกตุฉ่ำ
ปีการศึกษา : 2568

บทคัดย่อ

งานวิจัยนี้มุ่งพัฒนาระบบอัจฉริยะสำหรับตรวจจับการมีอยู่ของบุคคลและประเมินแนวโน้มการพกพาอาวุธในพื้นที่ โดยใช้ข้อมูลจากกล้องถ่ายภาพความร้อนและเซนเซอร์เรดาร์คลื่นมิลลิเมตรร่วมกับเทคนิค Machine Learning และ Deep Learning ภายใต้แนวคิดการลดการละเมิดความเป็นส่วนตัว

ระบบถูกออกแบบเป็นการตรวจจับ 2 ขั้นตอน โดยเริ่มจากการตรวจสอบการมีอยู่ของบุคคล แล้วจึงประเมินแนวโน้มการพกพาอาวุธเฉพาะกรณีที่พบบุคคล วิธีนี้ช่วยลดภาระการประมวลผลและลดการแจ้งเตือนผิดพลาด ข้อมูลจากเซนเซอร์ทั้งสองถูกผสานในรูปแบบข้อมูลเชิงโครงสร้าง และนำไปใช้กับแบบจำลอง Random Forest, Support Vector Machine และ XGBoost เพื่อเปรียบเทียบประสิทธิภาพ

ผลการวิจัยพบว่าระบบสามารถตรวจจับบุคคลและประเมินแนวโน้มการพกพาอาวุธได้อย่างมีประสิทธิภาพในสภาพแวดล้อมที่กำหนด การผสานข้อมูลจากกล้องความร้อนและเรดาร์ช่วยเพิ่มความน่าเชื่อถือมากกว่าการใช้เซนเซอร์เพียงชนิดเดียว อีกทั้งระบบยังสามารถทำงานแบบเรียลไทม์บนอุปกรณ์เอดจ์ได้ งานวิจัยนี้สะท้อนศักยภาพของ IoT และ Machine Learning ในการเพิ่มความปลอดภัยในพื้นที่ปิด และสามารถต่อยอดสู่การใช้งานในห้องเรียน อาคารสำนักงาน หรือพื้นที่สาธารณะได้

(มีจำนวนทั้งสิ้น 85 หน้า)

คำสำคัญ : ภาพความร้อน, การตรวจจับอาวุธ, การเรียนรู้ของเครื่อง, เรดาร์คลื่นมิลลิเมตร, อินเทอร์เน็ตของสรรพสิ่ง

_____ อาจารย์ที่ปรึกษาการค้นคว้าอิสระหลัก

Name : Mr. Ekkanit Sunsuwan
Independent Study Title : Development of an Intelligent System for Detecting Weapon-Carrying Individuals in Areas Using Machine Learning and IoT
Major Field : Management Information Systems
King Mongkut's University of Technology North Bangkok
Independent Study Advisor : Associate Professor Dr. Mahasak Ketcham
Academic Year : 2025

ABSTRACT

This research aims to develop an intelligent system for detecting human presence and assessing weapon-carrying risk in monitored areas by integrating thermal imaging and millimeter-wave radar sensors with machine learning techniques. The system follows a privacy-aware design by avoiding RGB cameras and personally identifiable visual information.

The proposed system employs a two-stage detection framework. In the first stage, human presence is identified using thermal patterns and radar-based motion data. In the second stage, the system assesses the weapon-carrying risk of detected individuals. This hierarchical approach helps reduce unnecessary computation and false alarms, supporting real-time operation.

Experimental results show that the system can effectively detect human presence and assess weapon-carrying risk under controlled conditions. Sensor fusion improves detection reliability compared with single-sensor approaches, and the system can operate in real time on resource-limited edge devices. These findings demonstrate the potential of combining IoT and machine learning to enhance security in indoor environments.

(Total 85 Pages)

Keywords: Thermal imaging, Weapon carrying detection, Machine learning, Millimeter-wave radar, Internet of Things

_____ Advisor

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยความกรุณาและการสนับสนุนจากหลายฝ่าย ผู้เขียนขอกราบขอบพระคุณ **รศ.ดร. มหศักดิ์ เกตุฉ่ำ** อาจารย์ที่ปรึกษา ที่ได้กรุณาให้คำแนะนำอย่างใกล้ชิด ให้ข้อเสนอแนะที่มีคุณค่า และสนับสนุนการดำเนินงานวิจัยในทุกขั้นตอนจนเสร็จสมบูรณ์

ขอขอบพระคุณ บริษัท KPIT Thailand สำหรับการสนับสนุนด้านเครื่องมือ ทรัพยากรที่จำเป็นต่อการทดลอง ตลอดจนคำปรึกษาเชิงเทคนิคและข้อชี้แนะที่เป็นประโยชน์อย่างยิ่งต่อการพัฒนางานวิจัยชิ้นนี้

ขอกราบขอบพระคุณสมาชิกใน **ครอบครัวซุ้นสุวรรณ** ทั้งคุณพ่อ คุณแม่ และพี่ชาย ที่คอยให้ความรัก ความเข้าใจ และเป็นกำลังใจสำคัญเสมอมา รวมถึงขอขอบคุณเพื่อน ๆ และ **บุคคลอันเป็นที่รักทุกท่าน** ที่คอยสนับสนุนและผลักดันให้ผู้เขียนมีพลังกายและใจในการผลิตผลงานชิ้นนี้จนสำเร็จ

คุณค่าและประโยชน์อันพึงมีจากงานวิจัยฉบับนี้ ผู้เขียนขอมอบเป็นเครื่องบูชาพระคุณแด่ผู้ที่มีส่วนเกี่ยวข้องทุกท่าน หากมีข้อบกพร่องประการใด ผู้เขียนขออภัยและขอน้อมรับความผิดพลาดนั้นไว้แต่เพียงผู้เดียว

เอกคณิต ซุ้นสุวรรณ

สารบัญ

หน้า

บทคัดย่อภาษาไทย ..... ข
บทคัดย่อภาษาอังกฤษ ..... ค
กิตติกรรมประกาศ ..... ง
สารบัญ ..... จ
สารบัญตาราง ..... ช
สารบัญรูปภาพ ..... ซ
บทที่ 1 บทนำ 1
1.1. ความเป็นมาและความสำคัญของปัญหา 1
1.2. วัตถุประสงค์ของการวิจัย 2
1.3. ขอบเขตของการวิจัย 2
1.4. ประโยชน์ที่คาดว่าจะได้รับ 3
บทที่ 2 ทฤษฎีและเอกสารวิจัยที่เกี่ยวข้อง 4
2.1. ประเภทสัญญาณสื่อสารสำหรับอุปกรณ์ IoT 4
2.2. การวิเคราะห์สัญญาณจากกล้องความร้อน (Thermal Sensor Analysis) 6
2.3. การวิเคราะห์สัญญาณจากเรดาร์ (Radar Sensor Analysis) 9
2.4. การแปลงข้อมูลเชิงตัวเลขเป็นภาพ (Numerical-to-Image Transformation) 11
2.5. การประยุกต์ใช้เทคโนโลยีการเรียนรู้ของเครื่อง (Machine Learning) 13
2.6. การประเมินประสิทธิภาพของระบบ (Systems Performance Evaluation) 16
2.7. สรุปงานวิจัยที่เกี่ยวข้อง 17
บทที่ 3 วิธีดำเนินงาน 21
3.1. ศึกษาและวิเคราะห์ปัญหา 21
3.2. การออกแบบระบบ (System Design) 22
3.3. การพัฒนาระบบ (System Development) 31
3.4. การประเมินผลระบบ 41
3.5. สถิติที่ใช้ในการวิเคราะห์ข้อมูล 45

สารบัญ(ต่อ)

หน้า

บทที่ 4 ผลการดำเนินงานวิจัย 48
4.1. ผลการตรวจสอบการมีอยู่ของบุคคล (Stage 1: Person Detection) 48
4.2. ผลการจำแนกแนวโน้มการพกพาอาวุธ (Stage 2: Weapon Risk Detection) 50
4.3. การวิเคราะห์ผลตามฉากการทดลอง (Scenario-Based Analysis) 53
4.4. ผลการประเมินในระดับระบบ (System-Level Evaluation) 55
4.5. อภิปรายผลการดำเนินงานวิจัย (Discussion) 56
4.6. สรุปผลการดำเนินงาน 57
บทที่ 5 สรุปผล อภิปรายผล และข้อเสนอแนะ 58
5.1. สรุปผลการวิจัย 58
5.2. อภิปรายผลการวิจัย 60
5.3. ข้อจำกัดของงานวิจัย 61
5.4. ข้อเสนอแนะสำหรับงานวิจัยในอนาคต 61
5.5. สรุปบท 62
บรรณานุกรม 64
ภาคผนวก 67
ภาคผนวก ก โครงสร้างชุดข้อมูล (Dataset Structure) 68
ภาคผนวก ข Hardware Specification และระยะการทำงานของระบบ 72
ภาคผนวก ค ตัวอย่าง Source Code ของระบบ 76
ประวัติผู้เขียน 85

สารบัญตาราง

ตารางที่ หน้า

2-1 แสดงลักษณะของความร้อนเปรียบเทียบระหว่าง สิ่งมีชีวิตและวัตถุไม่มีชีวิต 8
2-2 เปรียบเทียบเทคนิค Machine Learning ที่ใช้ในงานด้านความปลอดภัย 15
2-3 สรุปตัวชี้วัด 17
2-4 สรุปงานวิจัยที่เกี่ยวข้องด้านการตรวจจับบุคคลและการพกพาอาวุธในพื้นที่ปิด 19
3-1 โครงสร้างข้อมูลชุดข้อมูลและการกำหนดคุณลักษณะของข้อมูล 36
3-2 การเชื่อมโยงแบบจำลอง ชนิดข้อมูล และขั้นตอนการตรวจจับ 40
3-3 สถานการณ์ทดลองสำหรับการประเมินระบบ 42
3-4 การเชื่อมโยงคำถามวิจัยกับตัวชี้วัด 44
4-1 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลองใน Stage 1 48
4-2 Confusion Matrix ของ Stage 1 (XGBoost) 49
4-3 ตัวชี้วัดประสิทธิภาพรายคลาสของ Stage 1 (XGBoost) 49
4-4 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลองใน Stage 2A 51
4-5 Confusion Matrix ของ Stage 2A (XGBoost) 51
4-6 ตัวชี้วัดประสิทธิภาพรายคลาสของ Stage 2A (XGBoost) 52
4-7 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลองใน Stage 2B 52
4-8 Confusion Matrix ของ Stage 2B (Random Forest) 53
4-9 ตัวชี้วัดประสิทธิภาพรายคลาสของ Stage 2B (XGBoost) 53
4-10 ผลการประเมินประสิทธิภาพของระบบแยกตามฉากการทดลอง 54
4-11 สรุปประสิทธิภาพของระบบตรวจจับในแต่ละขั้นตอน 56

สารบัญรูปภาพ

ภาพที่ หน้า

2-1 หลักการทำงานของเรดาร์ (Radar Principle) 9

2-2 การเปรียบเทียบคุณลักษณะของเรดาร์และกล้องภาพความร้อนสำหรับงานตรวจจับในพื้นที่ปิด 11

3-1 ภาพรวมการทำงานของระบบ 22

3-2 กล้องความร้อน Thermal Sensor module 23

3-3 Redar module HLK-LD2410C 24

3-4 ESP32 WROOM-32 24

3-5 อุปกรณ์ภาพรวมของชิ้นงาน 25

3-6 การออกแบบหน้าจอแสดงผล (Dashboard) 26

3-7 การทำงานของระบบ 28

3-8 แสดงขั้นตอนการทำงานของการสื่อสารข้อมูลระหว่าง Server และ Dashboard 31

3-9 การแปลงข้อมูลอุณหภูมิเป็นรูปภาพ Heatmap 34

3-10 ตัวอย่างรูป Heatmap หลังจากทำการแปลงค่า 34

3-11 Dataset Collection Pipeline 37

3-12 ตัวอย่างการเก็บข้อมูลจากกล้องถ่ายภาพความร้อนและเซนเซอร์เรดาร์ภายใต้สถานการณ์ทดลองที่ควบคุมตัวแปร 37

3-13 ตัวอย่างอุปกรณ์จำลองที่ใช้ในการกำหนดสถานการณ์ทดลอง (ใช้เพื่อการวิจัยเท่านั้น) 43

3-14 ตัวอย่างการทดสอบตามสภาพแวดล้อมในที่มืดและมีแสง 43

ข-1 a) Top View of Sensor Detection Range
(b) Side View of Sensor Detection Range 74

บทที่ 1
บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ในยุคดิจิทัลปัจจุบัน เทคโนโลยีสารสนเทศ (Information Technology: IT) ได้เข้ามามีบทบาทสำคัญในทุกมิติของชีวิตประจำวัน โดยเฉพาะในด้านความปลอดภัยและการเฝ้าระวังภัยคุกคาม เทคโนโลยีต่าง ๆ เช่น Internet of Things (IoT), ปัญญาประดิษฐ์ (Artificial Intelligence: AI), และ Machine Learning (ML) ได้กลายเป็นเครื่องมือสำคัญที่ช่วยให้ระบบสามารถรวบรวม วิเคราะห์ และตัดสินใจในเชิงปฏิบัติได้อย่างรวดเร็วและแม่นยำ โดยไม่จำเป็นต้องอาศัยการควบคุมของมนุษย์ตลอดเวลา

ระบบเฝ้าระวังสมัยใหม่ที่ขับเคลื่อนด้วยเทคโนโลยีเหล่านี้สามารถ ตรวจจับความเคลื่อนไหว การมีอยู่ของบุคคล และพฤติกรรมผิดปกติ ได้แบบเรียลไทม์ และสามารถแจ้งเตือนผู้ดูแลหรือระบบรักษาความปลอดภัยได้ทันทีผ่านช่องทางที่หลากหลาย เช่น จอควบคุม สัญญาณเสียง หรือระบบเครือข่าย

ในบริบทของสังคมไทยและทั่วโลก ปัญหาด้านความปลอดภัยใน พื้นที่ปิด เช่น ห้องเรียน โรงเรียน อาคารสำนักงาน ห้างสรรพสินค้า สถานีขนส่ง และสถานที่ราชการ กลายเป็นประเด็นที่ได้รับความสนใจมากขึ้น เนื่องจากมีแนวโน้มเกิดเหตุการณ์ที่มีบุคคล พกพาอาวุธหรือวัตถุอันตรายเข้าไปในพื้นที่สาธารณะโดยเจตนาแอบแฝง ซึ่งส่งผลให้เกิดความเสียหายทั้งต่อชีวิตและทรัพย์สิน ตัวอย่างเหตุการณ์สำคัญที่เกิดขึ้นในประเทศไทย ได้แก่

- เหตุกราดยิงที่ห้างสรรพสินค้า Terminal 21 จังหวัดนครราชสีมา ปี 2563 ส่งผลให้มีผู้เสียชีวิตและบาดเจ็บจำนวนมาก
- เหตุยิงในห้างสรรพสินค้าสยามพารากอน ปี 2566 ซึ่งสร้างความตื่นตระหนกและสูญเสียในวงกว้าง
- เหตุการณ์คล้ายคลึงกันที่เกิดขึ้นซ้ำ ๆ ในโรงเรียน สถานีรถไฟฟ้า และสถานที่ราชการทั้งในและต่างประเทศ

เหตุการณ์เหล่านี้ตอกย้ำถึงความจำเป็นในการมี ระบบเฝ้าระวังอัจฉริยะ ที่สามารถตรวจจับบุคคลที่เข้ามาในพื้นที่ คัดกรองพฤติกรรมที่เสี่ยง และทำการแจ้งเตือนในทันที ซึ่งหากพึ่งพาเพียงระบบกล้องวงจรปิดแบบดั้งเดิม อาจไม่สามารถตอบสนองต่อเหตุการณ์ได้อย่างรวดเร็ว หรือไม่สามารถวิเคราะห์พฤติกรรมที่ซับซ้อนได้ ด้วยเหตุนี้ การนำเทคโนโลยีสารสนเทศมาประยุกต์ใช้ เช่น

- การติดตั้งเซนเซอร์ IoT เพื่อตรวจจับการเคลื่อนไหวและความร้อนของบุคคล
- การใช้ AI/ML วิเคราะห์รูปแบบพฤติกรรมจากข้อมูลที่ได้จากเซนเซอร์

- การเชื่อมต่อข้อมูลกับระบบ Cloud หรือเครือข่ายภายในเพื่อแจ้งเตือนแบบทันที

จึงเป็นแนวทางสำคัญที่ช่วยให้สามารถ คาดการณ์ ป้องกัน และตอบสนองต่อเหตุการณ์ความไม่ปลอดภัยได้อย่างมีประสิทธิภาพ

ระบบที่สามารถทำงานแบบอัตโนมัติผ่านอุปกรณ์ขนาดเล็ก เช่น ESP32 ควบคู่กับเซนเซอร์ MLX90640 (ตรวจจับภาพความร้อน) และ LD2410 (เรดาร์ตรวจจับการเคลื่อนไหว) จะช่วยให้การติดตั้งและใช้งานในพื้นที่หลากหลายเป็นไปได้อย่างสะดวกและยืดหยุ่น โดยเฉพาะเมื่อออกแบบให้มีการแจ้งเตือนผ่านอุปกรณ์แสดงผล เสียง หรือไฟ ทำให้สามารถใช้งานได้จริงในสถานการณ์หลากหลาย เช่น ห้องเรียน สำนักงาน ห้องประชุม หรือพื้นที่ที่ต้องการรักษาความปลอดภัยสูง

ดังนั้น การพัฒนาและวิจัยระบบตรวจจับภัยคุกคามในพื้นที่ปิด โดยใช้เทคโนโลยี IT, IoT และ AI จึงเป็นเรื่องจำเป็นอย่างยิ่ง ทั้งในเชิงวิชาการและเชิงปฏิบัติ เพื่อรับมือกับความท้าทายด้านความปลอดภัยของสังคมในอนาคต

1.2 วัตถุประสงค์ของการวิจัย

1.2.1 เพื่อพัฒนาระบบตรวจจับการมีอยู่ของบุคคลในพื้นที่ปิด โดยใช้เซนเซอร์ตรวจจับอุณหภูมิและการเคลื่อนไหวอย่างแม่นยำ เพื่อเป็นพื้นฐานในการวิเคราะห์พฤติกรรมที่ผิดปกติหรือมีความเสี่ยง

1.2.2 เพื่อออกแบบและประยุกต์ใช้เทคนิค Machine Learning ในการวิเคราะห์ข้อมูลจากเซนเซอร์ เพื่อลดอัตราการแจ้งเตือนผิดพลาด (False Alarm) และสามารถจำแนกพฤติกรรมที่อาจบ่งชี้ถึงการพกพาอาวุธหรือภัยคุกคามอื่น ๆ ได้อย่างมีประสิทธิภาพ

1.2.3 เพื่อทดสอบและประเมินประสิทธิภาพของระบบภายใต้สถานการณ์จำลองที่ใกล้เคียงกับการใช้งานจริง เช่น ห้องเรียน อาคารสำนักงาน หรือพื้นที่สาธารณะอื่น ๆ

1.3 ขอบเขตของการวิจัย

งานวิจัยนี้มุ่งเน้นการพัฒนา ระบบตรวจจับและแจ้งเตือนความเสี่ยงในพื้นที่ปิด โดยใช้เทคโนโลยี Internet of Things (IoT) ร่วมกับ Machine Learning เพื่อตรวจจับพฤติกรรมที่อาจบ่งชี้ถึงภัยคุกคาม เช่น การพกพาอาวุธ โดยระบบจะทำการแจ้งเตือนผ่านอุปกรณ์ควบคุมภายในพื้นที่ เช่น หน้าจอแสดงผล หรือไฟแจ้งเตือน ผู้วิจัยได้กำหนดขอบเขตของการวิจัยไว้ดังนี้

1.3.1 ศึกษากระบวนการแปลงข้อมูลจากเซนเซอร์ในแต่ละส่วน เพื่อใช้ในการจำแนกและตรวจสอบว่ามีการพกพาอาวุธเข้ามาในพื้นที่หรือไม่

1.3.2 พัฒนาระบบต้นแบบสำหรับการตรวจจับบุคคลและประเมินความเสี่ยงของการพกพาอาวุธ โดยใช้เทคนิค Machine Learning ได้แก่ Random Forest, Extra Trees, Support Vector Machine (SVM) และ XGBoost เพื่อจำแนกข้อมูลจากเซนเซอร์ โดยระบบถูกออกแบบให้ทำงานแบบหลายขั้นตอน (Hierarchical Detection) ประกอบด้วย

1.3.3 ทดสอบและประเมินประสิทธิภาพของระบบต้นแบบโดยใช้ข้อมูลที่เก็บจากการทดลองกับบุคคลจริงในพื้นที่ปิด ภายใต้สถานการณ์ที่แตกต่างกัน เช่น การเดินผ่านพื้นที่ การยืนอยู่กับที่ และการพกพาอาวุธประเภทต่าง ๆ โดยประเมินผลด้วยตัวชี้วัด ได้แก่ Accuracy, Precision, Recall และ F1-Score เพื่อวิเคราะห์ความสามารถของระบบในการตรวจจับและจำแนกภัยคุกคามได้อย่างมีประสิทธิภาพ

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1.4.1 ได้รับต้นแบบระบบอัจฉริยะที่สามารถตรวจจับการมีอยู่ของบุคคลในพื้นที่ปิดได้อย่างแม่นยำ ระบบสามารถประยุกต์ใช้ในพื้นที่ที่ต้องการความปลอดภัยสูง เช่น ห้องเรียน หรือ อาคารสำนักงาน

1.4.2 สามารถประเมินและยืนยันประสิทธิภาพของระบบในสถานการณ์ใกล้เคียงความเป็นจริง

พระจอมเกล้าพระนครเหนือ มหาวิทยาลัยเทคโนโลยี

บทที่ 2
ทฤษฎีและเอกสารวิจัยที่เกี่ยวข้อง

บทนี้นำเสนอกรอบความรู้พื้นฐาน แนวคิด และองค์ประกอบทางเทคนิคที่เกี่ยวข้องกับการพัฒนา ระบบอัจฉริยะสำหรับตรวจจับการพกพาอาวุธของบุคคลในพื้นที่ โดยบูรณาการเทคโนโลยีการเรียนรู้ของเครื่อง (Machine Learning) และ อินเทอร์เน็ตของสรรพสิ่ง (Internet of Things) องค์ความรู้ดังกล่าวถูกนำไปใช้ในการออกแบบสถาปัตยกรรมระบบ กำหนดกระบวนการประมวลผลข้อมูล วางแผนการทดลอง ตลอดจนตีความผลลัพธ์ของการวิจัย ทั้งนี้ บทนี้ประกอบด้วยหัวข้อสำคัญดังต่อไปนี้

2.1 ประเภทสัญญาณสื่อสารสำหรับอุปกรณ์ IoT
2.2 การวิเคราะห์สัญญาณจากกล้องความร้อน (Thermal Sensor Analysis)
2.3 การวิเคราะห์สัญญาณจากเรดาร์ (Radar Sensor Analysis)
2.4 การแปลงข้อมูลเชิงตัวเลขเป็นภาพ (Numerical-to-Image Transformation)
2.5 การประยุกต์ใช้เทคโนโลยีการเรียนรู้ของเครื่อง (Machine Learning)
2.6 การประเมินประสิทธิภาพของระบบ (Systems Performance Evaluation)
2.7 สรุปงานวิจัยที่เกี่ยวข้อง

2.1 ประเภทสัญญาณสื่อสารสำหรับอุปกรณ์ IoT

เทคโนโลยี IoT คือการเชื่อมต่อระหว่างอุปกรณ์อัจฉริยะ (Smart Devices) ผ่านเครือข่ายเพื่อแลกเปลี่ยนข้อมูลแบบอัตโนมัติ โดยอาศัยระบบสื่อสารข้อมูลและโพรโทคอลมาตรฐาน เช่น Wi-Fi, Bluetooth, ZigBee, LoRa และ MQTT ซึ่งช่วยให้เกิดการตรวจจับ (Sensing), การประมวลผล (Processing), และการสื่อสาร (Communication) แบบ End-to-End[1][2]

สถาปัตยกรรม IoT โดยทั่วไปประกอบด้วย 3 ชั้น ได้แก่

- ชั้นรับรู้ (Perception Layer): ประกอบด้วยเซนเซอร์ เช่น กล้องความร้อน MLX90640, เรดาร์ HLK-LD2410 และไมโครคอนโทรลเลอร์ (ESP32)
- ชั้นเครือข่าย (Network Layer): ใช้โพรโทคอลสื่อสาร UART, I²C, Wi-Fi เพื่อส่งข้อมูลระหว่างอุปกรณ์
- ชั้นประยุกต์ (Application Layer): เป็นส่วนของระบบวิเคราะห์และ Machine Learning ที่ประมวลผลข้อมูลเพื่อแสดงผลหรือแจ้งเตือน

การสื่อสารข้อมูลในระบบ IoT มักอยู่ในรูปแบบ Serial Communication ซึ่งเป็นการส่งข้อมูลแบบบิตต่อบิตผ่านเส้นทางเดียว ทำให้เหมาะสำหรับไมโครคอนโทรลเลอร์ เช่น ESP32 ที่ต้องเชื่อมต่อกับอุปกรณ์หลายชนิดในพื้นที่จำกัด โดยรูปแบบที่ใช้ทั่วไป ได้แก่ UART และ I²C

2.1.1 การสื่อสารแบบ UART (Universal Asynchronous Receiver/Transmitter)

UART เป็นการสื่อสารแบบอนุกรม (Asynchronous Serial Communication) ที่ไม่ต้องใช้สัญญาณนาฬิกา (Clock Signal) ร่วมระหว่างอุปกรณ์ โดยแต่ละอุปกรณ์จะกำหนดความเร็วในการส่งข้อมูล (Baud Rate) ที่เท่ากัน เช่น 115200 หรือ 256000 bps

ข้อมูลจะถูกส่งเป็นเฟรม (Frame) ซึ่งประกอบด้วย

- Start Bit (1 บิต)
- Data Bits (เช่น 8 บิต)
- Optional Parity Bit (ตรวจสอบความถูกต้อง)
- Stop Bit (1–2 บิต)

สมการความเร็วในการส่งข้อมูล UART

$$T_{bit} = \frac{1}{Baud\ Rate} \tag{2-1}$$

เช่น หาก Baud Rate = 256,000 bps จะใช้เวลา 3.9 µs ต่อบิต

2.1.2 การสื่อสารแบบ I²C (Inter-Integrated Circuit)

I²C เป็นการสื่อสารแบบซิงโครนัส (Synchronous Serial Communication) โดยใช้สายสัญญาณเพียง 2 เส้น คือ

- SDA (Serial Data) สำหรับรับ–ส่งข้อมูล
- SCL (Serial Clock) สำหรับสัญญาณนาฬิกา

ข้อมูลจะถูกส่งตามโพรโทคอลแบบ Master–Slave โดยอุปกรณ์ Master (ESP32) จะควบคุมการส่งข้อมูลไปยังอุปกรณ์ Slave แต่ละตัวผ่าน Address เฉพาะ (7 หรือ 10 บิต)

สมการเวลาการส่งข้อมูล I²C

$$T_{total} = (N_{bits} + N_{ack}) \times \frac{1}{f_{SCL}} \tag{2-2}$$

โดยที่ $\frac{1}{f_{SCL}}$ คือความถี่นาฬิกา (เช่น 100 kHz หรือ 400 kHz)

อย่างไรก็ตามการเลือกสัญญานที่ใช้ควรเลือกให้เหมาะสมกับอุปกรณ์และความเร็วที่ต้องการ เพื่อให้ Hardware ทำงานได้อย่างมีประสิทธิภาพ

2.2 การวิเคราะห์สัญญาณจากกล้องความร้อน (Thermal Sensor Analysis)

การศึกษาการทำงานของกล้องความร้อนเป็นการทำงานบนหลักการแผ่รังสีอินฟราเรดของวัตถุ (Black-body radiation) จับค่าความแตกต่างของอุณหภูมิผิวและสภาพแวดล้อม โดย เป็นการตรวจสอบวัตถุที่แผ่รังสีอินฟาเรดตามอุณหภูมิพื้นผิว ตามกฎของสเตฟาน–โบลท์ซมัน (Stefan–Boltzmann law) ซึ่งอธิบายว่าร่างกายดำ (Blackbody) จะคายพลังงานความร้อนด้วยกำลังไฟฟ้าต่อหน่วยพื้นที่แปรผันตามอุณหภูมิยกกำลังสี่[3], [4] ซึ่งมีสมการ การคำนวณคือ

$$j = \sigma T^4 \tag{2-3}$$

โดยนิยามตัวแปร

j คือ กำลังแผ่รังสีต่อหน่วยพื้นที่ ($W.m^{-2}$)

T คือ อุณหภูมิสัมบูรณ์ (K)

σ คือ ค่าคงที่สเตฟาน–โบลท์ซมัน $\approx 5.670374419x10^{-8} W \cdot m^{-2} \cdot K^{-4}$

ในการปฏิบัติจริง เซนเซอร์ความร้อนจะอ่าน “ค่าสัญญาณดิบรายพิกเซล” แล้วแปลงเป็นอุณหภูมิจริง(Radiometric Conversion) ผ่านค่าคงที่สอบเทียบ (Calibration constants) และอัลกอริทึมชดเชยความไม่สม่ำเสมอของพิกเซล (Non-uniformity correction) ตลอดจนการชดเชยค่าการแผ่รังสีของผิววัตถุ (Emissivity) และอิทธิพลของอุณหภูมิ/การสะท้อนจากฉากแวดล้อม

การปรับอุณหภูมิให้คำนึงถึงอีมิสซิวิตี (ε) และการสะท้อนจากสภาพแวดล้อมทำได้ด้วยสมการ

$$T_{ture} = \left(\frac{T_{app}^4 - (1-\varepsilon)T_{env}^4}{\varepsilon}\right)^{1/4} \tag{2-4}$$

โดยนิยามตัวแปร

ε คือ สัมประสิทธิ์การแผ่รังสีของผิววัตถุ (มักอยู่ในช่วง 0.90–0.98 สำหรับผิวที่ไม่เป็นโลหะด้าน)

T_{env} คือ อุณหภูมิฉากหรืออากาศโดยรอบที่สะท้อนเข้ากล้อง

T_{app} คือ อุณหภูมิที่คำนวณได้จากสัญญาณที่เซนเซอร์วัดได้ก่อนชดเชยอีมิสซิวิตีและฉาก (K)

T_{true} คือ อุณหภูมิที่คำนวณได้จากสัญญาณที่วัดได้ก่อนชดเชยอีมิสซิวิตีและฉาก (K)

ชี้งอุณภูมิที่ได้จะต้องเป็นหน่วยจะอยู่ในหน่วยเคลวิน (K) และการตั้งค่า ε ต้องให้สอดคล้องกับวัสดุผิวจริงมีผลอย่างมากต่อความถูกต้อง เช่น ผิวโลหะเงาจะมี ε ต่ำกว่าผิวด้าน/ฉนวน และยังต้องคึงตัวแปรกวนที่มีผลกระทบทำให้เกิดค่าความผิดปกติ เช่น อุณหภูมิห้อง, กระแสลม, วัตถุโลหะที่นำความร้อนเร็ว, การบังทัศนวิสัย ซึ่งเราสามารถำข้อมูลเหล่านี้มาวิเคราะห์หาช่วงความแตกต่างของแต่ละพื้นที่เพื่อจำแนกวัตุ หรือ สิ่งของในบริเวณนั้นๆ

2.2.1 ความแปรผันเชิงชีวภาพของอุณหภูมิ

อุณหภูมิของสิ่งมีชีวิตแตกต่างกันตามชนิด การเผาผลาญพลังงาน (Metabolism) และความสามารถในการควบคุมอุณหภูมิ (Endotherm/Ectotherm) สำหรับมนุษย์ แม้อุณหภูมิแกนกลางใกล้เคียงกันระหว่างบุคคล แต่อุณหภูมิ “ผิวหนัง” แตกต่างตามกายวิภาคและสรีรวิทยา เช่น การไหลเวียนเลือด ความหนาชั้นไขมัน การระเหยเหงื่อ และการสัมผัสสภาพแวดล้อม ส่งผลให้บริเวณใบหน้า (เช่น รอบตา จมูก ริมฝีปาก) มักอุ่นกว่า ขณะที่ปลายมือ–ปลายเท้ามักเย็นกว่า ความแตกต่างนี้มีทั้ง ภายในบุคคล (Intra-individual variation) และ ระหว่างบุคคล (Inter-individual variation) และยังแปรตามเวลา (เช่น ระหว่างพัก–ออกแรง หรือขณะเกิดความเครียด)

นัยต่อการวิเคราะห์ภาพความร้อนของมนุษย์

- ควรกำหนดค่า ε สำหรับผิวหนังให้เหมาะสม (ปกติสูง ~0.97–0.99)
- เลือกบริเวณสนใจ (ROI) ให้สอดคล้องกับกายวิภาค—เช่น ROI ใบหน้า/ลำตัวให้ข้อมูลมากกว่าค่าเฉลี่ยทั้งร่าง
- พิจารณาปัจจัยเวลา การเปลี่ยนแปลงตามกิจกรรม การหายใจ และการไหลเวียนเลือด

ลักษณะอุณหภูมิในวัตถุไม่มีชีวิต

วัตถุไม่มีชีวิตไม่มีเมตาบอลิซึมและกลไกควบคุมอุณหภูมิภายใน อุณหภูมิจึงถูกกำหนดโดยแหล่งความร้อนภายนอก สมดุลการนำ–การพา–การแผ่รังสี และคุณสมบัติวัสดุ (ความจุความร้อน การนำความร้อน ผิวเงาหรือผิวด้าน) ความแปรผันเชิงพื้นที่มักสะท้อนโครงสร้างวิศวกรรม เช่น จุดกำเนิดความร้อนของวงจรไฟฟ้า ครีบระบายความร้อน ฉนวน และจุดสัมผัสโลหะ

นัยต่อการวิเคราะห์ภาพความร้อนของวัตถุ

- ค่า **ε** แตกต่างกว้างมาก: จากผิวด้าน/โพลิเมอร์ (~0.9–0.98) ไปจนโลหะเงา (ต่ำ ~0.02–0.2) ซึ่งสะท้อน IR สูงและทำให้วัดพลาดได้ง่าย
- การเปลี่ยนแปลงตามเวลาขึ้นกับมวล ความจุความร้อน และการถ่ายเทความร้อนของชิ้นงาน บ่อยครั้ง “ช้ากว่า” สิ่งมีชีวิต

ตารางที่ 2-1 แสดงลักษณะของความร้อนเปรียบเทียบระหว่าง สิ่งมีชีวิตและวัตถุไม่มีชีวิต

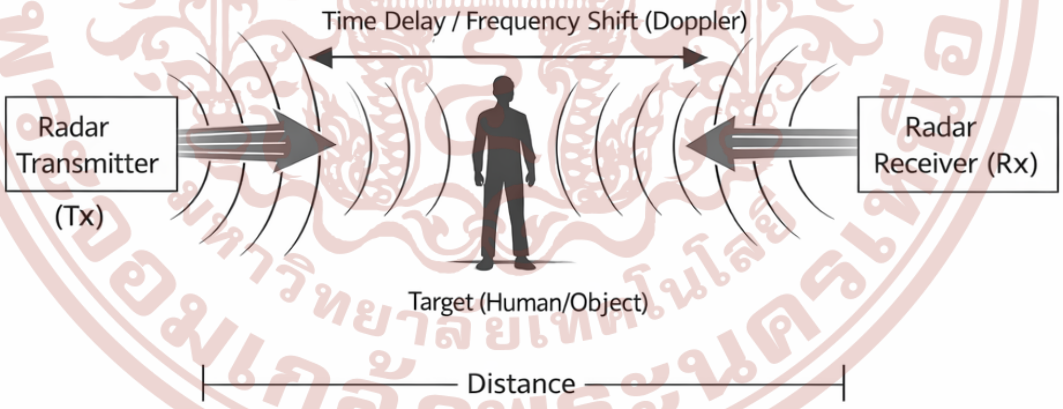
มิติเปรียบเทียบ	สิ่งมีชีวิต (เช่น มนุษย์)	วัตถุไม่มีชีวิต
แหล่งความร้อน	ภายใน (เมตาบอลิซึม) + ควบคุมด้วยสรีรวิทยา	ภายนอก (แสง/ไฟฟ้า/การเสียดทาน)
แพทเทิร์นเชิงพื้นที่	สอดคล้องกายวิภาค: ใบหน้า/ลำตัวอุ่นกว่าปลายมือ–เท้า	ฮอตสปอตที่ภาคจ่ายไฟ ครีบระบาย
การเปลี่ยนแปลงตามเวลา	เร็ว/มีจังหวะ (หายใจ ไหลเวียน เหงื่อ)	ตามมวล/ฉนวน/การนำความร้อน มักค่อยเป็นค่อยไป
Emissivity (**ε**)	สูงและสม่ำเสมอ (~0.97–0.99)	กระจายกว้าง โลหะเงาต่ำมาก (0.02–0.2)
ความเสี่ยงการสะท้อน IR	ต่ำ (ผิวด้าน)	สูงในผิวเงา/โลหะจะเกิด “ภาพสะท้อนฉาก”
วิธีลดอคติ	เลือก ROI ตามสรีรวิทยา/คุมสภาวะ	ตั้งค่า **ε** ตามวัสดุ/ติดเทปดำด้านเป็นจุดอ้างอิง

สิ่งมีชีวิตและวัตถุไม่มีชีวิตแสดงพลวัตอุณหภูมิที่ต่างกันอย่างเป็นระบบ ทั้งแหล่งกำเนิดความร้อน รูปแบบการกระจายเชิงพื้นที่ อัตราการเปลี่ยนตามเวลา และค่าสัมประสิทธิ์การแผ่รังสี ความเข้าใจความแตกต่างเหล่านี้ทำให้การตั้งค่ากล้อง การชดเชยทางรังสี–ฉาก และการออกแบบอัลกอริทึมจำแนก/ตรวจจับ มีความแม่นยำและทนทานยิ่งขึ้น โดยเฉพาะในงานด้านความปลอดภัยและการเฝ้าระวังในพื้นที่ปิดที่ต้องแยก “คน” ออกจาก “วัตถุร้อน” อย่างเชื่อถือได้

2.3 การวิเคราะห์สัญญาณจากเรดาร์ (Radar Sensor Analysis)

เรดาร์ (RADAR: Radio Detection and Ranging) เป็นเทคโนโลยีการตรวจจับระยะไกลที่อาศัยหลักการส่งคลื่นวิทยุไปยังวัตถุเป้าหมายและวิเคราะห์สัญญาณสะท้อนกลับ เพื่อนำมาประเมินคุณลักษณะสำคัญ ได้แก่ ระยะทาง (Range) ความเร็วเชิงรัศมี (Radial Velocity) มุมของการมาถึงของสัญญาณ (Angle of Arrival) และรูปแบบการเคลื่อนไหวเชิงละเอียด (Micro-Doppler Signature) คุณสมบัติเหล่านี้ทำให้เรดาร์ถูกนำมาใช้อย่างแพร่หลายในงานด้านความปลอดภัย การเฝ้าระวัง และระบบอัจฉริยะภายในอาคาร

ในช่วงไม่กี่ปีที่ผ่านมา เรดาร์ย่านคลื่นมิลลิเมตร (Millimeter-Wave Radar: mmWave) ซึ่งทำงานในช่วงความถี่ประมาณ 24–60 GHz ได้รับความสนใจเพิ่มขึ้นอย่างมาก เนื่องจากมีขนาดเสาอากาศเล็ก ให้ความละเอียดเชิงระยะสูง และสามารถทำงานได้ดีในสภาพแวดล้อมที่แสงน้อย มีควัน หรือมีสิ่งบดบัง ซึ่งเป็นข้อจำกัดของระบบกล้องแบบดั้งเดิม คุณสมบัติดังกล่าวทำให้ mmWave radar เหมาะสมอย่างยิ่งสำหรับการตรวจจับการมีอยู่ของบุคคลและการเคลื่อนไหวในพื้นที่ปิด เช่น อาคารสำนักงาน ห้องเรียน หรือสถานที่สาธารณะ [5], [6], [7]



ภาพที่ 2-1 หลักการทำงานของเรดาร์ (Radar Principle)

หลักการพื้นฐานของเรดาร์สามารถอธิบายได้จากสมการเรดาร์ (Radar Equation) ซึ่งแสดงความสัมพันธ์ระหว่างกำลังส่งและกำลังรับของสัญญาณสะท้อน ดังสมการ

$$P_r = \frac{P_t G_t G_r \lambda^2 \sigma}{(4\pi)^3 R^4 L} \quad (2\text{-}5)$$

โดยนิยามตัวแปร

P_t คือ กำลังส่ง

G_t, G_r คือ อัตราขยายเสาอากาศส่ง/รับ,

λ คือ ความยาวคลื่น

σ คือ Radar Cross Section (RCS), RR

R คือ ระยะเป้าหมาย

L คือ การสูญเสียรวม

จากสมการดังกล่าวจะเห็นได้ว่ากำลังสัญญาณที่รับได้ลดลงตามระยะทางยกกำลังสี่(R^{-4})ซึ่งเป็นข้อจำกัดสำคัญของเรดาร์ โดยเฉพาะในงานตรวจจับวัตถุขนาดเล็กหรือวัตถุที่มีค่า RCS ต่ำ เช่น อาวุธที่ถูกซ่อนอยู่ใต้เสื้อผ้า

เพื่อให้การตรวจจับมีความน่าเชื่อถือมากขึ้น จำเป็นต้องพิจารณาอัตราส่วนสัญญาณต่อสัญญาณรบกวน (Signal-to-Noise Ratio: SNR) ซึ่งสามารถประมาณได้จาก

$$SNR = \frac{P_r}{kTBF} \quad (2\text{-}6)$$

โดยนิยามตัวแปร

k คือ ค่าคงที่ของโบลต์ซมัน

T คือ อุณหภูมิของระบบ

B คือ แบนด์วิดท์ของตัวรับ

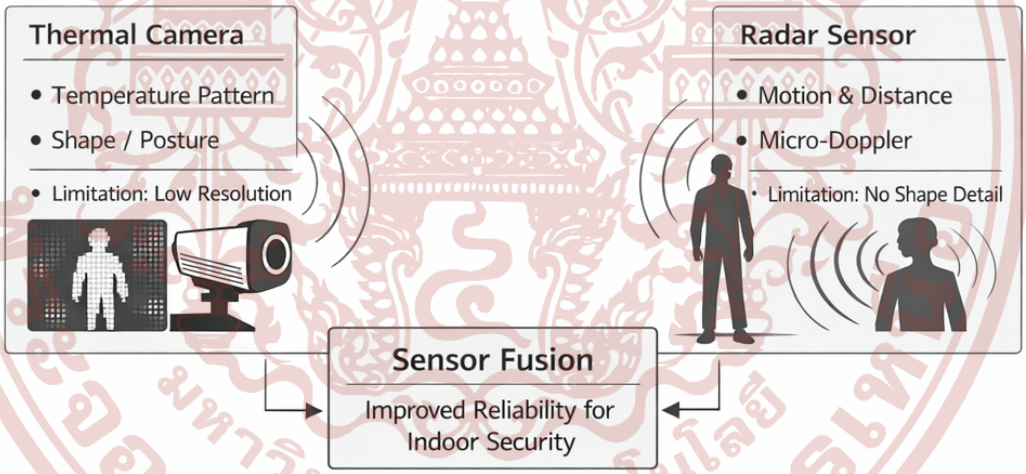
F คือ Noise Figure

ค่า SNR มีบทบาทสำคัญต่อความสามารถของระบบในการแยกแยะสัญญาณการเคลื่อนไหวของมนุษย์ออกจากสัญญาณรบกวนของสภาพแวดล้อม ในงานวิจัยด้านการเฝ้าระวังภายในอาคาร เรดาร์ mmWave มักถูกนำมาใช้เพื่อการตรวจจับการมีอยู่ของบุคคล (Human Presence Detection) และการวิเคราะห์รูปแบบการเคลื่อนไหว เนื่องจากสามารถตรวจจับการเคลื่อนไหวขนาดเล็ก เช่น การขยับตัวหรือการหายใจได้ผ่านปรากฏการณ์ Doppler และ Micro-Doppler ซึ่งสะท้อนลักษณะการเคลื่อนไหวเฉพาะของมนุษย์ อย่างไรก็ตาม แม้เรดาร์จะมีความสามารถสูงในการตรวจจับ

การเคลื่อนไหวและระยะทาง แต่ยังมีข้อจำกัดในการให้ข้อมูลเชิงรูปร่างและโครงสร้างของวัตถุ ทำให้ยากต่อการแยกแยะประเภทของวัตถุหรืออุปกรณ์ที่บุคคลพกพาอยู่

ในบริบทของการตรวจจับอาวุธ ข้อมูลจากเรดาร์เพียงอย่างเดียวอาจไม่เพียงพอ เนื่องจากอาวุธหลายประเภทมีขนาดเล็กและอาจไม่ก่อให้เกิดรูปแบบสัญญาณที่แตกต่างอย่างชัดเจนจากวัตถุทั่วไป อย่างไรก็ตาม เรดาร์สามารถให้ข้อมูลเสริมที่สำคัญ เช่น ความผิดปกติของรูปแบบการเคลื่อนไหว การเปลี่ยนแปลงพลังงานสะท้อนในแต่ละช่วงระยะ หรือรูปแบบ Micro-Doppler ที่สัมพันธ์กับการพกพาวัตถุแข็งหรือโลหะ

ดังนั้น งานวิจัยจำนวนมากจึงเสนอแนวทางการผสานข้อมูลจากเรดาร์ร่วมกับเซนเซอร์ประเภทอื่น เช่น กล้องภาพความร้อนหรือกล้องความลึก เพื่อเพิ่มความแม่นยำและความน่าเชื่อถือของระบบตรวจจับ การใช้เรดาร์เป็นแหล่งข้อมูลด้านการเคลื่อนไหวและระยะทาง ควบคู่กับข้อมูลเชิงพื้นที่จากภาพความร้อน ช่วยลดข้อจำกัดของเซนเซอร์แต่ละชนิดและสนับสนุนการพัฒนาระบบตรวจจับอัจฉริยะที่เหมาะสมต่อการใช้งานจริงในพื้นที่ปิด



ภาพที่ 2-2 การเปรียบเทียบคุณลักษณะของเรดาร์และกล้องภาพความร้อนสำหรับงานตรวจจับในพื้นที่ปิด

2.4 การแปลงข้อมูลเชิงตัวเลขเป็นภาพ (Numerical-to-Image Transformation)

การแปลงข้อมูลเชิงตัวเลขให้มีรูปแบบเป็นภาพ (Numerical-to-image transformation) เป็นกระบวนการที่มุ่งเปลี่ยนข้อมูลซึ่งอยู่ในรูป สเกลาร์ (Scalar), เวกเตอร์ (Vector) หรือ เมทริกซ์ (Matrix) ให้กลายเป็นสัญญาณภาพสองมิติหรือสามมิติ เพื่อให้สามารถมองเห็น “โครงสร้างเชิงรูปแบบ” (patterns) ที่ซ่อนอยู่ในข้อมูลเดิมได้ชัดเจนขึ้น ทั้งในมุมของมนุษย์ (visual analytics) และในมุมของการเรียนรู้ของเครื่อง โดยเฉพาะโมเดลด้านคอมพิวเตอร์วิทัศน์ เช่น Convolutional

Neural Network (CNN) หรือ Vision Transformer (ViT) ซึ่งสามารถสกัดคุณลักษณะเชิงพื้นที่ได้อย่างมีประสิทธิภาพ[4]

ในงานด้าน IoT และระบบตรวจจับอาวุธ ข้อมูลจากเซนเซอร์ต่าง ๆ เช่น กล้องถ่ายภาพความร้อน MLX90640 (ความละเอียด 32×24 พิกเซล) และเรดาร์คลื่นมิลลิเมตร (mmWave) มักอยู่ในรูปเมทริกซ์ตัวเลขดิบ ไม่ใช่ภาพถ่ายโดยตรง จึงจำเป็นต้องมีกระบวนการแปลงข้อมูลดังกล่าวให้เป็นภาพหรือแผนที่ความเข้ม (heatmap) เพื่อใช้ในการแสดงผล วิเคราะห์ และป้อนเข้าสู่ขั้นตอนการเรียนรู้ของเครื่อง กระบวนการหลักประกอบด้วยดังนี้

2.4.1 การทำให้เป็นมาตรฐาน (Normalization)

เพื่อกำจัดผลกระทบของสเกลที่ต่างกันระหว่างเฟรมหรือเซนเซอร์ ข้อมูลตัวเลขดิบ XXX จะถูกปรับให้อยู่ในช่วง [0,1][0,1][0,1] หรือ [−1,1][-1,1][−1,1] ผ่านวิธีการต่าง ๆ เช่น Min–Max Normalization

สูตร Min–Max Normalization

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (2\text{-}7)$$

สูตรนี้ทำให้ข้อมูลภาพสามารถนำไปวิเคราะห์ข้ามเฟรม หรือใช้เป็น input ให้กับโมเดล ML/DL ได้อย่างมีเสถียรภาพมากขึ้น

2.4.2 การปรับความละเอียด (Interpolation / Resampling)

ภาพจากเซนเซอร์ความร้อนซึ่งมีความละเอียดต่ำ (32×24พิกเซล) มักต้องถูกขยายให้มีความละเอียดสูงขึ้น เช่น 96×72 หรือ 320×240 เพื่อให้เหมาะกับการสกัดลักษณะเชิงพื้นที่โดย CNN

วิธีทั่วไปในการประมาณค่าพิกเซลใหม่ ได้แก่ Bilinear Interpolation

$$I_{(x,y)} = (1-a)(1-b)I_{00} + a(1-b)I_{10} + (1-a)bI_{01} + abI_{11} \quad (2\text{-}8)$$

โดยนิยามตัวแปร

a คือ x - |x|

b คือ y - |y|

I_{ij} คือ ความเข้มพิกเซลรอบจุดที่ต้องการประมาณ

วิธีนี้ช่วยให้ภาพมีความต่อเนื่องและลื่นไหลมากขึ้น เหมาะสำหรับแสดงผลแบบเรียลไทม์

2.4.3 การแมปสี (Color Mapping)

เป็นการแปลงค่าความเข้ม (intensity) หรืออุณหภูมิให้เป็นสีตามโครงร่างของ Colormap เช่น Jet, Inferno, Grayscale

ถ้า P คือค่าความเข้ม Normalized ค่า RGB สามารถเขียนเป็นฟังก์ชันของ P

$$(R, G, B) = f(P) \tag{2-9}$$

การแมปสีช่วยให้มองเห็นจุดร้อน–จุดเย็น รูปร่างของร่างกายมนุษย์ และความผิดปกติได้ชัดเจนกว่าภาพ grayscale ล้วน ๆ

2.4.4 การลดสัญญาณรบกวน (Denoising)

ข้อมูลจากเซนเซอร์มักมี Noise จึงต้องมีการกรองก่อนสร้างภาพ

Median Filter

$$I'(x, y) = median(N(x, y)) \tag{2-10}$$

Gaussian Filter

$$I'(x, y) = \sum_i \sum_j I(i, j) \cdot G_\sigma(x - i, y - j) \tag{2-11}$$

Temporal Smoothing

ใช้ค่าเฉลี่ยเคลื่อนที่ของหลายเฟรม

$$I'_t = \propto I_t + (1 - \propto) I_{t-1} \tag{2-12}$$

ซึ่งจะช่วยลดความสั่นไหวของภาพเมื่อทำงานแบบ real-time

2.5 การประยุกต์ใช้เทคโนโลยีการเรียนรู้ของเครื่อง (Machine Learning)

การเรียนรู้ของเครื่อง (Machine Learning: ML) เป็นแขนงหนึ่งของปัญญาประดิษฐ์ที่มุ่งเน้นการพัฒนาแบบจำลองที่สามารถเรียนรู้รูปแบบและความสัมพันธ์จากข้อมูลได้โดยอัตโนมัติ โดยไม่จำเป็นต้องกำหนดกฎเกณฑ์อย่างชัดเจนล่วงหน้า เทคโนโลยีดังกล่าวถูกนำมาใช้อย่างแพร่หลายใน

งานด้านความปลอดภัยและการเฝ้าระวัง (security and surveillance) เพื่อช่วยวิเคราะห์ข้อมูลจากเซนเซอร์และจำแนกสถานการณ์ที่มีความเสี่ยงจากข้อมูลจำนวนมากที่มีความซับซ้อน

ในบริบทของระบบตรวจจับบุคคลและการพกพาอาวุธ ข้อมูลที่นำมาใช้ในการวิเคราะห์มักมาจากเซนเซอร์หลายประเภท เช่น กล้องภาพความร้อนและเรดาร์ ซึ่งให้ข้อมูลในลักษณะที่แตกต่างกัน ทั้งข้อมูลเชิงพื้นที่ (spatial features) และข้อมูลเชิงเวลา (temporal features) การประยุกต์ใช้ Machine Learning ช่วยให้ระบบสามารถเรียนรู้รูปแบบของข้อมูลเหล่านี้ร่วมกัน และนำไปสู่การตัดสินใจที่มีความแม่นยำมากขึ้นเมื่อเทียบกับการใช้เกณฑ์เชิงกฎ (rule-based) แบบดั้งเดิม

งานวิจัยที่เกี่ยวข้องจำนวนมากเลือกใช้แบบจำลองการเรียนรู้ของเครื่องแบบกำกับ (Supervised Learning) โดยอาศัยข้อมูลที่มีการกำหนดป้ายกำกับ (ground truth) เพื่อฝึกสอนแบบจำลองให้สามารถจำแนกสถานการณ์ต่าง ๆ เช่น การมีอยู่ของบุคคล การไม่มีบุคคล หรือการมีพฤติกรรมที่ผิดปกติ แบบจำลองที่นิยมใช้ในงานลักษณะนี้ ได้แก่ Logistic Regression, Support Vector Machine (SVM), Decision Tree และ Random Forest เนื่องจากสามารถจัดการกับข้อมูลเชิงตัวเลขที่มีมิติสูงได้ดี ให้ผลลัพธ์ที่มีความเสถียร และสามารถอธิบายการตัดสินใจของโมเดลได้ในระดับหนึ่ง[8]

นอกจากแบบจำลองเชิงสถิติและต้นไม้ตัดสินใจแล้ว งานวิจัยด้านการวิเคราะห์ข้อมูลจากเซนเซอร์ภาพยังนิยมใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) โดยเฉพาะ Convolutional Neural Network (CNN) ซึ่งมีความสามารถในการสกัดลักษณะเชิงพื้นที่จากข้อมูลภาพหรือข้อมูลที่ถูกแปลงให้อยู่ในรูปแบบภาพ เช่น heatmap จากกล้องภาพความร้อน CNN สามารถเรียนรู้รูปแบบการกระจายของอุณหภูมิ รูปร่าง และโครงสร้างของวัตถุได้โดยอัตโนมัติ ซึ่งช่วยเพิ่มประสิทธิภาพในการจำแนกบุคคลและพฤติกรรมที่เกี่ยวข้องกับความเสี่ยง

อีกประเด็นสำคัญในงานด้านความปลอดภัยคือความไม่สมดุลของข้อมูล (class imbalance) ซึ่งมักเกิดจากจำนวนเหตุการณ์ปกติมีมากกว่าสถานการณ์ที่มีความเสี่ยงอย่างมีนัยสำคัญ งานวิจัยที่เกี่ยวข้องจึงเสนอเทคนิคต่าง ๆ เช่น การปรับน้ำหนักของคลาส (class weighting) การสุ่มตัวอย่างข้อมูล (resampling) หรือการกำหนดค่าเกณฑ์การตัดสินใจ (decision threshold) ให้เหมาะสม เพื่อช่วยลดอัตราการแจ้งเตือนผิดพลาด (false alarm) และลดความเสี่ยงจากการพลาดการตรวจจับเหตุการณ์สำคัญ

นอกจากนี้ ความสามารถในการอธิบายผลลัพธ์ของแบบจำลอง (model explainability) ยังเป็นประเด็นที่ได้รับความสนใจมากขึ้น โดยเฉพาะในระบบที่เกี่ยวข้องกับความปลอดภัยและการตัดสินใจเชิงนโยบาย งานวิจัยบางส่วนเสนอการใช้ตัวชี้วัดความสำคัญของคุณลักษณะ (feature importance) หรือเทคนิคการอธิบายแบบจำลอง เช่น SHAP เพื่อช่วยให้ผู้ใช้งานและผู้พัฒนาระบบสามารถเข้าใจเหตุผลเบื้องหลังการตัดสินใจของโมเดลได้ดีขึ้น

จากการทบทวนงานวิจัยที่เกี่ยวข้อง จะเห็นได้ว่าการประยุกต์ใช้ Machine Learning ในระบบตรวจจับอัจฉริยะมีบทบาทสำคัญในการเชื่อมโยงข้อมูลจากเซนเซอร์หลายประเภทเข้าด้วยกัน และช่วยเพิ่มความแม่นยำในการจำแนกสถานการณ์ อย่างไรก็ตาม การเลือกแบบจำลองที่เหมาะสมจำเป็นต้องพิจารณาร่วมกันทั้งด้านลักษณะข้อมูล ความซับซ้อนของปัญหา และข้อจำกัดด้านทรัพยากรของระบบ ซึ่งเป็นประเด็นสำคัญที่นำไปสู่การออกแบบแนวทางการพัฒนาแบบจำลองในงานวิจัยนี้

ตารางที่ 2-2 เปรียบเทียบเทคนิค Machine Learning ที่ใช้ในงานด้านความปลอดภัย

ประเภทโมเดล	หลักการทำงานเบื้องต้น	ข้อดี (Pros)	ข้อเสีย (Cons)
Logistic Regression	หาความสัมพันธ์แบบเส้นตรงเพื่อแบ่งคลาส	คำนวณเร็วมาก, เข้าใจง่าย, ไม่กินทรัพยากร	ไม่รองรับข้อมูลที่ซับซ้อนหรือมีความสัมพันธ์แบบไม่เป็นเส้นตรง
SVM (LinearSVC)	สร้างเส้นแบ่ง (Hyperplane) ที่ห่างจากข้อมูลมากที่สุด	แม่นยำสูงในข้อมูลมิติสูง (High-dimensional), จัดการ Outlier ได้ดี	ใช้เวลาเทรนนานถ้าข้อมูลเยอะมาก, ปรับจูน Parameter ยาก
Random Forest	สร้าง Decision Tree หลายต้นแล้วหาค่าเฉลี่ย (Bagging)	เสถียรมาก, ไม่ค่อย Overfit, จัดการข้อมูล Missing value ได้ดี	โมเดลมีขนาดใหญ่, ทำนายช้ากว่า Linear model
Extra Trees	คล้าย RF แต่ "สุ่ม" จุดตัดข้อมูลแบบสุดโต่ง	เร็วกว่า Random Forest, ลดความเอนเอียง (Variance) ได้ดี	อาจจะสุ่มจนพลาดจุดสำคัญถ้าข้อมูลมีน้อยเกินไป
XGBoost	สร้าง Tree ต่อเนื่องกันเพื่อแก้จุดบกพร่องตัวก่อนหน้า (Boosting)	แม่นยำที่สุด, ประสิทธิภาพสูงมาก (State-of-the-art)	ปรับจูนยาก (ซับซ้อน), เสี่ยงต่อการ Overfit ถ้าไม่คุมให้ดี

2.6 การประเมินประสิทธิภาพของระบบ (Systems Performance Evaluation)

การประเมินประสิทธิภาพของระบบตรวจจับอัจฉริยะเป็นขั้นตอนสำคัญที่ใช้ยืนยันความเหมาะสมของระบบทั้งในเชิงความแม่นยำของการตรวจจับและความสามารถในการนำไปใช้งานจริง งานวิจัยด้านระบบความปลอดภัยและการเฝ้าระวังมักเน้นการประเมินผลในหลายมิติ เนื่องจากระบบดังกล่าวไม่ได้พิจารณาเพียงผลลัพธ์การจำแนกที่ถูกต้องเท่านั้น แต่ยังต้องคำนึงถึงเวลาในการตอบสนอง ความเสถียรของระบบ และข้อจำกัดด้านทรัพยากรของอุปกรณ์ที่ใช้ในการประมวลผล

ในเชิงการประเมินผลด้านการจำแนก (classification performance) งานวิจัยที่เกี่ยวข้องมักใช้ตัวชี้วัดทางสถิติที่ได้จากตารางความสับสน (confusion matrix) เพื่อสะท้อนประสิทธิภาพของแบบจำลอง ตัวชี้วัดที่นิยมใช้ ได้แก่ Accuracy ซึ่งแสดงสัดส่วนของการจำแนกที่ถูกต้องทั้งหมด Precision ซึ่งสะท้อนความถูกต้องของผลการทำนายในคลาสที่สนใจ Recall ซึ่งแสดงความสามารถในการตรวจจับเหตุการณ์ที่เกิดขึ้นจริง และค่า F1-score ซึ่งเป็นค่าเฉลี่ยเชิงฮาร์มอนิกของ Precision และ Recall ตัวชี้วัดเหล่านี้ช่วยให้สามารถประเมินความสมดุลระหว่างการแจ้งเตือนผิดพลาดและการพลาดการตรวจจับได้อย่างเหมาะสม โดยเฉพาะในงานด้านความปลอดภัยที่ความผิดพลาดแต่ละประเภทมีผลกระทบแตกต่างกัน

นอกจากนี้ งานวิจัยจำนวนมากยังใช้ตัวชี้วัดเพิ่มเติม เช่น Receiver Operating Characteristic (ROC) และ Area Under the Curve (AUC) เพื่อวิเคราะห์ความสามารถของแบบจำลองในการแยกแยะคลาสต่าง ๆ ภายใต้ค่าเกณฑ์การตัดสินใจที่หลากหลาย รวมถึงการพิจารณาอัตราการแจ้งเตือนผิดพลาด (False Alarm Rate) และอัตราการพลาดการตรวจจับ (Missed Detection Rate) ซึ่งเป็นตัวชี้วัดที่มีความสำคัญอย่างยิ่งในบริบทของระบบเฝ้าระวังและระบบรักษาความปลอดภัย

นอกเหนือจากประสิทธิภาพด้านการจำแนกแล้ว การประเมินผลเชิงระบบ (system-level performance) ยังเป็นอีกมิติหนึ่งที่ได้รับความสนใจในงานวิจัยด้านระบบอัจฉริยะ โดยเฉพาะระบบที่ทำงานบนอุปกรณ์เอดจ์ ตัวชี้วัดในมิตินี้มักครอบคลุมเวลาแฝงของระบบ (latency) ตั้งแต่การรับข้อมูลจากเซนเซอร์จนถึงการแสดงผลหรือการแจ้งเตือน ความต่อเนื่องในการทำงาน (system stability) และความสามารถในการทำงานแบบเรียลไทม์ภายใต้สภาพแวดล้อมที่แตกต่างกัน [9]

โดยสรุป การประเมินประสิทธิภาพของระบบตรวจจับอัจฉริยะควรดำเนินการในลักษณะหลายมิติ ครอบคลุมทั้งด้านความถูกต้องของการจำแนก ด้านเวลาและความเสถียรในการทำงาน และด้านข้อจำกัดของทรัพยากรฮาร์ดแวร์ แนวคิดดังกล่าวเป็นกรอบสำคัญที่ใช้เป็นพื้นฐานในการออกแบบวิธีการทดลองและการประเมินผลของระบบในบทถัดไปของงานวิจัยนี้

ตารางที่ 2-3 สรุปตัวชี้วัด

ตัวชี้วัด	ความหมาย	ความสำคัญต่อระบบความปลอดภัย
Accuracy	ความถูกต้องรวม	ใช้ดูภาพรวม
Precision	ลด false alarm	สำคัญต่อการแจ้งเตือน
Recall	ลด missed detection	สำคัญสูงสุด
F1-score	สมดุล	ใช้เปรียบเทียบโมเดล
Latency	เวลาในการตอบสนอง	Real-time requirement

2.7 สรุปงานวิจัยที่เกี่ยวข้อง

จากการทบทวนงานวิจัยที่เกี่ยวข้อง สามารถจำแนกแนวทางการพัฒนาระบบตรวจจับบุคคลและการพกพาอาวุธในพื้นที่ปิดออกเป็นหลายกลุ่มตามประเภทของข้อมูลและเทคโนโลยีที่ใช้ ได้แก่ งานวิจัยที่อาศัยข้อมูลภาพจากกล้องวงจรปิด งานวิจัยที่ใช้ข้อมูลภาพความร้อน งานวิจัยที่ใช้เรดาร์คลื่นมิลลิเมตร และงานวิจัยที่ผสานข้อมูลจากหลายเซนเซอร์ (sensor fusion)

กลุ่มงานวิจัยที่ใช้ข้อมูลจากกล้องวงจรปิดและภาพ RGB เป็นแหล่งข้อมูลหลัก มุ่งเน้นการตรวจจับอาวุธจากลักษณะภายนอกของวัตถุและบริบทของมนุษย์ งานวิจัยของ Yupaporn Wanna และ Thanapong Inthara (2024) ได้นำเสนอชุดข้อมูล CONG ซึ่งออกแบบมาเพื่อการตรวจจับการพกพาอาวุธแบบซ่อนเร้น โดยอาศัยการวิเคราะห์พฤติกรรมจากวิดีโอและการเรียนรู้ของเครื่อง[10] เช่น Random Forest, SVM และ XGBoost ขณะที่งานของ Iván González และคณะ (2021) ใช้เทคนิค Deep Learning สำหรับการตรวจจับอาวุธปืนจากภาพกล้องวงจรปิด และแสดงให้เห็นว่าการเพิ่มข้อมูลท่าทางของมนุษย์ (pose information) สามารถช่วยลด false positives และเพิ่มความแม่นยำได้ในบางโมเดล[8] อย่างไรก็ตาม งานในกลุ่มนี้ยังคงมีข้อจำกัดด้านความเป็นส่วนตัว และประสิทธิภาพของระบบมักลดลงเมื่อภาพมีคุณภาพต่ำ แสงน้อย หรือมีการบดบังวัตถุ

อีกกลุ่มหนึ่งเป็นงานวิจัยที่ใช้ภาพความร้อน (thermal imaging) เป็นแหล่งข้อมูลหลัก ซึ่งมีข้อได้เปรียบด้านการทำงานในสภาพแสงน้อยและความเป็นส่วนตัว งานของ Marius Sorin Pavel และคณะ (2025) แสดงให้เห็นว่า ทั้ง Machine Learning และ Deep Learning สามารถนำมาประยุกต์ใช้กับภาพความร้อนเพื่อจำแนกอารมณ์ของมนุษย์ได้อย่างมีประสิทธิภาพ[3] โดยเฉพาะเมื่อมีการจัดการสัญญาณรบกวนและการเพิ่มข้อมูล (data augmentation) อย่างเหมาะสม นอกจากนี้ งานวิจัย Borrow from Anywhere: Pseudo Multi-modal Object Detection in Thermal Imagery ยังเสนอแนวคิด pseudo multi-modal ที่ช่วยเพิ่มประสิทธิภาพการตรวจจับวัตถุจากภาพ

thermal แม้ในกรณีที่มีข้อมูลจำกัด[4] อย่างไรก็ตาม งานในกลุ่มนี้ส่วนใหญ่มุ่งเน้นที่การตรวจจับวัตถุหรืออารมณ์จากภาพ และยังไม่ได้ผสานข้อมูลเชิงพฤติกรรมหรือข้อมูลจากเซนเซอร์ประเภทอื่นอย่างเป็นระบบ

งานวิจัยที่ใช้เรดาร์คลื่นมิลลิเมตร (mmWave radar) ได้รับความสนใจเพิ่มขึ้น เนื่องจากมีความได้เปรียบด้านความเป็นส่วนตัวและสามารถทำงานได้ในทุกสภาพแสง งานของ Gao และคณะ (2021) ได้นำเสนอระบบตรวจจับวัตถุที่พกพา (Open carry และ Concealed carry) โดยใช้เรดาร์ความถี่ 77 GHz ร่วมกับเทคนิค Deep Learning และการตัดสินใจแบบหลายเฟรม ซึ่งช่วยเพิ่มความแม่นยำและลดอัตราการพลาดการตรวจจับได้อย่างมีนัยสำคัญ ขณะที่งานของ Alizadeh และคณะ (2019) แสดงให้เห็นว่าเรดาร์ mmWave แบบต้นทุนต่ำสามารถตรวจจับการมีอยู่ของบุคคลได้อย่างแม่นยำในบริบทของยานยนต์ อย่างไรก็ตาม งานในกลุ่มนี้ยังมีข้อจำกัดในการให้ข้อมูลเชิงรูปร่างและบริบทของวัตถุที่ถูกซ่อนอยู่ใต้เสื้อผ้า

เพื่อแก้ไขข้อจำกัดของการใช้เซนเซอร์เพียงประเภทเดียว งานวิจัยหลายฉบับจึงเสนอแนวทางการผสานข้อมูลจากหลายเซนเซอร์ (Sensor fusion) งานของ Chaitanya Kaul และคณะ (2024) แสดงให้เห็นอย่างชัดเจนว่าการรวมข้อมูลจาก mmWave radar และกล้อง depth สามารถเพิ่มความแม่นยำในการตรวจจับโลหะที่ซ่อนอยู่บนร่างกายได้อย่างมีนัยสำคัญ เมื่อเทียบกับการใช้เซนเซอร์เดี่ยว[11] นอกจากนี้ งานวิจัย Gun Detection Using Combined Human Pose and Weapon Appearance ยังชี้ให้เห็นว่าการผสานข้อมูลบริบทของท่าทางมนุษย์กับลักษณะอาวุธช่วยเพิ่มความสามารถในการตรวจจับอาวุธในภาพกล้องวงจรปิด โดยเฉพาะในสภาพแวดล้อมที่มีความซับซ้อน

จากการทบทวนงานวิจัยทั้งหมด สามารถสรุปได้ว่างานวิจัยก่อนหน้าส่วนใหญ่ยังคงมุ่งเน้นการใช้ข้อมูลจากกล้อง RGB หรือการประมวลผลบนระบบที่ต้องการทรัพยากรสูง ขณะที่งานที่ใช้เรดาร์หรือภาพความร้อนมักจำกัดอยู่ที่การตรวจจับการมีอยู่ของบุคคลหรือวัตถุในลักษณะทั่วไป นอกจากนี้ยังมีงานวิจัยจำนวนจำกัดที่มุ่งเน้นการพัฒนาระบบตรวจจับภัยคุกคามในพื้นที่ปิดโดยใช้การผสานข้อมูลจากเซนเซอร์ที่คำนึงถึงทั้งความเป็นส่วนตัว ข้อจำกัดด้านทรัพยากร และการทำงานแบบเรียลไทม์บนอุปกรณ์เอดจ์

ดังนั้น งานวิจัยนี้จึงมุ่งเติมเต็มช่องว่างดังกล่าว โดยนำเสนอแนวทางการพัฒนาระบบตรวจจับบุคคลและการพกพาอาวุธในพื้นที่ปิด ด้วยการผสานข้อมูลจากกล้องภาพความร้อนและเรดาร์คลื่นมิลลิเมตร ร่วมกับเทคนิค Machine Learning และ Deep Learning ที่เหมาะสมกับอุปกรณ์เอดจ์ เพื่อเพิ่มความแม่นยำในการตรวจจับ ลดการแจ้งเตือนผิดพลาด และยังคงรักษาความเป็นส่วนตัวของผู้ใช้งาน ซึ่งเป็นประเด็นสำคัญสำหรับการนำระบบไปใช้งานจริงในสภาพแวดล้อมของสังคมปัจจุบัน

ตารางที่ 2-4 สรุปงานวิจัยที่เกี่ยวข้องด้านการตรวจจับบุคคลและการพกพาอาวุธในพื้นที่ปิด

ชื่องานวิจัย (ย่อ)	ผู้วิจัย / ปี	แหล่งข้อมูลหลัก	เทคนิคที่ใช้	วัตถุประสงค์ของงานวิจัย	ข้อจำกัดที่พบ
CONG: Concealed Gun Dataset[10]	Wanna & Inthara (2024)	วิดีโอ CCTV (RGB)	RF, SVM, XGBoost + Pose & Movement Analysis	พัฒนาชุดข้อมูลและแบบจำลองเพื่อตรวจจับการพกพาอาวุธปืนแบบซ่อนเร้น	ประสิทธิภาพลดลงในกรณีซ่อนเร้นสูง และพึ่งพาคุณภาพภาพ RGB
Automated Firearm Detection[8]	González et al. (2021)	ภาพ CCTV (RGB)	CNN (YOLOv3, RetinaNet, Faster R-CNN) + Pose Info	ตรวจจับอาวุธปืนอัตโนมัติจากกล้องวงจรปิด	ใช้ทรัพยากรสูง และประสิทธิภาพลดลงในบางสภาพแวดล้อม
Thermal-based Emotion Recognition[3]	Pavel et al. (2025)	ภาพความร้อนใบหน้า	RF, SVM, KNN, CNN	จำแนกอารมณ์จากภาพความร้อนด้วย ML/DL	ไม่ได้มุ่งเน้นการตรวจจับอาวุธหรือพฤติกรรมเสี่ยง
Child & Pet Detection in Vehicles [12]	Palanisamy & Ratnarajah (2023)	ภาพ RGB ภายในรถ	YOLOv6, YOLOv7, NanoDet	ตรวจจับเด็กและสัตว์เลี้ยงในรถยนต์เพื่อความปลอดภัย	มีประเด็นด้านความเป็นส่วนตัวจากการใช้กล้อง RGB
mmSenseAF: Multi-sensor Fusion[11]	Kaul et al. (2024)	mmWave Radar + Depth Camera	CNN, ConvLSTM, Sensor Fusion	ตรวจจับโลหะที่ซ่อนอยู่ด้วยการผสานข้อมูลหลายเซนเซอร์	ระบบซับซ้อน ต้องใช้ฮาร์ดแวร์ประสิทธิภาพสูง
Concealed Object Detection via mmWave Radar[5]	Gao et al. (2021)	mmWave Radar 77 GHz	3D CNN + Multi-shot Decision	ตรวจจับวัตถุพกพาแบบเปิดและซ่อนเร้น	ต้องใช้ข้อมูลจำนวนมาก และยังมีอัตราการพลาดการตรวจจับ

ตารางที่ 2-4 (ต่อ)

ชื่องานวิจัย (ย่อ)	ผู้วิจัย / ปี	แหล่งข้อมูลหลัก	เทคนิคที่ใช้	วัตถุประสงค์ของงานวิจัย	ข้อจำกัดที่พบ
Pseudo Multi-modal Thermal Detection[4]	Devaguptapu et al. (2019)	Thermal + Pseudo-RGB	CNN + Pseudo Multi-modal Fusion	เพิ่มประสิทธิภาพการตรวจจับวัตถุจากภาพความร้อน	เกิด false positives ในฉากซับซ้อน
Pose-assisted Gun Detection	Maligireddy et al. (2025)	RGB + Human Pose	YOLOv3 + Pose Fusion	ตรวจจับอาวุธปืนโดยใช้ข้อมูลท่าทางและลักษณะวัตถุ	ความแม่นยำลดลงเมื่อมุมกล้องไม่เหมาะสม
Low-cost mmWave Occupancy Detection [6]	Alizadeh et al. (2019)	mmWave FMCW Radar	Signal Processing + SVM	ตรวจจับการมีอยู่ของบุคคลด้วยเรดาร์ต้นทุนต่ำ	ทดลองในสภาพแวดล้อมจำกัด ยังไม่ผสานข้อมูลจากเซนเซอร์อื่น

บทที่ 3
วิธีดำเนินงาน

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาระบบอัจฉริยะสำหรับตรวจจับการมีอยู่ของบุคคลและแนวโน้มการพกพาอาวุธในพื้นที่ โดยอาศัยการบูรณาการข้อมูลจากเซนเซอร์หลายประเภท (Multi-sensor Integration) ได้แก่ เซนเซอร์กล้องถ่ายภาพความร้อน (Thermal Imaging Sensor) รุ่น MLX90640 และเซนเซอร์เรดาร์คลื่นมิลลิเมตร (mmWave Radar) รุ่น HLK-LD2410C ซึ่งทำงานร่วมกับหน่วยประมวลผลแบบสมองกลฝังตัว ESP32 เป็นแกนกลางของระบบ

ข้อมูลที่ได้จากเซนเซอร์ดังกล่าวถูกนำมาประมวลผลด้วยเทคนิคการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก (Machine Learning และ Deep Learning) เพื่อจำแนกสถานการณ์ออกเป็นลำดับขั้น ได้แก่ (1) การตรวจจับการมีอยู่ของบุคคล และ (2) การประเมินแนวโน้มการพกพาอาวุธของบุคคลที่ตรวจพบ โดยระบบถูกออกแบบให้สามารถนำไปประยุกต์ใช้งานได้ในพื้นที่ทั่วไป ทั้งพื้นที่ปิด พื้นที่กึ่งเปิด และพื้นที่สาธารณะ ภายใต้แนวคิดการลดการละเมิดความเป็นส่วนตัวของบุคคล

กระบวนการดำเนินงานวิจัยนี้ถูกพัฒนาและปรับปรุงตามวงจรการพัฒนาแบบต้นแบบ (Prototype Development Cycle) ซึ่งเน้นการออกแบบ ทดสอบ และปรับปรุงระบบอย่างต่อเนื่อง โดยสามารถแบ่งขั้นตอนการดำเนินงานออกเป็น 5 ขั้นตอนหลัก ดังนี้

3.1 ศึกษาและวิเคราะห์ปัญหา
3.2 การออกแบบระบบ
3.3 การพัฒนาระบบ
3.4 การประเมินผลระบบ
3.5 สถิติที่ใช้ในการวิเคราะห์ข้อมูล

3.1 ศึกษาและวิเคราะห์ปัญหา

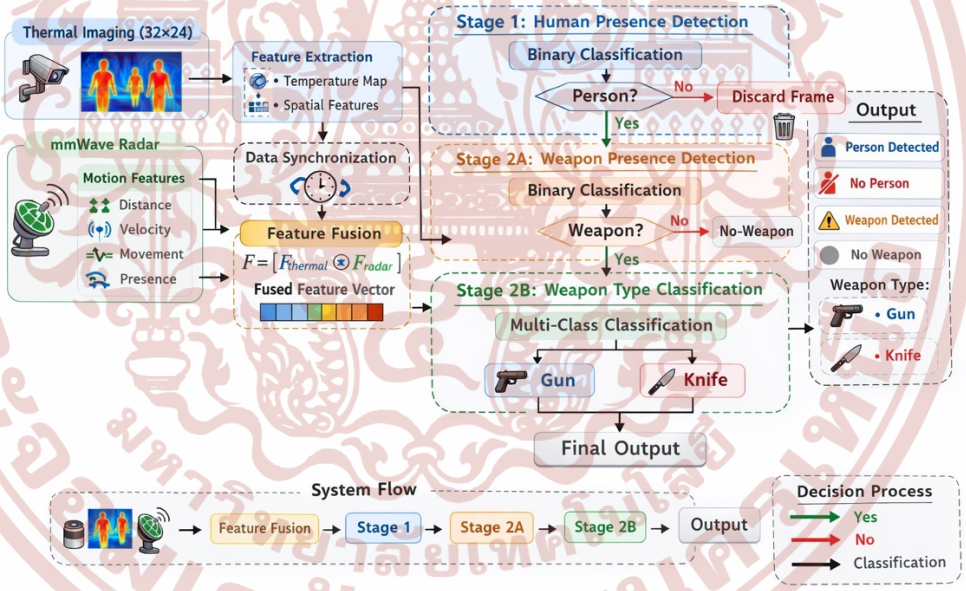
ขั้นตอนแรกของการดำเนินงานวิจัยคือการศึกษาและวิเคราะห์ปัญหาที่เกี่ยวข้องกับความปลอดภัยในพื้นที่ ซึ่งพบว่าการตรวจจับบุคคลที่อาจพกพาอาวุธมีความท้าทายจากหลายปัจจัย เช่น ความหลากหลายของสภาพแวดล้อม ท่าทางของบุคคล รูปแบบการพกพาอาวุธแบบเปิดเผยและแบบซ่อนเร้น รวมถึงข้อจำกัดด้านความเป็นส่วนตัวเมื่อใช้กล้องภาพสี (RGB Camera)

จากการทบทวนงานวิจัยที่เกี่ยวข้อง พบว่าเซนเซอร์กล้องถ่ายภาพความร้อนสามารถตรวจจับการมีอยู่ของร่างกายมนุษย์จากการแผ่รังสีความร้อนได้โดยไม่แสดงรายละเอียดเชิงอัตลักษณ์ของบุคคล ขณะที่เซนเซอร์เรดาร์ mmWave สามารถตรวจจับการเคลื่อนไหว ระยะห่าง และพลังงานการสะท้อนของวัตถุได้อย่างต่อเนื่อง งานวิจัยนี้จึงเลือกใช้แนวทางการผสานข้อมูลจากเซนเซอร์ทั้งสองประเภท เพื่อเพิ่มความแม่นยำและลดข้อจำกัดของการใช้เซนเซอร์เพียงชนิดเดียว

นอกจากนี้ ได้กำหนดแนวคิดการทำงานของระบบในลักษณะการตรวจจับแบบลำดับขั้น (Two-Stage Detection) โดยเริ่มจากการตรวจสอบการมีอยู่ของบุคคลก่อน หากตรวจพบบุคคลจึงดำเนินการประเมินแนวโน้มการพกพาอาวุธต่อไป ซึ่งช่วยลดการแจ้งเตือนผิดพลาดและเพิ่มประสิทธิภาพของระบบโดยรวม[12], [13], [14]

3.2 การออกแบบระบบ (System Design)

สถาปัตยกรรมฮาร์ดแวร์ของระบบตรวจจับอาวุธที่นำเสนอในงานวิจัยนี้ถูกออกแบบภายใต้แนวคิดของการผสานข้อมูลจากหลายเซนเซอร์ (Multi-sensor fusion) เพื่อเพิ่มความแม่นยำและความน่าเชื่อถือในการตรวจจับบุคคลและอาวุธในพื้นที่ ระบบประกอบด้วยเซนเซอร์หลักจำนวน 2 ประเภท ได้แก่ กล้องความร้อนและเรดาร์คลื่นความถี่มิลลิเมตร โดยมีไมโครคอนโทรลเลอร์ทำหน้าที่เป็นศูนย์กลางในการประมวลผลและจัดการข้อมูลทั้งหมด[11], [15]

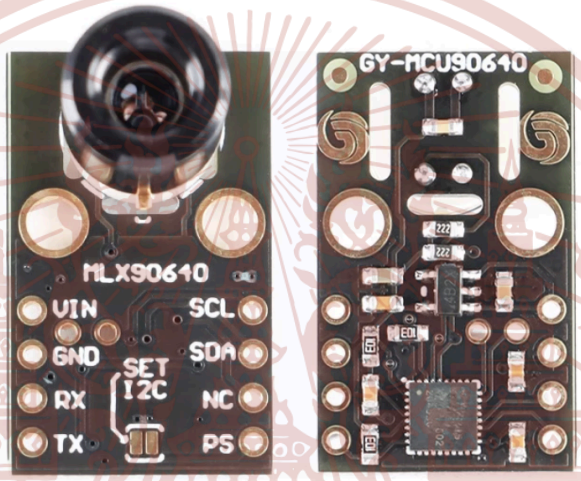


ภาพที่ 3-1 ภาพรวมการทำงานของระบบ

3.2.1 กล้องความร้อน MLX90640

กล้องความร้อนรุ่น MLX90640 ถูกเลือกใช้เป็นเซนเซอร์หลักสำหรับการรับข้อมูลภาพความร้อนของวัตถุในฉากตรวจจับ โดยมีความละเอียด 32 × 24 พิกเซล ซึ่งเหมาะสมกับการใช้งานในระบบสมองกลฝังตัว (Embedded system) เนื่องจากให้ข้อมูลเชิงพื้นที่เพียงพอสำหรับการวิเคราะห์รูปแบบความร้อน ขณะเดียวกันยังใช้ทรัพยากรการประมวลผลต่ำ กล้องความร้อนรุ่นนี้มีมุมมองการตรวจจับ (Field of View) ขนาด 55 องศา และในบางการทดลองมีการใช้รุ่นมุมมอง 110 องศาเพื่อศึกษาผลกระทบของมุมมองต่อประสิทธิภาพของระบบ

MLX90640 สามารถตรวจวัดอุณหภูมิพื้นผิวของวัตถุแบบเรียลไทม์โดยไม่ต้องสัมผัส ซึ่งเหมาะสมกับการใช้งานด้านความปลอดภัยและการเฝ้าระวัง การเชื่อมต่อกับหน่วยประมวลผลกลางใช้โปรโตคอล I²C และพัฒนาโปรแกรมควบคุมด้วยไลบรารี Adafruit_MLX90640 เพื่ออ่านค่าอุณหภูมิและจัดเก็บข้อมูลในรูปแบบอาร์เรย์ของพิกเซลความร้อนสำหรับการประมวลผลในขั้นตอนถัดไป

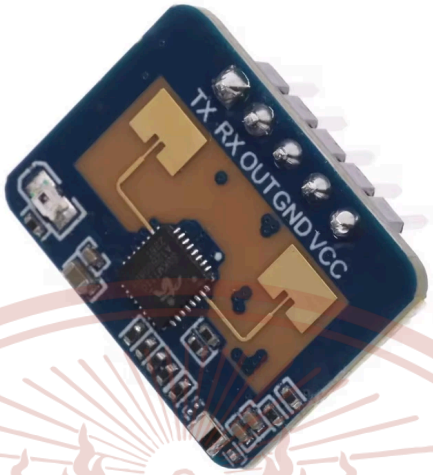


ภาพที่ 3-2 กล้องความร้อน Thermal Sensor module

3.2.2 mmWave Radar HLK-LD2410C

เรดาร์คลื่นความถี่มิลลิเมตรรุ่น HLK-LD2410C ถูกนำมาใช้เพื่อเสริมข้อมูลด้านการเคลื่อนไหวและระยะทางของวัตถุ ซึ่งเป็นข้อมูลที่กล้องความร้อนไม่สามารถให้ได้โดยตรง เรดาร์รุ่นนี้มีมุมมองการตรวจจับประมาณ ±60 องศา และสามารถตรวจจับข้อมูลสำคัญ เช่น ระยะทาง การเคลื่อนไหว และพลังงานการสะท้อนของวัตถุในแต่ละช่วงระยะ

จุดเด่นของ HLK-LD2410C คือการรองรับโหมด Engineering Mode ซึ่งเปิดให้สามารถอ่านค่าพลังงานของสัญญาณสะท้อนในแต่ละ gate ได้ โดยแบ่งออกเป็น Gate การเคลื่อนไหว (Move) และ gate วัตถุคงที่ (Static) รวมทั้งสิ้น 8 gate ต่อประเภท ส่งผลให้ได้คุณลักษณะ (Features) ด้านเรดาร์รวม 16 ค่า ข้อมูลเหล่านี้มีความสำคัญอย่างยิ่งต่อการวิเคราะห์พฤติกรรมและการจำแนกสถานการณ์ต่าง ๆ การสื่อสารข้อมูลระหว่างเรดาร์และไมโครคอนโทรลเลอร์ใช้โปรโตคอล UART โดยใช้ไลบรารีที่ผู้วิจัยพัฒนาขึ้นเองและปรับปรุงให้สอดคล้องกับโครงสร้างคำสั่งของอุปกรณ์ LD2410

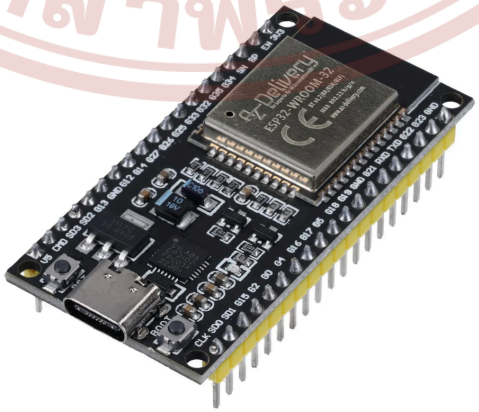


ภาพที่ 3-3 Redar module HLK-LD2410C

3.2.3 ไมโครคอนโทรลเลอร์ ESP32 WROOM-32

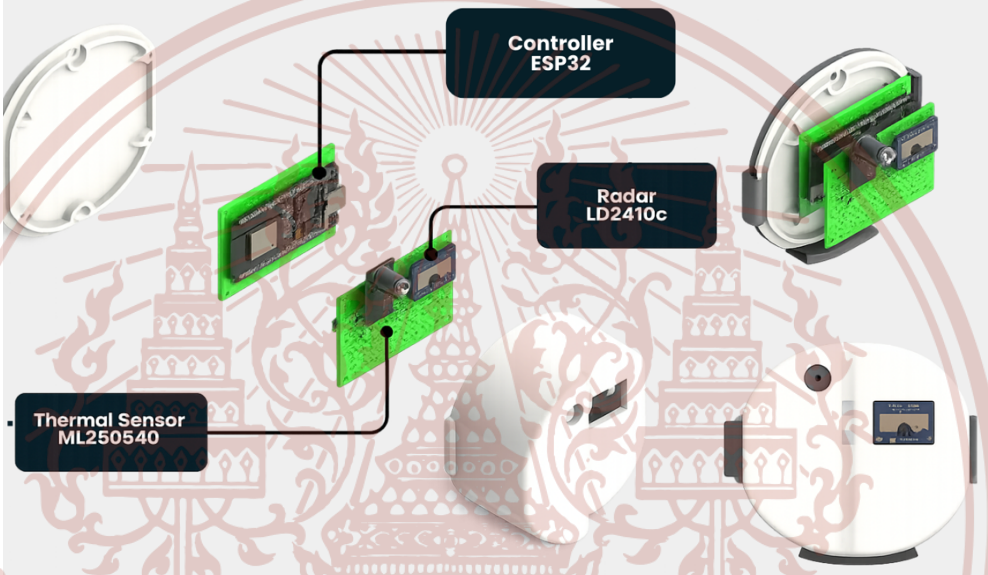
ไมโครคอนโทรลเลอร์ ESP32 WROOM-32 ทำหน้าที่เป็นหน่วยประมวลผลกลางของระบบ มีหน้าที่รับข้อมูลจากกล้องความร้อน MLX90640 และเรดาร์ HLK-LD2410C จากนั้นดำเนินการประมวลผลเบื้องต้นและจัดการข้อมูลเพื่อส่งต่อไปยังระบบส่วนอื่น ๆ ESP32 ถูกเลือกใช้เนื่องจากมีสมรรถนะการประมวลผลที่เหมาะสม รองรับการสื่อสารแบบไร้สายผ่าน Wi-Fi และสามารถเชื่อมต่อกับอุปกรณ์ต่อพ่วงได้หลากหลาย

หน้าที่หลักของ ESP32 ประกอบด้วยการอ่านค่าจากเซนเซอร์ทั้งสองชนิด การแปลงข้อมูลให้อยู่ในรูปแบบ JSON หรือ CSV เพื่อความสะดวกในการจัดเก็บและประมวลผลภายหลัง การแสดงผลภาพ heatmap บนจอ TFT รุ่น ILI9341 ในกรณีที่ใช้งานระบบแบบมีหน้าจอ รวมถึงการอัปโหลดข้อมูลไปยังเซิร์ฟเวอร์หรือระบบคลาวด์ผ่านเครือข่าย Wi-Fi นอกจากนี้ยังมีการประมวลผลเบื้องต้น เช่น การทำ smoothing และการลดสัญญาณรบกวน (denoise) เพื่อเพิ่มคุณภาพของข้อมูลก่อนนำไปใช้ในการฝึกสอนแบบจำลอง



ภาพที่ 3-4 ESP32 WROOM-32

นอกจากนี้ ในกรณีที่มีการแสดงผลข้อมูลแบบเรียลไทม์บนอุปกรณ์สำหรับแสดงภาพ heatmap และข้อมูลสถานะของระบบ อุปกรณ์ประกอบอื่น ๆ ที่ใช้ในการพัฒนาและติดตั้งระบบ ได้แก่ สายเชื่อมต่อ Dupont แผ่นวงจรพิมพ์ (PCB) และกล่องอุปกรณ์ที่ผลิตด้วยเครื่องพิมพ์สามมิติ (3D printed box) ซึ่งออกแบบให้เหมาะสมกับการติดตั้งเซนเซอร์และไมโครคอนโทรลเลอร์ภายในพื้นที่จำกัด



ภาพที่ 3-5 อุปกรณ์ภาพรวมของชิ้นงาน

3.2.4 เครื่องมือด้านซอฟต์แวร์ (Software)

ในด้านซอฟต์แวร์ งานวิจัยนี้ใช้เครื่องมือหลากหลายเพื่อรองรับการพัฒนาเฟิร์มแวร์ การจัดการข้อมูล และการพัฒนาแบบจำลอง Machine Learning และ Deep Learning ภาษาโปรแกรม Python ถูกใช้เป็นเครื่องมือหลักสำหรับการประมวลผลข้อมูล การเตรียมข้อมูล และการพัฒนาแบบจำลอง โดยอาศัยไลบรารีที่สำคัญ ได้แก่ NumPy และ Pandas สำหรับการจัดการข้อมูลเชิงตัวเลขและตารางข้อมูล Scikit-learn สำหรับการพัฒนาแบบจำลอง Machine Learning และ TensorFlow สำหรับการพัฒนาแบบจำลอง Deep Learning

การพัฒนาเฟิร์มแวร์บนไมโครคอนโทรลเลอร์ ESP32 ดำเนินการผ่านโปรแกรม Arduino IDE ขณะที่การฝึกสอนแบบจำลองที่ต้องการทรัพยากรการประมวลผลสูงดำเนินการบนแพลตฟอร์ม Google Colab ซึ่งช่วยลดข้อจำกัดด้านฮาร์ดแวร์ของผู้วิจัย

สำหรับการออกแบบโครงสร้างกล่องอุปกรณ์ ใช้โปรแกรม Shapr3D และ SketchUp เพื่อสร้างแบบจำลองสามมิติของกล่องและปรับตำแหน่งอุปกรณ์ให้เหมาะสม นอกจากนี้

โปรแกรม Visual Studio Code (VS Code) ถูกใช้เป็นสภาพแวดล้อมในการพัฒนาโค้ดสำหรับฝั่งเซิร์ฟเวอร์และการจัดการ API

ในส่วนของการรับส่งข้อมูล ระบบใช้ Server API สำหรับรับข้อมูลในรูปแบบ JSON จากอุปกรณ์ IoT เพื่อจัดเก็บข้อมูลและนำไปใช้ในการประมวลผล วิเคราะห์ และประเมินผลแบบจำลองในขั้นตอนถัดไปของงานวิจัย



ภาพที่ 3-6 การออกแบบหน้าจอแสดงผล (Dashboard)

จากภาพที่ 3-6 แสดงหน้าจอแสดงผลของระบบตรวจจับอัจฉริยะหลังจากที่ข้อมูลจากเซนเซอร์ได้รับการประมวลผลแล้ว โดยหน้าจอดังกล่าวทำหน้าที่แสดงผลข้อมูลที่ได้รับจากอุปกรณ์ตรวจจับทั้งสองประเภท ได้แก่ กล้องถ่ายภาพความร้อน (Thermal Imaging Sensor) และเซนเซอร์เรดาร์คลื่นมิลิเมตร (mmWave Radar)

ข้อมูลที่ได้จากกล้องถ่ายภาพความร้อนจะถูกแปลงจากข้อมูลเชิงตัวเลขให้อยู่ในรูปแบบของภาพความร้อน (Thermal Image Representation) เพื่อช่วยให้ผู้ใช้งานสามารถเข้าใจลักษณะการกระจายของอุณหภูมิและการปรากฏตัวของบุคคลในพื้นที่ได้อย่างชัดเจนยิ่งขึ้น ขณะเดียวกัน ข้อมูลจากเซนเซอร์เรดาร์จะแสดงในรูปของค่าการตรวจจับการเคลื่อนไหว ระยะทาง และพลังงานของสัญญาณสะท้อน เพื่อใช้ประกอบการวิเคราะห์พฤติกรรมของบุคคลที่ตรวจพบ

นอกจากนี้ หน้าจอแสดงผลยังนำเสนอผลลัพธ์จากกระบวนการทำนายของแบบจำลองการเรียนรู้ของเครื่อง ซึ่งทำการวิเคราะห์ข้อมูลที่ได้รับจากเซนเซอร์ร่วมกัน โดยผลการทำนายจะแสดงสถานะและระดับความเสี่ยงของสถานการณ์ที่ตรวจพบ เพื่อสนับสนุนการตัดสินใจและการเฝ้าระวังในระบบรักษาความปลอดภัยแบบอัจฉริยะ

3.2.5 การออกโครงสร้างข้อมูลที่ส่งออก (Data Schema)

ข้อมูลที่ได้จากเซนเซอร์ทั้งหมดจะถูกจัดโครงสร้างให้อยู่ในรูปแบบ JSON เพื่อความสะดวกในการจัดเก็บ ประมวลผล และนำไปใช้สร้างชุดข้อมูล (dataset) สำหรับการพัฒนาแบบจำลอง Machine Learning โดยโครงสร้างข้อมูลประกอบด้วยข้อมูลด้านเวลา ข้อมูลภาพความร้อน ข้อมูลการเคลื่อนไหว และข้อมูลพลังงานจากเรดาร์

ตัวอย่างโครงสร้างข้อมูล JSON ที่ส่งออกจากระบบแสดงดังนี้

```
{
  "timestamp": "2025-01-01 10:32:11",
  "thermal": [...768 pixels...],
  "motion": true,
  "motion_distance": 42,
  "motion_energy": 76,
  "static_energy": 100,
  "eng_move_gate_energy": [72, 76, 16, 4, 3, 10, 3, 7],
  "eng_static_gate_energy": [3, 0, 0, 100, 10, 2, 1, 0],
  "label": "weapon_type"
}
```

ฟิลด์ Timestamp ใช้ระบุเวลาที่ข้อมูลถูกบันทึกเพื่อรองรับการวิเคราะห์เชิงลำดับเวลา ฟิลด์ thermal เก็บข้อมูลพิกเซลความร้อนจำนวน 768 ค่า ซึ่งเป็นข้อมูลหลักสำหรับการวิเคราะห์รูปแบบความร้อนของบุคคลและวัตถุ ฟิลด์ motion, motion_distance, motion_energy และ static_energy แสดงสถานะและลักษณะการเคลื่อนไหวที่ตรวจจับได้จากเรดาร์

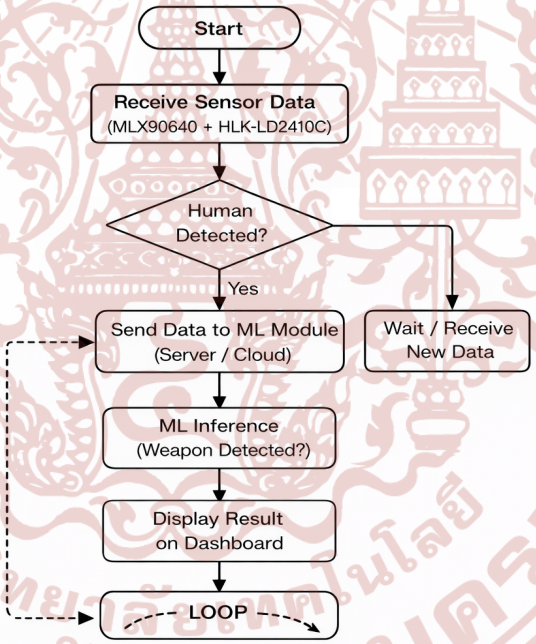
นอกจากนี้ ฟิลด์ eng_move_gate_energy และ eng_static_gate_energy ใช้เก็บค่าพลังงานการสะท้อนของสัญญาณเรดาร์ในแต่ละ gate ซึ่งเป็นข้อมูลเชิงลึกที่ช่วยเพิ่มศักยภาพในการจำแนกพฤติกรรมและสถานการณ์ต่าง ๆ ส่วนฟิลด์ label ใช้ระบุคลาสของ

ข้อมูล เช่น ไม่มีบุคคล ไม่มีอาวุธ หรือมีอาวุธ ซึ่งถูกกำหนดในขั้นตอนการเตรียมข้อมูลเพื่อใช้เป็นข้อมูลกำกับ (ground truth) สำหรับการฝึกสอนแบบจำลอง

ข้อมูลทั้งหมดในโครงสร้างนี้ถูกนำไปใช้ในการสร้างชุดข้อมูลสำหรับการพัฒนาแบบจำลอง Machine Learning และ Deep Learning ซึ่งจะอธิบายรายละเอียดเพิ่มเติมในหัวข้อถัดไปของบทที่ 3 และบทที่ 4 ของงานวิจัย

3.2.6 การทำงานของระบบ

การทำงานของระบบนี้จะแบ่งเป็น 2 ส่วนด้วยกัน คือ ระบบเก็บข้อมูลเพื่อทำการสอนโมเดล และ ระบบที่ออนไลน์สำหรับใช้งานจริง โดยการทำงานของระบบจะทำงานตามแผนผังดังนี้



ภาพที่ 3-7 การทำงานของระบบ

การทำงานของระบบเริ่มต้นจากการเก็บข้อมูลจากเซนเซอร์ภาพความร้อนและเรดาร์ จากนั้นข้อมูลจะถูกจัดรูปแบบเป็นโครงสร้างข้อมูลแบบ JSON และส่งไปยังเซิร์ฟเวอร์เพื่อทำการประมวลผ] กระบวนการสื่อสารข้อมูลของระบบสามารถอธิบายได้ดังอัลกอริทึมที่ 3-1

อัลกอริทึม 3-1: กระบวนการสื่อสารข้อมูล (Data Communication Pipeline)

ข้อมูลนำเข้า (Input): ข้อมูลจากเซนเซอร์ภาพความร้อน (MLX90640) และข้อมูลจากเรดาร์ (LD2410C)
ข้อมูลส่งออก (Output): ข้อมูลเชิงโครงสร้างสำหรับการแสดงผลและการประมวลผลด้วย Machine Learning (รูปแบบ JSON)

1. เริ่มต้นการทำงานของ ESP32 และตั้งค่าการสื่อสารต่าง ๆ ได้แก่ I2C, UART และ Wi-Fi
2. อ่านข้อมูลพิกเซลภาพความร้อนจากเซนเซอร์ MLX90640
3. อ่านข้อมูลการเคลื่อนไหว ระยะทาง และค่าพลังงานจากเรดาร์ LD2410C
4. ทำการกรองข้อมูลเบื้องต้นและปรับค่าความเรียบของข้อมูลดิบจากเซนเซอร์
5. สร้างโครงสร้างข้อมูลในรูปแบบ JSON
6. ส่งข้อมูลไปยังเซิร์ฟเวอร์ผ่านเครือข่ายไร้สาย
7. เซิร์ฟเวอร์ทำการตรวจสอบความถูกต้องของโครงสร้างและความสมบูรณ์ของข้อมูล
8. ทำการปรับรูปแบบและปรับสเกลข้อมูลเพื่อใช้ในการแสดงผลและการประมวลผลด้วย Machine Learning

3.2.7 กรอบการตรวจจับแบบสองลำดับขั้น (Two-Stage Detection Framework)

ระบบตรวจจับถูกออกแบบให้ทำงานในลักษณะลำดับขั้น เพื่อเพิ่มความแม่นยำและลดการแจ้งเตือนผิดพลาด โดยในขั้นตอนแรกระบบจะตรวจสอบว่ามีบุคคลอยู่ในพื้นที่หรือไม่ หากตรวจพบบุคคลจึงจะดำเนินการตรวจสอบการพกพาอาวุธในขั้นตอนถัดไป

กระบวนการตรวจจับดังกล่าวสามารถอธิบายได้ดังอัลกอริทึมที่ 3-2

อัลกอริทึม 3-2 กรอบการตรวจจับแบบสองลำดับขั้น (Two-Stage Detection Framework)

ข้อมูลนำเข้า (Input):

คุณลักษณะจากเซนเซอร์ภาพความร้อนและเรดาร์

ข้อมูลส่งออก (Output):

ผลการตรวจจับ (ไม่มีบุคคล / พบบุคคล / มีความเสี่ยงการพกพาอาวุธ)

1: รับข้อมูลเซนเซอร์จากโมดูลการสื่อสารข้อมูล
2: ขั้นตอนที่ 1 – การตรวจจับบุคคล (Person Detection)
3: สกัดคุณลักษณะจากข้อมูลภาพความร้อนและข้อมูลเรดาร์
4: ประมวลผลด้วยแบบจำลองตรวจจับบุคคล
5: หากไม่พบบุคคล ให้ส่งผลลัพธ์เป็น "No Person"
6: ขั้นตอนที่ 2 – การตรวจจับความเสี่ยงจากอาวุธ (Weapon Risk Detection)
7: สกัดคุณลักษณะเชิงพื้นที่และการเคลื่อนไหวเพิ่มเติม
8: ประมวลผลด้วยแบบจำลองตรวจจับอาวุธ
9: สร้างผลการทำนายพร้อมค่าความเชื่อมั่น (confidence score)
10: ส่งผลการตรวจจับไปยังแดชบอร์ด

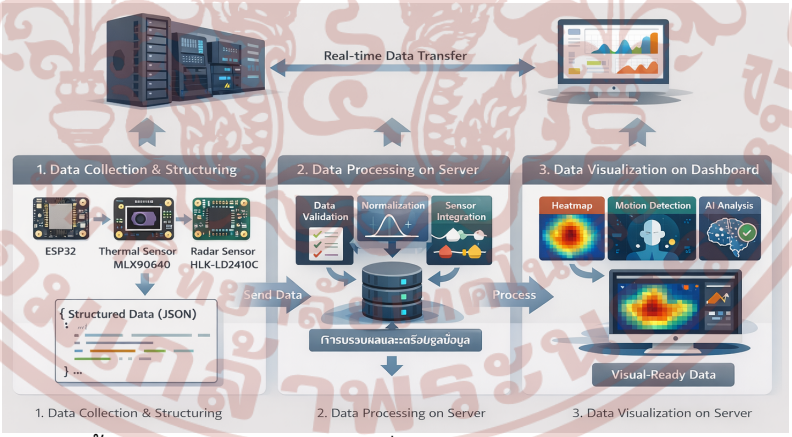
3.3 การพัฒนาระบบ (System Development)

หัวข้อนี้อธิบายขั้นตอนการพัฒนาระบบตามโครงสร้างที่ได้ออกแบบไว้ในบทที่ 3.2 โดยมุ่งเน้นการพัฒนาเชิงปฏิบัติการในแต่ละองค์ประกอบของระบบ ตั้งแต่การสื่อสารข้อมูล การแสดงผล การจัดเก็บชุดข้อมูล ไปจนถึงการพัฒนาแบบจำลองการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกสำหรับการตรวจจับบุคคลและการพกพาอาวุธ[3], [6]

3.3.1 การพัฒนาการสื่อสารข้อมูลระหว่าง Server และ Dashboard

การพัฒนาการสื่อสารข้อมูลในงานวิจัยนี้มุ่งเน้นการออกแบบกระบวนการรับ–ส่งข้อมูลระหว่างอุปกรณ์ฮาร์ดแวร์ เซิร์ฟเวอร์ และระบบแสดงผล ให้สามารถทำงานได้อย่างต่อเนื่องและมีประสิทธิภาพในลักษณะเรียลไทม์ โดยให้ความสำคัญกับความถูกต้องของข้อมูล โครงสร้างข้อมูลที่เป็นมาตรฐาน และเวลาแฝงต่ำ เพื่อรองรับการใช้งานด้านความปลอดภัยในพื้นที่จริง

ในระดับระบบการสื่อสารข้อมูลถูกออกแบบเป็นลำดับขั้น (Data pipeline) ตั้งแต่การรวบรวมข้อมูลจากเซนเซอร์ การจัดโครงสร้างข้อมูล การประมวลผลบนเซิร์ฟเวอร์ จนถึงการส่งข้อมูลที่พร้อมใช้งานไปยังหน้าแสดงผล โดยมีการกำหนดบทบาทของแต่ละองค์ประกอบอย่างชัดเจน



ภาพที่ 3-8 แสดงขั้นตอนการทำงานของการสื่อสารข้อมูลระหว่าง Server และ Dashboard

1) การรวบรวมและจัดโครงสร้างข้อมูลจากอุปกรณ์ IoT

ไมโครคอนโทรลเลอร์ ESP32 ทำหน้าที่เป็นศูนย์กลางในการรวบรวมข้อมูลดิบจากเซนเซอร์กล้องถ่ายภาพความร้อน MLX90640 และเซนเซอร์เรดาร์คลื่นมิลลิเมตร HLK-LD2410C ข้อมูลจากกล้องความร้อนอยู่ในรูปแบบอาร์เรย์ของค่าตัวเลขอุณหภูมิ ขณะที่ข้อมูลจากเรดาร์ประกอบด้วยสถานะการเคลื่อนไหว ระยะทาง และค่าพลังงานของสัญญาณสะท้อนในแต่ละช่วงระยะ

ข้อมูลจากเซนเซอร์ทั้งสองประเภทจะถูกจัดเรียงและบรรจุให้อยู่ในรูปแบบข้อมูลเชิงโครงสร้าง (Structured data) เช่น JSON เพื่อให้สะดวกต่อการส่งผ่านเครือข่ายและการประมวลผลในขั้นตอนถัดไป โดยในขั้นตอนนี้อุปกรณ์ฮาร์ดแวร์อาจมีการประมวลผลเบื้องต้น เช่น การกรองสัญญาณรบกวนหรือการรวมข้อมูลจากหลายแหล่ง ก่อนส่งข้อมูลไปยังเซิร์ฟเวอร์ผ่านเครือข่ายไร้สาย

2) การประมวลผลและเตรียมข้อมูลบนฝั่งเซิร์ฟเวอร์

เมื่อเซิร์ฟเวอร์ได้รับข้อมูลจากอุปกรณ์ IoT ระบบจะดำเนินการตรวจสอบความถูกต้องของโครงสร้างข้อมูล (Data validation) และจัดการข้อมูลให้อยู่ในรูปแบบที่เหมาะสมสำหรับการใช้งานต่อไป ข้อมูลอุณหภูมิจากกล้องความร้อนจะถูกนำมาปรับค่าให้อยู่ในช่วงมาตรฐานตามกระบวนการ normalization ที่ได้อธิบายไว้แล้วในบทที่ 2 เพื่อให้ข้อมูลมีความสม่ำเสมอและสามารถเปรียบเทียบระหว่างช่วงเวลาได้

จากนั้นข้อมูลจะถูกจัดรูปแบบใหม่ให้อยู่ในลักษณะเมทริกซ์สองมิติและโครงสร้างข้อมูลเชิงตัวเลขที่เป็นมาตรฐานเดียวกันทั้งระบบ รวมถึงการผสานข้อมูลจากหลายเซนเซอร์ (sensor integration) เพื่อเตรียมเป็นข้อมูลนำเข้าให้กับแบบจำลองการเรียนรู้ของเครื่อง และเป็นข้อมูลที่พร้อมสำหรับการส่งต่อไปยังระบบแสดงผล

3) การส่งข้อมูลที่พร้อมใช้งานไปยัง Dashboard

หลังจากการประมวลผลและจัดเตรียมข้อมูลเสร็จสิ้น เซิร์ฟเวอร์จะส่งข้อมูลในรูปแบบที่พร้อมใช้งาน (Visual-ready data) ไปยังหน้าแสดงผลผ่านกลไกการสื่อสารแบบเรียลไทม์ เช่น REST API หรือ WebSocket โดยข้อมูลที่ส่งออกประกอบด้วยข้อมูลอุณหภูมิที่ผ่านการปรับค่าแล้ว ข้อมูลการเคลื่อนไหวจากเรดาร์ และผลลัพธ์จากการประเมินของแบบจำลอง

ในขั้นตอนนี้ ระบบจะมุ่งเน้นเฉพาะการส่งข้อมูลและผลลัพธ์ที่ถูกต้องและทันเวลา โดยยังไม่ครอบคลุมรายละเอียดด้านการออกแบบและการแสดงผลเชิงภาพ ซึ่งจะอธิบายเพิ่มเติมในหัวข้อถัดไป

3.3.2 การพัฒนาการแสดงผลของหน้า Dashboard

หน้า Dashboard ได้รับการพัฒนาเพื่อทำหน้าที่เป็นส่วนติดต่อผู้ใช้ (User Interface) สำหรับการแสดงสถานะและผลลัพธ์ของระบบตรวจจับ โดยออกแบบให้สามารถแสดงข้อมูลจากหลายแหล่งพร้อมกัน ได้แก่ ข้อมูลการเคลื่อนไหวจากเซนเซอร์เรดาร์ ข้อมูลภาพความร้อนจากกล้อง MLX90640 และผลการทำนายจากแบบจำลองการเรียนรู้ของเครื่อง

การออกแบบหน้าแดชบอร์ดในงานวิจัยนี้มีวัตถุประสงค์เพื่อสนับสนุนการรับรู้สถานการณ์ (situational awareness) และการตัดสินใจของผู้ใช้งาน โดยลดความซับซ้อนของข้อมูลดิบจากหลายเซนเซอร์ และนำเสนอในรูปแบบที่เข้าใจได้รวดเร็วในบริบทของงานด้านความปลอดภัย

สำหรับข้อมูลจากกล้องถ่ายภาพความร้อน ข้อมูลอุณหภูมิในรูปแบบเมทริกซ์เชิงตัวเลขถูกนำมาแปลงเป็นภาพสี (Heatmap) บนหน้า Dashboard เพื่อช่วยให้ผู้ใช้งานสามารถตีความการกระจายตัวของความร้อนได้ง่ายขึ้น การแปลงข้อมูลดังกล่าวเป็นการเพิ่มความละเอียดเชิงการแสดงผล (Display Resolution) โดยไม่กระทบต่อค่าจริงของข้อมูลจากเซนเซอร์ ขณะที่ผลการทำนายของแบบจำลองถูกแสดงในรูปแบบข้อความและแถบแสดงค่าความน่าจะเป็น เพื่อให้ผู้ใช้งานสามารถประเมินระดับความเสี่ยงของสถานการณ์ที่ตรวจพบได้อย่างชัดเจน ดังแสดงในภาพที่ 3-6

ในกระบวนการแสดงผลข้อมูลจากกล้องถ่ายภาพความร้อน ข้อมูลอุณหภูมิจากเซนเซอร์ MLX90640 ซึ่งอยู่ในรูปแบบเมทริกซ์เชิงตัวเลขขนาด 32×24 ถูกนำมาปรับสเกลค่าเพื่อการแสดงผล โดยใช้กระบวนการ normalization เพื่อแปลงค่าอุณหภูมิให้อยู่ในช่วงเดียวกันก่อนนำไปแปลงเป็นสีบนภาพ Heatmap ดังสมการ

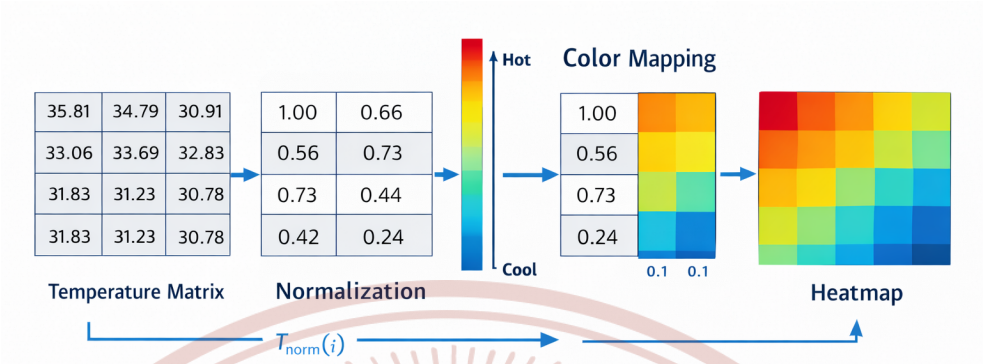
$$T_{norm}(i) = \frac{T_{(i)} - T_{(min)}}{T_{(max)} - T_{(min)}} \quad (3\text{-}1)$$

โดยที่

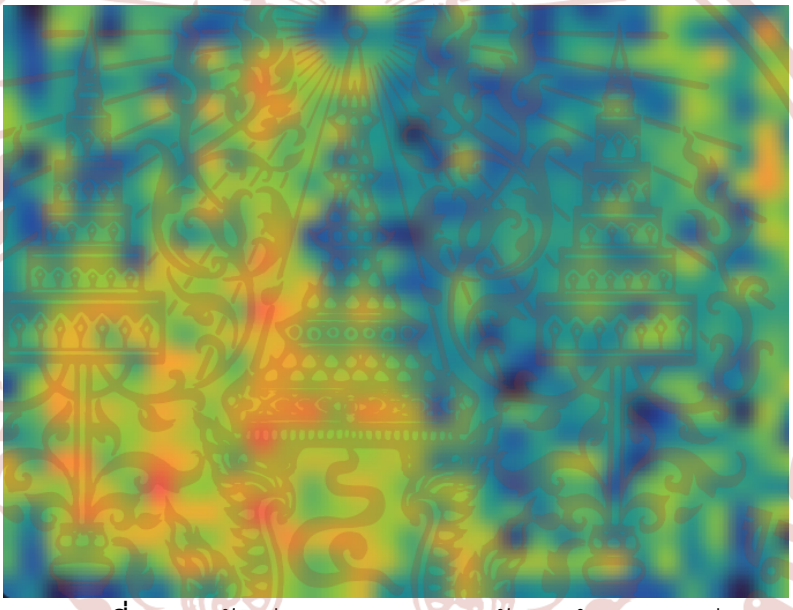
$T_{(i)}$ คือ ค่าอุณหภูมิของพิกเซลตำแหน่งที่ i

$T_{(max)}, T_{(min)}$ คือ ค่าอุณหภูมิต่ำสุดและสูงสุดในเฟรมเดียวกัน

สมการนี้ถูกนำมาใช้ในขั้นตอนการแปลงข้อมูลบนฝั่งเซิร์ฟเวอร์ก่อนส่งไปยังแดชบอร์ด



ภาพที่ 3-9 การแปลงข้อมูลอุณหภูมิเป็นรูปภาพ Heatmap



ภาพที่ 3-10 ตัวอย่างรูป Heatmap หลังจากทำการแปลงค่า

การปรับสเกลดังกล่าวเป็นการเพิ่มความชัดเจนเชิงการแสดงผล (Visualization Enhancement) เพื่อให้ผู้ใช้งานสามารถตีความการกระจายตัวของความร้อนได้ง่ายขึ้น โดยไม่ได้เป็นการเพิ่มความละเอียดจริงของข้อมูลจากเซนเซอร์

กระบวนการแปลงข้อมูลอุณหภูมิเป็นภาพความร้อนสามารถอธิบายเชิงขั้นตอนได้ดังอัลกอริทึม 3-3

อัลกอริทึม 3-3: การสร้างภาพ Heatmap

ข้อมูลนำเข้า (Input): เมทริกซ์ภาพความร้อน (32×24)
ข้อมูลส่งออก (Output): ภาพ Heatmap สำหรับแสดงผลบน Dashboard

1: รับเมทริกซ์ข้อมูลพิกเซลภาพความร้อนจากเซิร์ฟเวอร์
2: คำนวณค่าความร้อนต่ำสุดและค่าสูงสุดภายในเฟรมข้อมูล
3: ปรับสเกลค่าพิกเซลด้วยวิธี Min–Max Normalization
4: ปรับขนาดเมทริกซ์ภาพความร้อนด้วยวิธี Bilinear Interpolation
5: ใช้ตัวกรองลดสัญญาณรบกวนเพื่อปรับภาพให้มีความเรียบมากขึ้น
6: แปลงค่าที่ผ่านการปรับสเกลให้เป็นช่วงสีตาม Heatmap Color Scale
7: แสดงผลภาพ Heatmap บนส่วนติดต่อผู้ใช้ของแดชบอร์ด

3.3.3 การพัฒนาระบบเพื่อเก็บข้อมูล Dataset

การพัฒนาระบบเพื่อเก็บข้อมูลชุดข้อมูล (Dataset) มีวัตถุประสงค์เพื่อรองรับการฝึกสอนและการประเมินประสิทธิภาพของแบบจำลอง Machine Learning และ Deep Learning ในงานวิจัยนี้ โดยระบบเก็บข้อมูลถูกออกแบบให้ทำงานแยกจากโหมดการใช้งานจริงของระบบตรวจจับ เพื่อให้สามารถบันทึกข้อมูลดิบจากเซนเซอร์ได้อย่างครบถ้วน มีความถูกต้อง และไม่กระทบต่อความเสถียรของการทำงานแบบเรียลไทม์

ข้อมูลถูกเก็บจากเซนเซอร์กล้องถ่ายภาพความร้อน MLX90640 และเซนเซอร์เรดาร์คลื่นมิลลิเมตร HLK-LD2410C โดยมีไมโครคอนโทรลเลอร์ ESP32 ทำหน้าที่เป็นศูนย์กลางในการรวบรวมข้อมูลจากทั้งสองแหล่ง ข้อมูลจากกล้องความร้อนอยู่ในรูปแบบอาร์เรย์ของค่าพิกเซลอุณหภูมิขนาด 32×24 พิกเซล ขณะที่ข้อมูลจากเรดาร์ประกอบด้วยสถานะการเคลื่อนไหว ระยะทาง และค่าพลังงานของสัญญาณสะท้อนในแต่ละช่วงระยะ ข้อมูลทั้งหมดถูกจัดโครงสร้างให้อยู่ในรูปแบบข้อมูลเชิงโครงสร้าง เช่น JSON หรือไฟล์ตาราง เพื่อความสะดวกในการจัดเก็บ วิเคราะห์ และนำไปใช้งานในขั้นตอนการเตรียมข้อมูล

เพื่อให้ชุดข้อมูลมีความเหมาะสมต่อการนำไปใช้พัฒนาแบบจำลอง ข้อมูลที่จัดเก็บถูกกำหนดคุณลักษณะ (feature) อย่างชัดเจนจากทั้งสองเซนเซอร์ และรวมข้อมูลด้านเวลาเพื่อรองรับการวิเคราะห์เชิงลำดับ ข้อมูลเชิงโครงสร้างดังกล่าวช่วยให้สามารถผสานข้อมูลจากหลายเซนเซอร์ (sensor fusion) และนำไปใช้เป็นข้อมูลนำเข้าให้กับแบบจำลองได้อย่างเป็น

ระบบ รายละเอียดของโครงสร้างข้อมูลและคุณลักษณะที่ใช้ในการสร้างชุดข้อมูลสรุปไว้ในตารางที่ 3-1

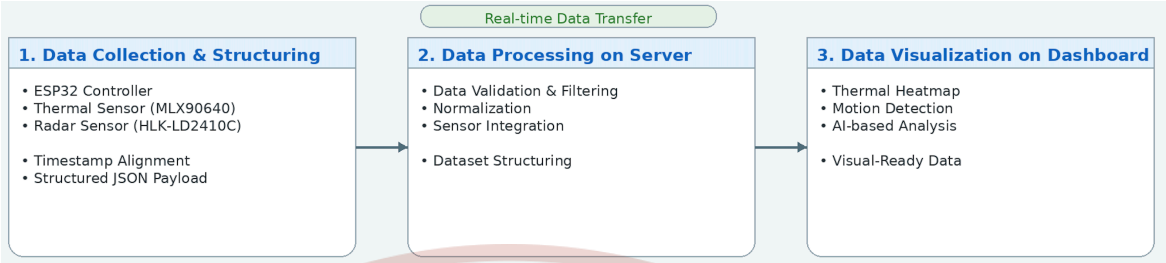
การกำหนดป้ายกำกับข้อมูล (ground truth) ดำเนินการภายใต้เงื่อนไขการทดลองที่ควบคุมไว้ล่วงหน้า เพื่อให้ข้อมูลกำกับมีความถูกต้องและสอดคล้องกับสถานการณ์จริง ชุดข้อมูลถูกออกแบบให้ครอบคลุมสถานการณ์ที่หลากหลาย เช่น กรณีไม่มีบุคคล การมีอยู่ของบุคคลทั่วไป และสถานการณ์ที่มีแนวโน้มการพกพาอาวุธ ทั้งนี้เพื่อช่วยลดอคติของข้อมูลและเพิ่มความสามารถในการทั่วไปของแบบจำลองที่พัฒนาขึ้น

ชุดข้อมูลที่ได้จากระบบเก็บข้อมูลนี้ถูกนำไปใช้ในขั้นตอนการฝึกสอน การตรวจสอบ และการทดสอบแบบจำลอง Machine Learning และ Deep Learning ซึ่งรายละเอียดของการพัฒนาและการประเมินแบบจำลองจะอธิบายเพิ่มเติมในหัวข้อถัดไปของบทนี้และในบทที่ 4

ตารางที่ 3-1 โครงสร้างข้อมูลชุดข้อมูลและการกำหนดคุณลักษณะของข้อมูล

Feature Name	Data Type	Dimension	Source Sensor	Description
timestamp	datetime	1	System	Time of data acquisition
thermal_pixel	float	768 (32×24)	MLX90640	Raw thermal pixel values
motion	boolean	1	LD2410C	Motion detection status
motion_distance	integer	1	LD2410C	Estimated target distance (cm)
motion_energy	float	1	LD2410C	Energy of moving target
static_energy	float	1	LD2410C	Energy of static target
eng_move_gate_energy	float	8	LD2410C	Radar energy per moving gate
eng_static_gate_energy	float	8	LD2410C	Radar energy per static gate
label	categorical	1	Manual	Ground truth class label

ในงานวิจัยนี้ ข้อมูลจากเซนเซอร์ภาพความร้อน MLX90640 และเซนเซอร์เรดาร์คลื่นมิลลิเมตร HLK-LD2410 ถูกนำมาใช้ร่วมกันเพื่อเพิ่มความแม่นยำในการตรวจจับ โดยข้อมูลจากทั้งสองเซนเซอร์ถูกนำมาสร้างเป็นคุณลักษณะ (features) สำหรับการฝึกแบบจำลอง Machine Learning ในบางขั้นตอนของกระบวนการตรวจจับ โดยเฉพาะในขั้นตอนการตรวจสอบการพกพาอาวุธ ซึ่งการผสานข้อมูลจากหลายเซนเซอร์ (Sensor Fusion) สามารถช่วยเพิ่มความสามารถในการจำแนกสถานการณ์ที่ซับซ้อนได้



ภาพที่ 3-11 Dataset Collection Pipeline



ภาพที่ 3-12 ตัวอย่างการเก็บข้อมูลจากกล้องถ่ายภาพความร้อนและเซนเซอร์เรดาร์ภายใต้สถานการณ์ทดลองที่ควบคุมตัวแปร

ขั้นตอนการเก็บข้อมูลเพื่อสร้างชุดข้อมูลสำหรับฝึกแบบจำลองสามารถสรุปได้ดัง Algorithm 3-4

อัลกอริทึม 3-4 การเก็บรวบรวมชุดข้อมูล (Dataset Collection)
ข้อมูลนำเข้า (Input):
กระแสข้อมูลจากเซนเซอร์หลายประเภท (Multi-sensor data streams)
ข้อมูลส่งออก (Output):
ชุดข้อมูลที่มีการกำกับป้ายกำกับ (Labeled dataset) สำหรับการฝึกแบบจำลอง Machine Learning / Deep Learning

1: เริ่มต้นโหมดการเก็บข้อมูลบนไมโครคอนโทรลเลอร์ ESP32
2: อ่านข้อมูลจากเซนเซอร์ภาพความร้อนและเรดาร์พร้อมกัน (synchronized)
3: เพิ่มค่าประทับเวลา (timestamp) ให้กับแต่ละรายการข้อมูล
4: จัดเก็บข้อมูลเซนเซอร์ดิบในรูปแบบโครงสร้าง เช่น JSON หรือ CSV
5: กำหนดป้ายกำกับข้อมูล (ground truth label) ตามสถานการณ์การทดลอง
6: ตรวจสอบความครบถ้วนและความสอดคล้องของข้อมูล
7: เพิ่มรายการข้อมูลลงในคลังชุดข้อมูล (dataset repository)
8: ทำซ้ำขั้นตอนที่ 2–7 จนกว่าขนาดของชุดข้อมูลจะเพียงพอ

3.3.4 การพัฒนาแบบจำลอง Machine Learning และ Deep Learning สำหรับการตรวจสอบการมีอยู่ของบุคคล

การตรวจสอบการมีอยู่ของบุคคลถูกกำหนดให้เป็นขั้นตอนแรกของกระบวนการตรวจจับ (Stage 1) โดยมีวัตถุประสงค์เพื่อคัดกรองสถานการณ์เบื้องต้นก่อนเข้าสู่กระบวนการวิเคราะห์การพกพาอาวุธในขั้นตอนถัดไป แบบจำลองในขั้นตอนนี้ถูกพัฒนาขึ้นจากข้อมูลที่ได้จากเซนเซอร์เรดาร์คลื่นมิลลิเมตร (Millimeter-wave Radar) และข้อมูลภาพความร้อนจากกล้อง MLX90640 โดยมีเป้าหมายเพื่อจำแนกสถานะของพื้นที่ตรวจจับออกเป็นสองกรณี ได้แก่ การมีอยู่ของบุคคล (Person) และ การไม่มีบุคคล (No-Person)

การกำหนดให้มีขั้นตอนการตรวจสอบการมีอยู่ของบุคคลก่อนเข้าสู่กระบวนการตรวจสอบการพกพาอาวุธช่วยลดภาระการประมวลผลของระบบโดยรวม เนื่องจากข้อมูลจะถูกส่งต่อไปยังขั้นตอนการวิเคราะห์อาวุธเฉพาะในกรณีที่ระบบตรวจพบการมีอยู่ของบุคคลเท่านั้น แนวทางดังกล่าวช่วยลดการประมวลผลที่ไม่จำเป็น ลดโอกาสการแจ้งเตือนผิดพลาดจากข้อมูล

ที่ไม่เกี่ยวข้อง และช่วยเพิ่มประสิทธิภาพในการทำงานของระบบให้สามารถตอบสนองแบบเกือบเรียลไทม์ได้

เพื่อพัฒนาระบบตรวจจับให้มีความแม่นยำและเหมาะสมกับสภาพแวดล้อมการใช้งานจริง งานวิจัยนี้ได้พัฒนาและเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่องหลายประเภท ได้แก่ Logistic Regression, Linear Support Vector Classifier (LinearSVC) ที่ใช้เทคนิค probability calibration, Random Forest, ExtraTrees และ XGBoost โดยแบบจำลองเหล่านี้ถูกนำมาใช้สำหรับการจำแนกข้อมูลเชิงตัวเลขที่ได้จากเซนเซอร์เรดาร์และข้อมูลภาพความร้อนที่ถูกแปลงเป็นคุณลักษณะเชิงสถิติ เนื่องจากสามารถจัดการข้อมูลที่มีมิติสูงได้ดีและให้ผลลัพธ์ที่มีความเสถียร

นอกจากนี้ งานวิจัยยังได้พัฒนาแบบจำลอง Convolutional Neural Network เพื่อใช้วิเคราะห์ข้อมูลภาพความร้อนในรูปแบบเมทริกซ์สองมิติ เนื่องจาก CNN มีความสามารถในการเรียนรู้ลักษณะเชิงพื้นที่ของข้อมูลภาพ เช่น รูปแบบการกระจายตัวของอุณหภูมิที่เกิดจากร่างกายมนุษย์ ซึ่งเป็นลักษณะสำคัญในการจำแนกการมีอยู่ของบุคคล

การเลือกใช้และเปรียบเทียบแบบจำลองหลายประเภทดังกล่าวช่วยให้สามารถประเมินความเหมาะสมของแต่ละแนวทางได้อย่างครอบคลุม ทั้งในด้านความแม่นยำของการจำแนก ความสามารถในการเรียนรู้รูปแบบข้อมูลที่ซับซ้อน และข้อจำกัดด้านทรัพยากรการประมวลผลของระบบ ซึ่งมีความสำคัญต่อการนำระบบไปประยุกต์ใช้งานจริงในสภาพแวดล้อมภายในอาคาร โดยผลการเปรียบเทียบประสิทธิภาพของแบบจำลองแต่ละประเภทจะนำเสนอในบทที่ 4

3.3.5 การพัฒนาแบบจำลอง Machine Learning สำหรับการตรวจสอบการพกพาอาวุธ

เมื่อระบบตรวจพบการมีอยู่ของบุคคลจากขั้นตอนแรกแล้ว ข้อมูลที่เกี่ยวข้องจะถูกส่งเข้าสู่ขั้นตอนการตรวจสอบการพกพาอาวุธ (Stage 2) ซึ่งเป็นขั้นตอนหลักของระบบอัจฉริยะที่พัฒนาขึ้นในงานวิจัยนี้ แบบจำลองในขั้นตอนนี้ถูกออกแบบให้สามารถวิเคราะห์ลักษณะเชิงรูปแบบจากข้อมูลภาพความร้อนร่วมกับข้อมูลจากเซนเซอร์เรดาร์ เพื่อประเมินแนวโน้มการพกพาอาวุธของบุคคลที่ตรวจพบ

การพัฒนาแบบจำลองในขั้นตอนนี้มุ่งเน้นการแยกแยะความแตกต่างระหว่างบุคคลทั่วไปและบุคคลที่มีความเสี่ยงจากการพกพาอาวุธ โดยอาศัยทั้งคุณลักษณะเชิงพื้นที่จากภาพความร้อนและคุณลักษณะด้านการเคลื่อนไหวจากเรดาร์ ผลลัพธ์จากการทำนายจะถูกส่งไปแสดงผลบนหน้า Dashboard เพื่อสนับสนุนการรับรู้สถานการณ์และการตัดสินใจของผู้ใช้งาน

ทั้งนี้ การออกแบบระบบการตรวจจับแบบสองขั้นตอนดังกล่าวช่วยเพิ่มความแม่นยำ และความเหมาะสมของระบบในการนำไปประยุกต์ใช้งานจริงด้านความปลอดภัยในพื้นที่ปิด

ตารางที่ 3-2 การเชื่อมโยงแบบจำลอง ชนิดข้อมูล และขั้นตอนการตรวจจับ

Model	Data Type	Input Representation	Detection Stage	Purpose
Logistic Regression	Radar และ Thermal (features)	เวกเตอร์คุณลักษณะเชิงตัวเลขจากเซนเซอร์	Stage 1, Stage 2	แบบจำลองพื้นฐานสำหรับการจำแนกข้อมูลแบบทวิภาค
LinearSVC (Calibrated)	Radar และ Thermal (features)	เวกเตอร์คุณลักษณะที่ผ่านการปรับสเกล	Stage 1, Stage 2	แบบจำลอง SVM เชิงเส้นที่ปรับค่า probability เพื่อใช้ในการประเมินผล
Random Forest (RF)	Radar และ Thermal (features)	เวกเตอร์คุณลักษณะเชิงสถิติและค่าจากเรดาร์	Stage 1, Stage 2	แบบจำลอง Ensemble ที่สามารถจัดการข้อมูลหลายมิติได้ดี
ExtraTrees	Radar และ Thermal (features)	เวกเตอร์คุณลักษณะจากเซนเซอร์	Stage 1, Stage 2	แบบจำลอง Ensemble ที่ใช้การสุ่มสูงเพื่อลด overfitting
XGBoost	Radar และ Thermal (features)	เวกเตอร์คุณลักษณะจากเซนเซอร์	Stage 1, Stage 2	แบบจำลอง Gradient Boosting สำหรับเพิ่มประสิทธิภาพการจำแนก
Convolutional Neural Network (CNN)	Thermal image	ภาพความร้อนแบบสองมิติ (Heatmap 32×24)	Stage 1, Stage 2	การสกัดคุณลักษณะเชิงพื้นที่จากภาพความร้อน

3.4 การประเมินผลระบบ

การประเมินผลระบบในงานวิจัยนี้มีวัตถุประสงค์เพื่อยืนยันว่าระบบตรวจจับอัจฉริยะที่พัฒนาขึ้นสามารถทำงานได้ตามกรอบแนวคิดและการออกแบบที่กำหนดไว้ในบทที่ 3 โดยการประเมินจะครอบคลุมทั้งในระดับของแบบจำลองการเรียนรู้ของเครื่อง (model-level evaluation) และในระดับของระบบโดยรวม (system-level evaluation) ภายใต้สถานการณ์ทดลองที่ควบคุมตัวแปรอย่างเหมาะสม เพื่อให้ผลการประเมินมีความน่าเชื่อถือและสามารถนำไปใช้สะท้อนศักยภาพของระบบได้อย่างเป็นระบบ

การประเมินผลถูกออกแบบให้สอดคล้องกับกระบวนการตรวจจับแบบสองขั้นตอน (Two-Stage Detection) ได้แก่

1. การตรวจสอบการมีอยู่ของบุคคล
2. การประเมินแนวโน้มการพกพาอาวุธ

โดยมีการกำหนดตัวชี้วัด ฉากการทดลอง และขั้นตอนการทดสอบที่ชัดเจน ดังรายละเอียดต่อไป

3.4.1 วัตถุประสงค์ของการประเมินผล (Evaluation Objectives)

การประเมินผลระบบในงานวิจัยนี้มีวัตถุประสงค์หลักดังต่อไปนี้

1. เพื่อประเมินความสามารถของระบบในการตรวจสอบการมีอยู่ของบุคคลในพื้นที่ตรวจจับ (Stage 1)
2. เพื่อประเมินความสามารถของระบบในการจำแนกสถานการณ์ที่มีแนวโน้มการพกพาอาวุธ (Stage 2)
3. เพื่อประเมินการทำงานของระบบในเชิงระบบสารสนเทศ เช่น ความต่อเนื่องของการรับ–ส่งข้อมูล และเวลาแฝงในการประมวลผล
4. เพื่อศึกษาความเหมาะสมของระบบภายใต้สถานการณ์ทดลองที่มีตัวแปรด้านระยะ มุมมอง และลักษณะการแต่งกายที่แตกต่างกัน

ดังกล่าวถูกนำไปใช้เป็นกรอบในการกำหนดตัวชี้วัดและการออกแบบขั้นตอนการทดสอบในหัวข้อถัดไป

3.4.2 ตัวชี้วัดและเมตริกที่ใช้ในการประเมิน (Evaluation Metrics)

การประเมินผลในงานวิจัยนี้ใช้ตัวชี้วัดทั้งเชิงการจำแนก (classification metrics) และเชิงระบบ (system performance metrics) เพื่อสะท้อนประสิทธิภาพของระบบในหลายมิติ ได้แก่

- Accuracy ใช้ประเมินความถูกต้องโดยรวมของการจำแนก
- Precision ใช้ประเมินความถูกต้องของการแจ้งเตือนในแต่ละคลาส
- Recall ใช้ประเมินความสามารถในการตรวจจับเหตุการณ์ที่เกิดขึ้นจริง
- F1-score ใช้เป็นตัวชี้วัดสมดุลระหว่าง Precision และ Recall
- Confusion Matrix ใช้แสดงรูปแบบความผิดพลาดของการจำแนกในแต่ละคลาส
- Latency (End-to-End Delay) ใช้ประเมินเวลาแฝงตั้งแต่การรับข้อมูลจากอุปกรณ์ IoT จนถึงการแสดงผลบน Dashboard

Frame Rate / Throughput ใช้ประเมินความต่อเนื่องของการประมวลผลข้อมูลแบบเรียลไทม์

ตัวชี้วัดเหล่านี้ถูกเลือกใช้เพื่อรองรับลักษณะของปัญหาด้านความปลอดภัย ซึ่งต้องคำนึงถึงทั้งความถูกต้องของการตรวจจับและความพร้อมใช้งานของระบบในเชิงปฏิบัติ

3.4.3 ฉากทดสอบและสถานการณ์ทดลอง (Test Scenarios)

เพื่อให้การประเมินผลเป็นไปอย่างเป็นระบบ งานวิจัยนี้ได้กำหนดฉากการทดลอง (test scenarios) ที่ครอบคลุมสถานการณ์พื้นฐานและสถานการณ์ที่มีความซับซ้อน โดยควบคุมตัวแปรด้านสภาพแวดล้อมให้คงที่ และเปลี่ยนแปลงเฉพาะตัวแปรที่เกี่ยวข้องกับการตรวจจับ ดังแสดงในตารางที่ 3-3

ตารางที่ 3-3 สถานการณ์ทดลองสำหรับการประเมินระบบ

Scenario ID	สภาพแสง	บุคคล	ประเภทอาวุธ	ระยะทาง	Ground Truth
S1	กลางวัน	ไม่มี	ไม่มี	1–3 m	No Person
S2	กลางวัน	1 คน	ไม่มี	1–3 m	Person
S3	กลางวัน	1 คน	ปืนจำลอง	1–3 m	Gun

ตารางที่ 3-3 (ต่อ)

Scenario ID	สภาพแสง	บุคคล	ประเภทอาวุธ	ระยะทาง	Ground Truth
S4	กลางวัน	1 คน	มีดจำลอง	1–3 m	Knife
S1	กลางคืน	ไม่มี	ไม่มี	1–3 m	No Person
S2	กลางคืน	1 คน	ไม่มี	1–3 m	Person
S3	กลางคืน	1 คน	ปืนจำลอง	1–3 m	Gun
S4	กลางคืน	1 คน	มีดจำลอง	1–3 m	Knife



ภาพที่ 3-13 ตัวอย่างอุปกรณ์จำลองที่ใช้ในการกำหนดสถานการณ์ทดลอง (ใช้เพื่อการวิจัยเท่านั้น)



ภาพที่ 3-14 ตัวอย่างการทดสอบตามสภาพแวดล้อมในที่มืดและมีแสง

3.4.4 ขั้นตอนการทดสอบ (Test Protocol)

ขั้นตอนการทดสอบระบบถูกออกแบบให้เป็นลำดับขั้นอย่างชัดเจน เพื่อให้สามารถทำซ้ำการทดลองได้และตรวจสอบความถูกต้องของผลการประเมิน โดยมีขั้นตอนดังนี้

- เตรียมสภาพแวดล้อมการทดลอง โดยควบคุมอุณหภูมิห้องให้อยู่ในช่วง 24–26°C และกำหนดเงื่อนไขสภาพแสง 2 รูปแบบ ได้แก่ สภาพแสงกลางวัน และสภาพแสงมืด/แสงน้อย เพื่อศึกษาผลกระทบของสภาพแสงต่อประสิทธิภาพของระบบตรวจจับ
- ติดตั้งอุปกรณ์ตรวจจับในตำแหน่งที่กำหนด และตรวจสอบการทำงานของเซนเซอร์กล้องความร้อนและเรดาร์
- กำหนดฉากการทดลองตามตารางสถานการณ์ทดลอง และทำการทดสอบซ้ำในแต่ละฉากตามจำนวนรอบที่กำหนด
- บันทึกข้อมูลจากเซนเซอร์ในรูปแบบข้อมูลเชิงโครงสร้าง พร้อมกำหนดป้ายกำกับข้อมูล (ground truth) ให้สอดคล้องกับสถานการณ์จริง
- ประเมินผลในระดับแบบจำลอง โดยใช้ชุดข้อมูลทดสอบและตัวชี้วัดที่กำหนด

ขั้นตอนดังกล่าวช่วยให้การประเมินผลสะท้อนทั้งความสามารถของแบบจำลองและความเหมาะสมของระบบในเชิงการใช้งานจริง

3.4.5 การเชื่อมโยงคำถามวิจัยกับตัวชี้วัด (Research Question–Metric Mapping)

เพื่อให้การประเมินผลสามารถตอบคำถามวิจัยได้อย่างเป็นระบบ งานวิจัยนี้ได้กำหนดความเชื่อมโยงระหว่างคำถามวิจัย ตัวชี้วัด และระดับการประเมิน ดังแสดงในตารางที่ 3-4

ตารางที่ 3-4 การเชื่อมโยงคำถามวิจัยกับตัวชี้วัด

คำถามวิจัย	ระดับการตรวจจับ	ตัวชี้วัดที่ใช้	วัตถุประสงค์
การตรวจสอบการมีอยู่ของบุคคลมีความเหมาะสมเพียงใด	Stage 1	Precision, Recall, F1-score	ประเมินการคัดกรองบุคคล
ระบบสามารถจำแนกแนวโน้มการพกพาอาวุธได้หรือไม่	Stage 2	Confusion Matrix, Macro F1-score	ประเมินการจำแนกหลายคลาส
ระบบสามารถทำงานแบบเรียลไทม์ได้หรือไม่	System	Latency, Frame Rate	ประเมินความพร้อมใช้งาน
ระบบมีความเหมาะสมต่อการใช้งานในหลายสถานการณ์หรือไม่	System	Performance/Scenario	ประเมินความเสถียร

3.5 สถิติที่ใช้ในการวิเคราะห์ข้อมูล

การวิเคราะห์ข้อมูลในงานวิจัยนี้ใช้สถิติพื้นฐานและสถิติเชิงประเมินผล (Evaluation statistics) เพื่ออธิบายลักษณะของข้อมูล ตรวจสอบความเหมาะสมของชุดข้อมูล และประเมินผลการทำงานของแบบจำลองการเรียนรู้ของเครื่องและระบบตรวจจับอัจฉริยะโดยรวม สถิติที่เลือกใช้มีความเหมาะสมกับลักษณะของข้อมูลจากเซนเซอร์หลายประเภท และสอดคล้องกับวัตถุประสงค์ของการประเมินผลที่กำหนดไว้ในหัวข้อ 3.4

สถิติที่ใช้ในการวิเคราะห์ข้อมูลสามารถแบ่งออกเป็น 2 กลุ่มหลัก ได้แก่

(1) สถิติเชิงพรรณนา

(2) สถิติเชิงประเมินผลการจำแนก

3.5.1 สถิติเชิงพรรณนา (Descriptive Statistics)

สถิติเชิงพรรณนาถูกนำมาใช้เพื่ออธิบายลักษณะพื้นฐานของข้อมูลที่ได้จากเซนเซอร์กล้องถ่ายภาพความร้อนและเซนเซอร์เรดาร์ก่อนนำไปใช้ในการฝึกและทดสอบแบบจำลอง โดยสถิติที่ใช้ประกอบด้วย

ค่าเฉลี่ย (Mean) ใช้อธิบายแนวโน้มค่ากลางของข้อมูลอุณหภูมิและพลังงานการสะท้อนจากเรดาร์

$$\overline{X} = \frac{\sum_{i=1}^{n} x_i}{n} \quad (3\text{-}2)$$

เมื่อกำหนดให้

$\overline{X}$ หมายถึง ค่าเฉลี่ยเลขคณิต

$\sum_{i=1}^{n} x_i$ หมายถึง ผลรวมของกลุ่มข้อมูลทั้งหมด

n หมายถึง จำนวนข้อมูล

ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) ใช้แสดงความกระจายตัวของข้อมูล เพื่อสะท้อนความแปรผันของสัญญาณจากเซนเซอร์

$$S.D. = \sqrt{\frac{\sum_{i=1}^{n}(x_i - \overline{x})}{n-1}} \quad (3\text{-}3)$$

เมื่อกำหนดให้

S.D.	หมายถึง ค่าเฉลี่ยเบี่ยงเบนมาตรฐานของกลุ่มตัวอย่าง
x_i	หมายถึง ข้อมูลของแต่ละจำนวน
$\overline{X}$	หมายถึง ค่าเฉลี่ยเลขคณิต
$\sum_{i=1}^{n} x_i$	หมายถึง ผลรวมของกลุ่มข้อมูลทั้งหมด
n	หมายถึง จำนวนข้อมูล

สถิติเหล่านี้ช่วยให้สามารถตรวจสอบความสม่ำเสมอของข้อมูล ระบุความผิดปกติของสัญญาณ และประเมินความเหมาะสมของข้อมูลก่อนนำไปใช้ในกระบวนการวิเคราะห์ขั้นสูง

3.5.2 สถิติเชิงประเมินผลการจำแนก (Classification Evaluation Statistics)

เพื่อประเมินประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกในการตรวจจับการมีอยู่ของบุคคลและการประเมินแนวโน้มการพกพาอาวุธ งานวิจัยนี้ใช้สถิติที่ได้จากเมทริกซ์ความสับสน (Confusion Matrix) เป็นพื้นฐานในการคำนวณตัวชี้วัด ดังนี้

กำหนดให้

TP = True Positive

TN = True Negative

FP = False Positive

FN = False Negative

- Accuracy ใช้แสดงสัดส่วนของผลการจำแนกที่ถูกต้องเมื่อเทียบกับจำนวนตัวอย่างทั้งหมด

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3\text{-}4)$$

- Precision ใช้แสดงสัดส่วนของข้อมูลที่ระบบจำแนกว่าเป็นคลาสเป้าหมาย และเป็นคลาสนั้นจริง

$$Precision = \frac{TP}{TP+FP} \quad (3\text{-}5)$$

- Recall (Sensitivity) ใช้แสดงความสามารถของระบบในการตรวจจับเหตุการณ์ที่เกิดขึ้นจริง โดยเฉพาะเหตุการณ์ที่มีความสำคัญด้านความปลอดภัย

$$Recall = \frac{TP}{TP+FN} \quad (3\text{-}6)$$

- F1-score ใช้เป็นค่ากลางระหว่าง Precision และ Recall เพื่อสะท้อนสมดุลของการแจ้งเตือนและการตรวจจับ

$$F_{1score} = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad (3\text{-}7)$$

สถิติเหล่านี้ถูกเลือกใช้เนื่องจากเหมาะสมกับลักษณะของปัญหาด้านความปลอดภัย ซึ่งต้องให้ความสำคัญกับการตรวจจับเหตุการณ์สำคัญมากกว่าการพิจารณาความถูกต้องโดยรวมเพียงอย่างเดียว

บทที่ 4
ผลการดำเนินงานวิจัย

บทนี้นำเสนอผลการดำเนินงานและผลการทดลองของระบบตรวจจับอัจฉริยะสำหรับการตรวจสอบการมีอยู่ของบุคคลและการประเมินแนวโน้มการพกพาอาวุธในพื้นที่ โดยอ้างอิงกระบวนการประเมินผล สถานการณ์ทดลอง และตัวชี้วัดทางสถิติที่ได้กำหนดไว้ในบทที่ 3.4 และบทที่ 3.5 ผลการวิเคราะห์ครอบคลุมทั้งในระดับของแบบจำลองการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก รวมถึงในระดับของระบบโดยรวม เพื่อสะท้อนความสามารถของระบบภายใต้เงื่อนไขการทดลองที่หลากหลาย

4.1 ผลการตรวจสอบการมีอยู่ของบุคคล (Stage 1: Person Detection)

การตรวจสอบการมีอยู่ของบุคคลเป็นขั้นตอนแรกของกระบวนการตรวจจับแบบลำดับขั้น (Hierarchical Detection) โดยมีวัตถุประสงค์เพื่อคัดกรองข้อมูลก่อนเข้าสู่ขั้นตอนการประเมินการพกพาอาวุธในขั้นตอนถัดไป การตรวจจับในขั้นตอนนี้ทำหน้าที่ระบุว่าภายในพื้นที่ตรวจจับมีบุคคลอยู่หรือไม่ ซึ่งช่วยลดภาระการประมวลผลของระบบในขั้นตอนการจำแนกอาวุธ

ผลการทดลองในขั้นตอนนี้ถูกประเมินโดยใช้ตัวชี้วัดทางสถิติ ได้แก่ Accuracy, Precision, Recall และ F1-score รวมถึงการวิเคราะห์ Confusion Matrix เพื่อศึกษาลักษณะความผิดพลาดของแบบจำลองในสถานการณ์ต่าง ๆ เช่น การตรวจจับบุคคลในระยะที่แตกต่างกัน หรือมุมมองที่เอียงจากตำแหน่งการติดตั้งเซนเซอร์

ตารางที่ 4-1 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลองใน Stage 1

Model	Accuracy	Macro-F1
Logistic Regression	0.95	0.95
Linear SVC	0.95	0.95
Random Forest	0.98	0.98
Extra Trees	0.98	0.98
XGBoost	**0.99**	**0.99**

จากตารางที่ 4-1 พบว่าแบบจำลอง XGBoost ให้ผลลัพธ์ดีที่สุด โดยมีค่า Accuracy เท่ากับ 0.9956 และค่า Macro-F1 เท่ากับ 0.99 ซึ่งสูงกว่าแบบจำลองอื่นอย่างชัดเจน แสดงให้เห็นว่าแบบจำลองสามารถจำแนกสถานการณ์ระหว่าง “มีบุคคล” และ “ไม่มีบุคคล” ได้อย่างแม่นยำ

ผลการทดลองนี้สะท้อนให้เห็นว่าการผสานข้อมูลจาก กล้องถ่ายภาพความร้อน (Thermal Camera) และ เซนเซอร์เรดาร์ mmWave สามารถช่วยเพิ่มความสามารถในการตรวจจับการมีอยู่ของบุคคลได้อย่างมีประสิทธิภาพ และเหมาะสมสำหรับใช้เป็นขั้นตอนคัดกรองก่อนเข้าสู่การวิเคราะห์การพกพาอาวุธใน Stage 2

ตารางที่ 4-2 Confusion Matrix ของ Stage 1 (XGBoost)

Actual \ Predicted	No Person	Person
No Person	2033	19
Person	22	3652

จาก Confusion Matrix พบว่าแบบจำลองสามารถจำแนกบุคคลได้อย่างถูกต้องในจำนวนมาก โดยมีค่า True Positive เท่ากับ 3652 ขณะที่จำนวน False Negative เท่ากับ 22 ซึ่งหมายถึงกรณีที่ระบบไม่สามารถตรวจจับบุคคลได้แม้ว่าจะมีบุคคลอยู่จริง

จำนวน False Negative ที่ต่ำมากแสดงให้เห็นว่าแบบจำลองมีความสามารถในการตรวจจับบุคคลได้อย่างแม่นยำ ซึ่งเป็นคุณสมบัติที่สำคัญสำหรับระบบด้านความปลอดภัย เนื่องจากช่วยลดความเสี่ยงจากการพลาดเหตุการณ์ก่อนเข้าสู่ขั้นตอนการตรวจจับอาวุธใน Stage 2

ตารางที่ 4-3 ตัวชี้วัดประสิทธิภาพรายคลาสของ Stage 1 (XGBoost)

Class	Precision	Recall	F1-score	Support
No Person	0.98	0.99	0.99	2052
Person	0.99	0.99	0.99	3674
Macro Average	0.99	0.99	0.99	–
Overall Accuracy			0.99	5726

จากผลการทดลองพบว่าแบบจำลองมีค่า Precision และ Recall ของทั้งสองคลาสอยู่ในระดับสูงมาก โดยเฉพาะคลาส “Person” ซึ่งมีค่า Precision เท่ากับ 0.99 และ Recall เท่ากับ 0.9967 แสดงให้เห็นว่าระบบสามารถตรวจจับบุคคลได้อย่างแม่นยำและมีอัตราการพลาดการตรวจจับต่ำ

โดยรวมแล้วผลการทดลองใน Stage 1 แสดงให้เห็นว่าแบบจำลอง XGBoost สามารถทำหน้าที่เป็น ขั้นตอนคัดกรอง (Pre-screening Stage) ได้อย่างมีประสิทธิภาพก่อนที่จะส่งข้อมูลเข้าสู่ขั้นตอนการตรวจจับการพกพาอาวุธใน Stage 2

4.2 ผลการจำแนกแนวโน้มการพกพาอาวุธ (Stage 2: Weapon Risk Detection)

เมื่อระบบตรวจพบการมีอยู่ของบุคคลจากขั้นตอน Stage 1 แล้ว ข้อมูลจะถูกส่งเข้าสู่ขั้นตอนการจำแนกแนวโน้มการพกพาอาวุธ ซึ่งเป็นขั้นตอนหลักของงานวิจัยนี้ เพื่อประเมินความเสี่ยงด้านความปลอดภัยภายในพื้นที่ตรวจจับ

การทดลองในขั้นตอน Stage 2 ถูกออกแบบเป็น กระบวนการตรวจจับแบบสองลำดับขั้น (two-stage classification) เพื่อเพิ่มความแม่นยำและลดความซับซ้อนของปัญหาการจำแนก โดยประกอบด้วย

(1) การตรวจจับการพกพาอาวุธ (Weapon vs No-Weapon: Stage 2A)

(2) การจำแนกประเภทอาวุธ (Gun vs Knife: Stage 2B)

แนวทางดังกล่าวช่วยให้ระบบสามารถตอบคำถามเชิงลำดับได้อย่างเป็นระบบ ได้แก่ มีอาวุธหรือไม่ และ หากมีอาวุธ เป็นอาวุธประเภทใด ซึ่งสอดคล้องกับบริบทการใช้งานจริงด้านความปลอดภัย

ผลการประเมินในขั้นตอนนี้นำเสนอผ่านเมทริกซ์ความสับสน (Confusion Matrix) และค่าตัวชี้วัดเชิงสถิติ ได้แก่ Accuracy, Precision, Recall และ Macro-averaged F1-score โดยให้ความสำคัญกับค่า Macro-averaged F1-score เป็นหลัก เนื่องจากสามารถสะท้อนสมดุลของประสิทธิภาพในแต่ละคลาสภายใต้ชุดข้อมูลที่มีความไม่สมดุลของจำนวนตัวอย่างได้อย่างเหมาะสม

4.2.1 การตรวจจับการพกพาอาวุธ (Stage 2A: Weapon vs No-Weapon)

ขั้นตอน Stage 2A มีวัตถุประสงค์เพื่อจำแนกว่า บุคคลที่ถูกตรวจพบจาก Stage 1 มีแนวโน้มการพกพาอาวุธหรือไม่ โดยกำหนดเป็นปัญหาการจำแนกแบบสองคลาส ได้แก่

- ไม่มีอาวุธ (No-Weapon)
- มีอาวุธ (Weapon)

ขั้นตอนนี้ถือเป็นกลไกสำคัญในการประเมินความเสี่ยงเบื้องต้น ก่อนเข้าสู่การจำแนกประเภทอาวุธในขั้นตอนถัดไป

การทดลองได้ทำการเปรียบเทียบประสิทธิภาพของแบบจำลองหลายประเภท ได้แก่ Random Forest, ExtraTrees, Logistic Regression, LinearSVC และ XGBoost โดยแบบจำลอง XGBoost ใช้แนวทาง Early Fusion ซึ่งทำการผสานคุณลักษณะจากเซนเซอร์ MLX90640 thermal camera และ HLK-LD2410C mmWave radar ก่อนเข้าสู่กระบวนการจำแนก

ตารางที่ 4-4 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลองใน Stage 2A

Model	Accuracy	Macro-F1
Random Forest	0.90	0.90
ExtraTrees	0.89	0.89
Logistic Regression	0.74	0.74
LinearSVC	0.73	0.73
XGBoost (Early Fusion)	**0.94**	**0.94**

จากตารางที่ 4-4 พบว่า XGBoost ที่ใช้แนวทาง Early Fusion ให้ประสิทธิภาพสูงที่สุด โดยมีค่า Accuracy เท่ากับ 0.94 และ Macro-F1 เท่ากับ 0.94

ผลการทดลองแสดงให้เห็นว่าการผสานข้อมูลจากเซนเซอร์ทั้งสองชนิดสามารถช่วยเพิ่มความสามารถในการจำแนกสถานการณ์ที่มีการพกพาอาวุธได้อย่างมีนัยสำคัญ เนื่องจากข้อมูลจากเซนเซอร์ภาพความร้อนสามารถสะท้อนลักษณะการกระจายความร้อนของวัตถุ ขณะที่ข้อมูลจากเรดาร์สามารถสะท้อนพฤติกรรมการเคลื่อนไหวและตำแหน่งของวัตถุได้

ตารางที่ 4-5 Confusion Matrix ของ Stage 2A (XGBoost)

Actual \ Predicted	No-Weapon	Weapon
No-Weapon	1722	120
Weapon	78	1754

จากตารางที่ 4-5 พบว่าแบบจำลองสามารถจำแนกตัวอย่างที่ ไม่มีอาวุธได้ถูกต้องจำนวน 3,674 ตัวอย่าง และสามารถตรวจจับผู้ที่มีการพกพาอาวุธได้ถูกต้องจำนวน 1,754 ตัวอย่าง

จำนวนการจำแนกผิดมีค่าไม่มาก โดยมี False Positive จำนวน 120 ตัวอย่าง และ False Negative จำนวน 78 ตัวอย่าง ซึ่งสะท้อนให้เห็นว่าแบบจำลองมีความสามารถในการตรวจจับการพกพาอาวุธได้ในระดับที่ดี

ตารางที่ 4-6 ตัวชี้วัดประสิทธิภาพรายคลาสของ Stage 2A (XGBoost)

Class	Precision	Recall	F1-score	Support
No weapon	0.96	0.93	0.95	1842
Weapon	0.94	0.96	0.95	1832
Macro Average	0.95	0.95	0.95	–
Overall Accuracy			0.95	3674

แม้ว่าปัญหาการตรวจจับการพกพาอาวุธจะมีความซับซ้อน เนื่องจากลักษณะข้อมูลจากเซนเซอร์มีความหลากหลายและอาจมีความคล้ายคลึงกันระหว่างสถานการณ์ที่มีและไม่มีอาวุธ แต่ผลการทดลองแสดงให้เห็นว่าแบบจำลองสามารถจำแนกทั้งสองสถานการณ์ได้อย่างมีประสิทธิภาพเมื่อพิจารณาจากค่า Macro-F1 score

4.2.2 การจำแนกประเภทอาวุธ (Stage 2B: Gun vs Knife)

เมื่อระบบตรวจพบการพกพาอาวุธจากขั้นตอน Stage 2A แล้ว ข้อมูลจะถูกส่งเข้าสู่ขั้นตอนการจำแนกประเภทอาวุธใน Stage 2B โดยกำหนดเป็นปัญหาการจำแนกแบบสองคลาส ได้แก่ “ปืน (Gun)” และ “มีด (Knife)” เพื่อระบุระดับความเสี่ยงและลักษณะของอาวุธอย่างเฉพาะเจาะจงมากขึ้น

การทดลองในขั้นตอนนี้ได้ทำการเปรียบเทียบแบบจำลอง Random Forest, ExtraTrees, Logistic Regression, LinearSVC และ XGBoost

ที่ใช้ข้อมูลภาพความร้อนเพียงอย่างเดียว โดยผลการประเมินแสดงดังตารางที่ 4-7

ตารางที่ 4-7 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลองใน Stage 2B

Model	Accuracy	Macro-F1
Random Forest	0.91	0.91
ExtraTrees	0.90	0.90
Logistic Regression	0.85	0.85
LinearSVC	0.86	0.86
XGBoost	0.94	0.94

จากตารางที่ 4-7 พบว่าแบบจำลอง XGBoost ให้ประสิทธิภาพดีที่สุดในขั้นตอน Stage 2B โดยมีค่า Macro-F1 เท่ากับ 0.94

ผลลัพธ์ดังกล่าวแสดงให้เห็นว่า Random Forest สามารถจำแนกอาวุธสองประเภทที่มีลักษณะทางกายภาพและรูปแบบการกระจายความร้อนใกล้เคียงกันได้ดีกว่าแบบจำลองอื่น

ตารางที่ 4-8 Confusion Matrix ของ Stage 2B (Random Forest)

Actual \ Predicted	Gun	Knife
Gun	868	56
Knife	49	848

ตารางที่ 4-9 ตัวชี้วัดประสิทธิภาพรายคลาสของ Stage 2B (XGBoost)

Class	Precision	Recall	F1-score	Support
Gun	0.95	0.94	0.94	924
Knife	0.94	0.95	0.94	897
Macro Average	0.94	0.94	0.94	–
Overall Accuracy			0.94	1821

จากตาราง 4-8 พบว่าแบบจำลอง Random Forest สามารถจำแนกอาวุธประเภทมีดได้ถูกต้องจำนวน 848 ตัวอย่าง และอาวุธประเภทปืนได้ถูกต้องจำนวน 868 ตัวอย่าง แม้ว่าจะยังมีความสับสนบางส่วนระหว่างอาวุธสองประเภท โดยเฉพาะในกรณีที่อาวุธมีขนาดเล็กหรือถูกบดบังด้วยร่างกาย อย่างไรก็ตาม ผลลัพธ์โดยรวมยังคงแสดงถึงความสามารถในการจำแนกประเภทอาวุธได้อย่างมีประสิทธิภาพ

4.3 การวิเคราะห์ผลตามฉากการทดลอง (Scenario-Based Analysis)

เพื่อศึกษาความเหมาะสมของระบบภายใต้เงื่อนไขที่แตกต่างกัน ผลการทดลองถูกนำมาวิเคราะห์แยกตามฉากการทดลองที่กำหนดไว้ในบทที่ 3.4 ซึ่งประกอบด้วยตัวแปรด้านระยะทาง มุมมองการตรวจจับ และลักษณะการแต่งกายของบุคคล

ผลการวิเคราะห์ตามฉากการทดลองช่วยให้สามารถสังเกตแนวโน้มของการทำงานของระบบในสถานการณ์ที่มีความซับซ้อนแตกต่างกัน และสะท้อนให้เห็นถึงความสามารถของระบบในการรองรับการเปลี่ยนแปลงของสภาพแวดล้อมภายในพื้นที่ปิด การวิเคราะห์ในส่วนนี้ช่วยเสริมความเข้าใจเกี่ยวกับข้อจำกัดและศักยภาพของระบบในเชิงการใช้งานจริง

4.3.1 ผลการวิเคราะห์ตามฉากการทดลองในแต่ละขั้นตอนของระบบ

ผลการทดลองถูกสรุปแยกตามฉากการทดลอง โดยพิจารณาประสิทธิภาพของระบบในแต่ละขั้นตอน ได้แก่ Stage 1 (Person Detection), Stage 2A (Weapon Detection) และ Stage 2B (Weapon Type Classification) เพื่อสะท้อนผลกระทบของเงื่อนไขการทดลองต่อการทำงานของระบบในแต่ละลำดับขั้น

ตารางที่ 4-10 ผลการประเมินประสิทธิภาพของระบบแยกตามฉากการทดลอง

Scenario	ระยะ (m)	สภาพแสง	Stage 1 ความถูกต้อง	Stage 2A ความถูกต้อง	Stage 2B ความถูกต้อง
S1	0.5	สว่าง	82% (41/50)	64% (32/50)	78% (39/50)
S2	1	สว่าง	84% (42/10)	66% (33/50)	80% (40/50)
S3	2	สว่าง	72% (37/50)	58% (29/50)	64% (32/50)
S4	3	สว่าง	70% (35/50)	54% (27/50)	60% (30/50)
S5	0.5	มืด	84% (42/50)	64% (32/50)	78% (39/50)
S6	1	มืด	82% (41/50)	64% (32/50)	78% (35/50)
S7	2	มืด	70% (35/10)	58% (29/50)	64% (32/50)
S8	3	มืด	70% (35/50)	54% (27/50)	60% (30/50)

จากตาราง 4-10 สามารถสังเกตได้ว่าประสิทธิภาพของระบบมีแนวโน้มลดลงเมื่อระยะห่างระหว่างบุคคลกับอุปกรณ์ตรวจจับเพิ่มขึ้น โดยเฉพาะในขั้นตอนการตรวจจับการพกพาอาวุธ (Stage 2A) และการจำแนกประเภทของอาวุธ (Stage 2B) ซึ่งต้องอาศัยรายละเอียดของรูปแบบข้อมูลจากเซนเซอร์ภาพความร้อนและสัญญาณเรดาร์ในระดับที่ละเอียดมากขึ้น

เมื่อระยะการตรวจจับเพิ่มขึ้น คุณภาพของข้อมูลจากเซนเซอร์อาจลดลง เนื่องจากข้อจำกัดด้านมุมมอง (Field of View) ของเซนเซอร์ภาพความร้อน และการกระจายของพลังงานสัญญาณจากเซนเซอร์เรดาร์ ส่งผลให้ความสามารถในการแยกแยะลักษณะของวัตถุที่อาจเป็นอาวุธลดลงเล็กน้อย

อย่างไรก็ตาม ระบบยังสามารถรักษาระดับประสิทธิภาพโดยรวมให้อยู่ในระดับที่ยอมรับได้ในทุกฉากการทดลอง ซึ่งสะท้อนให้เห็นถึงศักยภาพของระบบในการทำงานภายใต้สภาพแวดล้อมจริงภายในพื้นที่ปิด และแสดงให้เห็นถึงความเป็นไปได้ในการนำระบบดังกล่าวไปประยุกต์ใช้เพื่อสนับสนุนการเฝ้าระวังด้านความปลอดภัย

4.4 ผลการประเมินในระดับระบบ (System-Level Evaluation)

นอกจากการประเมินประสิทธิภาพในระดับแบบจำลองแล้ว งานวิจัยนี้ยังได้ทำการประเมินการทำงานของระบบในระดับระบบสารสนเทศ (System-Level Evaluation) เพื่อพิจารณาความสามารถของระบบโดยรวมในการทำงานจริง โดยการประเมินในระดับนี้ครอบคลุมถึงกระบวนการรับ–ส่งข้อมูลจากอุปกรณ์ IoT การประมวลผลบนเซิร์ฟเวอร์ และการแสดงผลผ่านระบบแดชบอร์ด

ระบบที่พัฒนาขึ้นประกอบด้วยองค์ประกอบหลัก ได้แก่ เซนเซอร์ตรวจจับ (Thermal Camera MLX90640 และ mmWave Radar HLK-LD2410C) ไมโครคอนโทรลเลอร์ ESP32 สำหรับการรวบรวมข้อมูล เซิร์ฟเวอร์สำหรับการประมวลผลแบบจำลอง Machine Learning และส่วนแสดงผลข้อมูลผ่านเว็บแดชบอร์ด

ผลการทดลองแสดงให้เห็นว่าระบบสามารถรับข้อมูลจากเซนเซอร์และส่งต่อไปยังเซิร์ฟเวอร์เพื่อทำการประมวลผลได้อย่างต่อเนื่อง โดยกระบวนการประมวลผลของแบบจำลองในแต่ละขั้นตอน (Stage 1A, Stage 2A และ Stage 2B) สามารถดำเนินการได้ภายในช่วงเวลาที่เหมาะสมสำหรับการใช้งานเชิงเฝ้าระวัง ทำให้ระบบสามารถทำงานในลักษณะ near real-time monitoring ภายใต้เงื่อนไขของการทดลอง

นอกจากนี้ การทดสอบระบบยังแสดงให้เห็นว่ากระบวนการสื่อสารข้อมูลระหว่างอุปกรณ์ IoT เซิร์ฟเวอร์ และระบบแสดงผลสามารถทำงานร่วมกันได้อย่างสอดคล้อง ซึ่งยืนยันว่าการออกแบบสถาปัตยกรรมระบบที่นำเสนอในบทที่ 3 สามารถรองรับการทำงานของระบบตรวจจับภัยคุกคามได้อย่างเหมาะสม

ตารางที่ 4-11 สรุปประสิทธิภาพของระบบตรวจจับในแต่ละขั้นตอน

Stage	Task	Best Model	Accuracy	F1-score
Stage 1A	Person Detection	XGBoost	0.99	0.99
Stage 2A	Weapon Detection	XGBoost (Early Fusion)	0.96	0.95
Stage 2B	Weapon Type Classification	Random Forest	0.91	0.91

จากตารางที่ 4-9 สามารถสรุปได้ว่าระบบตรวจจับภัยคุกคามที่พัฒนาขึ้นมีโครงสร้างการทำงานแบบลำดับขั้น ซึ่งแต่ละขั้นตอนเลือกใช้แบบจำลองที่ให้ประสิทธิภาพดีที่สุดสำหรับปัญหาการจำแนกในขั้นตอนนั้น โดยแบบจำลอง XGBoost ให้ผลลัพธ์ดีที่สุดในขั้นตอนการตรวจสอบการมีอยู่ของบุคคล (Stage 1A) และการตรวจจับการพกพาอาวุธ (Stage 2A) ขณะที่แบบจำลอง Random Forest ให้ผลลัพธ์ดีที่สุดในการจำแนกประเภทอาวุธในขั้นตอน Stage 2B

ผลลัพธ์ดังกล่าวสะท้อนให้เห็นว่าการใช้แนวทางการตรวจจับแบบลำดับขั้นร่วมกับการผสานข้อมูลจากเซนเซอร์หลายชนิดสามารถช่วยเพิ่มประสิทธิภาพของระบบตรวจจับภัยคุกคามได้อย่างมีประสิทธิภาพ

4.5 อภิปรายผลการดำเนินงานวิจัย (Discussion)

จากผลการทดลองในบทนี้สามารถอภิปรายได้ว่าแนวทางการออกแบบระบบตรวจจับแบบลำดับขั้น (Hierarchical Detection) ร่วมกับการผสานข้อมูลจากเซนเซอร์หลายชนิด (Sensor Fusion) สามารถช่วยเพิ่มประสิทธิภาพในการตรวจจับภัยคุกคามได้อย่างมีประสิทธิภาพ

ในขั้นตอน Stage 1A แบบจำลองสามารถตรวจสอบการมีอยู่ของบุคคลได้อย่างแม่นยำ ซึ่งช่วยลดจำนวนข้อมูลที่ไม่เกี่ยวข้องก่อนเข้าสู่ขั้นตอนการวิเคราะห์การพกพาอาวุธ ในขั้นตอน Stage 2A การผสานข้อมูลจากกล้องถ่ายภาพความร้อนและเซนเซอร์เรดาร์ช่วยให้แบบจำลองสามารถจำแนกสถานการณ์ที่มีการพกพาอาวุธได้อย่างมีประสิทธิภาพ โดยเฉพาะเมื่อใช้แนวทาง Early Fusion ร่วมกับแบบจำลอง XGBoost ซึ่งให้ผลการทดลองดีที่สุด

สำหรับขั้นตอน Stage 2B ซึ่งเป็นการจำแนกประเภทของอาวุธ พบว่าแบบจำลอง Random Forest สามารถแยกแยะอาวุธประเภทปืนและมีดได้ดีกว่าแบบจำลองอื่น อย่างไรก็ตาม ปัญหาการจำแนกประเภทอาวุธยังคงมีความท้าทาย เนื่องจากลักษณะของข้อมูลจากเซนเซอร์มีความซับซ้อนและบางกรณีอาจมีความคล้ายคลึงกันระหว่างวัตถุประเภทต่าง ๆ

นอกจากนี้ ผลการทดลองยังสะท้อนให้เห็นข้อจำกัดบางประการของระบบ เช่น

- ความละเอียดของภาพจากเซนเซอร์ MLX90640 ซึ่งมีจำนวนพิกเซลจำกัด
- ความแปรผันของสัญญาณจากเซนเซอร์เรดาร์ภายใต้สภาพแวดล้อมที่แตกต่างกัน
- ความแตกต่างของลักษณะท่าทางการถืออาวุธของผู้ทดลอง

ข้อจำกัดเหล่านี้เป็นปัจจัยสำคัญที่ควรนำไปพิจารณาในการพัฒนาและปรับปรุงระบบในงานวิจัยในอนาคต

4.6 สรุปผลการดำเนินงาน

บทนี้ได้นำเสนอผลการทดลองและการวิเคราะห์ประสิทธิภาพของระบบตรวจจับภัยคุกคามที่พัฒนาขึ้น โดยครอบคลุมทั้งการประเมินในระดับแบบจำลอง Machine Learning และการประเมินในระดับระบบโดยรวม

ผลการทดลองแสดงให้เห็นว่าแบบจำลองที่ใช้ในแต่ละขั้นตอนสามารถทำงานร่วมกันได้อย่างมีประสิทธิภาพ โดยแบบจำลอง XGBoost ให้ผลลัพธ์ดีที่สุดในขั้นตอนการตรวจจับการพกพาอาวุธ (Stage 2A) ขณะที่แบบจำลอง Random Forest ให้ผลลัพธ์ดีที่สุดในการจำแนกประเภทอาวุธ (Stage 2B)

เมื่อพิจารณาการทำงานของระบบโดยรวม พบว่ากระบวนการตรวจจับแบบลำดับขั้นร่วมกับการผสานข้อมูลจากเซนเซอร์หลายชนิดสามารถช่วยเพิ่มความแม่นยำของระบบตรวจจับภัยคุกคามได้อย่างมีประสิทธิภาพ และมีศักยภาพในการนำไปประยุกต์ใช้ในระบบเฝ้าระวังด้านความปลอดภัยในพื้นที่ปิด

ผลการทดลองและการวิเคราะห์ที่นำเสนอในบทนี้จึงถูกใช้เป็นพื้นฐานสำหรับการสรุปผลและเสนอแนวทางการพัฒนางานวิจัยในบทที่ 5 ต่อไป

บทที่ 5
สรุปผล อภิปรายผล และข้อเสนอแนะ

บทนี้นำเสนอการสรุปผลการดำเนินงานวิจัย อภิปรายผลการทดลองที่ได้จากระบบตรวจจับอัจฉริยะสำหรับการตรวจสอบการมีอยู่ของบุคคลและการประเมินแนวโน้มการพกพาอาวุธในพื้นที่ปิด รวมถึงนำเสนอข้อจำกัดของงานวิจัยและแนวทางการพัฒนาเพิ่มเติมในอนาคต โดยการอภิปรายผลอ้างอิงจากผลการทดลองที่นำเสนอในบทที่ 4 อย่างเป็นระบบ

5.1 สรุปผลการวิจัย

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาระบบตรวจจับบุคคลและการพกพาอาวุธในพื้นที่ปิด โดยใช้การผสานข้อมูลจากเซนเซอร์หลายชนิดร่วมกับเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) ภายใต้แนวคิดของระบบตรวจจับแบบหลายขั้นตอน (Multi-Stage Detection System)

ระบบที่พัฒนาขึ้นประกอบด้วยสามขั้นตอนหลัก ได้แก่

- การตรวจจับบุคคล (Stage 1A: Person Detection)
- การตรวจจับการพกพาอาวุธ (Stage 2A: Weapon Detection)
- การจำแนกประเภทของอาวุธ (Stage 2B: Weapon Type Classification)

โดยระบบใช้ เซนเซอร์ภาพความร้อน MLX90640 ซึ่งมีความละเอียด 32 × 24 พิกเซล สำหรับตรวจจับรูปแบบการกระจายอุณหภูมิของวัตถุ และใช้ เซนเซอร์เรดาร์ HLK-LD2410C สำหรับตรวจจับการเคลื่อนไหวและพลังงานของวัตถุภายในพื้นที่ตรวจจับ ข้อมูลจากทั้งสองเซนเซอร์ถูกนำมาประมวลผลร่วมกันเพื่อเพิ่มความแม่นยำของระบบตรวจจับ

ผลการทดลองสามารถสรุปได้ดังนี้

5.1.1 Stage 1: การตรวจจับบุคคล (Person Detection)

ในขั้นตอนแรกของระบบ ได้ทำการทดลองเปรียบเทียบแบบจำลอง Machine Learning หลายชนิด ได้แก่

- Random Forest
- ExtraTrees
- Logistic Regression
- LinearSVC
- XGBoost

โดยใช้ข้อมูลคุณลักษณะที่สกัดจากเซนเซอร์ภาพความร้อนและเซนเซอร์เรดาร์เป็นข้อมูลนำเข้า

ผลการทดลองพบว่าแบบจำลอง XGBoost ให้ประสิทธิภาพดีที่สุด ในการตรวจจับบุคคล โดยมีค่า

- Accuracy ≈ 0.99
- F1-score ≈ 0.99

ผลลัพธ์ดังกล่าวแสดงให้เห็นว่าแบบจำลองสามารถจำแนกสถานการณ์ระหว่างการมีบุคคลและไม่มีบุคคลในพื้นที่ได้อย่างแม่นยำสูง และเหมาะสมสำหรับใช้เป็นขั้นตอนคัดกรองข้อมูลก่อนเข้าสู่กระบวนการตรวจจับการพกพาอาวุธในขั้นตอนถัดไป

5.1.2 Stage 2A: การตรวจจับการพกพาอาวุธ (Weapon Detection)

ในขั้นตอนที่สองของระบบ ได้มีการตรวจสอบว่าบุคคลที่ตรวจพบใน Stage 1 มีการพกพาอาวุธหรือไม่ โดยงานวิจัยนี้ได้ประยุกต์ใช้แนวคิด Sensor Fusion เพื่อรวมข้อมูลจากเซนเซอร์หลายชนิดเข้าด้วยกัน

ข้อมูลจากเซนเซอร์ภาพความร้อนและเซนเซอร์เรดาร์ถูกนำมาสกัดคุณลักษณะและรวมเข้าด้วยกันในระดับคุณลักษณะ (Early Fusion) ก่อนนำไปฝึกแบบจำลอง XGBoost

ผลการทดลองพบว่าแนวทางดังกล่าวสามารถเพิ่มประสิทธิภาพในการตรวจจับการพกพาอาวุธได้อย่างมีนัยสำคัญ โดยแบบจำลอง XGBoost ที่ใช้เทคนิค Early Fusion ให้ค่า

- Accuracy ≈ 0.94
- Macro-averaged F1-score ≈ 0.94

ผลลัพธ์ดังกล่าวแสดงให้เห็นว่าการผสานข้อมูลจากเซนเซอร์หลายชนิดช่วยให้ระบบสามารถตรวจจับการพกพาอาวุธได้อย่างมีประสิทธิภาพมากกว่าการใช้ข้อมูลจากเซนเซอร์เพียงชนิดเดียว

5.1.3 Stage 2B: การจำแนกประเภทอาวุธ (Weapon Type Classification)

เมื่อระบบตรวจพบว่ามีการพกพาอาวุธแล้ว ข้อมูลจะถูกส่งเข้าสู่ขั้นตอนการจำแนกประเภทของอาวุธใน Stage 2B โดยกำหนดเป็นปัญหาการจำแนกแบบสองคลาส ได้แก่

- ปืน (Gun)
- มีด (Knife)

การทดลองในขั้นตอนนี้ได้เปรียบเทียบแบบจำลองหลายชนิด ได้แก่ Random Forest, ExtraTrees, Logistic Regression, LinearSVC และ XGBoost

ผลการทดลองพบว่าแบบจำลอง XGBoost ให้ประสิทธิภาพดีที่สุดในการจำแนกประเภทอาวุธ โดยมีค่า

- Accuracy ≈ 0.94
- Macro-averaged F1-score ≈ 0.94

ซึ่งแสดงให้เห็นว่าแบบจำลองสามารถแยกแยะอาวุธสองประเภทที่มีลักษณะการกระจายความร้อนใกล้เคียงกันได้อย่างมีประสิทธิภาพ

5.2 อภิปรายผลการวิจัย

จากผลการทดลองของระบบตรวจจับแบบหลายขั้นตอน พบว่าแนวทาง Multi-Stage Detection ร่วมกับการผสานข้อมูลจากเซนเซอร์หลายชนิด (Sensor Fusion) สามารถช่วยเพิ่มประสิทธิภาพของระบบตรวจจับได้อย่างมีนัยสำคัญ โดยเฉพาะในการประยุกต์ใช้งานในพื้นที่ปิดที่มีข้อจำกัดด้านมุมมองและสภาพแวดล้อม

ในขั้นตอน Stage 1A (Person Detection) การใช้แบบจำลอง XGBoost ให้ผลลัพธ์ที่มีความแม่นยำสูง เนื่องจากข้อมูลจากเซนเซอร์ภาพความร้อนสามารถสะท้อนรูปแบบการกระจายอุณหภูมิของร่างกายมนุษย์ได้อย่างชัดเจน ขณะที่ข้อมูลจากเซนเซอร์เรดาร์ช่วยเสริมข้อมูลด้านการเคลื่อนไหวของวัตถุ ทำให้แบบจำลองสามารถแยกแยะระหว่างบุคคลและวัตถุอื่นภายในพื้นที่ตรวจจับได้อย่างมีประสิทธิภาพ

ในขั้นตอน Stage 2A (Weapon Detection) การใช้เทคนิค Early Fusion มีบทบาทสำคัญในการเพิ่มความสามารถในการตรวจจับการพกพาอาวุธ เนื่องจากข้อมูลจากเซนเซอร์ภาพความร้อนเพียงอย่างเดียวอาจไม่เพียงพอสำหรับการจำแนกวัตถุขนาดเล็ก เช่น อาวุธที่ถูกถือหรือซ่อนอยู่ใกล้กับร่างกายมนุษย์ อย่างไรก็ตาม เมื่อมีการรวมข้อมูลจากเซนเซอร์เรดาร์ซึ่งสามารถตรวจจับพลังงานและการเคลื่อนไหวของวัตถุได้ ระบบจึงสามารถวิเคราะห์ลักษณะของวัตถุได้ครอบคลุมมากขึ้น ส่งผลให้แบบจำลอง XGBoost สามารถให้ประสิทธิภาพในการจำแนกได้สูง

สำหรับขั้นตอน Stage 2B (Weapon Type Classification) ผลการทดลองแสดงให้เห็นว่าแบบจำลอง Random Forest สามารถจำแนกประเภทของอาวุธได้ดีกว่าแบบจำลองอื่น เนื่องจากโครงสร้างของแบบจำลองสามารถจัดการกับข้อมูลที่มีลักษณะไม่เชิงเส้น (Non-linear) และมีความหลากหลายของคุณลักษณะได้อย่างมีประสิทธิภาพ อย่างไรก็ตาม การจำแนกประเภทอาวุธยังคงมีความท้าทาย เนื่องจากอาวุธบางประเภทอาจมีลักษณะทางกายภาพหรือรูปแบบการกระจายความร้อนที่ใกล้เคียงกัน

โดยรวมแล้ว ผลการทดลองของระบบแสดงให้เห็นว่าการผสานข้อมูลจากเซนเซอร์หลายชนิดร่วมกับเทคนิค Machine Learning สามารถเพิ่มความสามารถในการตรวจจับพฤติกรรมที่มีความเสี่ยงในพื้นที่ปิดได้อย่างมีประสิทธิภาพ และมีศักยภาพในการนำไปประยุกต์ใช้ในระบบเฝ้าระวังด้านความปลอดภัยในสภาพแวดล้อมจริง

5.3 ข้อจำกัดของงานวิจัย

แม้ว่าระบบตรวจจับอัจฉริยะที่พัฒนาขึ้นในงานวิจัยนี้จะสามารถให้ผลลัพธ์ที่มีประสิทธิภาพในการทดลอง แต่ยังมีข้อจำกัดบางประการที่ควรนำมาพิจารณา ดังต่อไปนี้

ประการแรก เซนเซอร์ภาพความร้อน MLX90640 ที่ใช้ในการทดลองมีความละเอียดเพียง 32 × 24 พิกเซล ซึ่งอาจส่งผลให้การตรวจจับและจำแนกวัตถุที่มีขนาดเล็กหรือถูกบดบังบางส่วนทำได้ยาก เนื่องจากข้อมูลเชิงพื้นที่ของภาพมีรายละเอียดจำกัด

ประการที่สอง ชุดข้อมูลที่ใช้ในการฝึกแบบจำลองถูกเก็บรวบรวมภายใต้สภาพแวดล้อมการทดลองที่ค่อนข้างจำกัด เช่น พื้นที่ภายในอาคารและรูปแบบการเคลื่อนไหวของผู้ทดลองที่กำหนดไว้ ส่งผลให้แบบจำลองอาจมีข้อจำกัดในการทั่วไป (generalization) เมื่อนำไปใช้งานในสภาพแวดล้อมที่แตกต่างออกไป

ประการที่สาม การจำแนกประเภทอาวุธในงานวิจัยนี้ยังจำกัดอยู่เพียงสองประเภท ได้แก่ ปืน (Gun) และ มีด (Knife) ซึ่งยังไม่ครอบคลุมอาวุธประเภทอื่นที่อาจพบได้ในสถานการณ์จริง เช่น อาวุธที่มีลักษณะใกล้เคียงหรือวัตถุที่อาจถูกใช้เป็นอาวุธ

ประการที่สี่ ปัจจัยด้านสิ่งแวดล้อมบางประการ เช่น การเปลี่ยนแปลงของอุณหภูมิห้อง การมีวัตถุอื่นในพื้นที่ตรวจจับ หรือการเคลื่อนไหวของบุคคลหลายคนในพื้นที่เดียวกัน ยังไม่ได้รับการพิจารณาอย่างครบถ้วนในการทดลอง ซึ่งอาจส่งผลต่อความแม่นยำของระบบเมื่อนำไปใช้งานในสถานการณ์จริง

ดังนั้น ข้อจำกัดเหล่านี้จึงเป็นประเด็นสำคัญที่ควรนำไปพิจารณาในการพัฒนาระบบในงานวิจัยต่อไป เพื่อเพิ่มความสามารถในการทำงานของระบบในสภาพแวดล้อมจริงได้ดียิ่งขึ้น

5.4 ข้อเสนอแนะสำหรับงานวิจัยในอนาคต

เพื่อพัฒนาระบบตรวจจับอัจฉริยะให้มีประสิทธิภาพและสามารถนำไปประยุกต์ใช้ในสถานการณ์จริงได้มากยิ่งขึ้น งานวิจัยในอนาคตสามารถพิจารณาแนวทางต่อไปนี้

ประการแรก ควรเพิ่ม ขนาดและความหลากหลายของชุดข้อมูล (Dataset Expansion) โดยครอบคลุมสถานการณ์ที่ซับซ้อนมากขึ้น เช่น ท่าทางการถือวัตถุที่แตกต่างกัน การแต่งกายที่หลากหลาย หรือสภาพแวดล้อมที่แตกต่างกัน เพื่อช่วยให้แบบจำลองสามารถเรียนรู้รูปแบบของข้อมูลได้ครอบคลุมมากขึ้น และเพิ่มความสามารถในการทั่วไปของระบบ

ประการที่สอง ควรศึกษาการใช้เซนเซอร์ภาพความร้อนที่มีความละเอียดสูงขึ้น หรือประยุกต์ใช้เทคนิค การเพิ่มความละเอียดของภาพ (Thermal Image Super-Resolution) เพื่อเพิ่มรายละเอียด

เชิงพื้นที่ของข้อมูล ซึ่งอาจช่วยเพิ่มความแม่นยำในการตรวจจับวัตถุขนาดเล็ก เช่น อาวุธที่ถูกถือหรือซ่อนอยู่ใกล้กับร่างกายมนุษย์

ประการที่สาม ควรพัฒนาแนวทาง การผสานข้อมูลจากหลายเซนเซอร์ (Advanced Sensor Fusion) ในระดับที่ซับซ้อนมากขึ้น เช่น การผสานข้อมูลในระดับคุณลักษณะ (Feature-level Fusion) หรือระดับการตัดสินใจ (Decision-level Fusion) เพื่อเพิ่มความแม่นยำของระบบและลดผลกระทบจากสัญญาณรบกวนของเซนเซอร์

ประการที่สี่ ควรศึกษาการนำแบบจำลอง Machine Learning ไปปรับใช้บนอุปกรณ์ Edge Computing เช่น Raspberry Pi หรือไมโครคอนโทรลเลอร์ประสิทธิภาพสูง เพื่อประเมินความสามารถของระบบในการทำงานแบบเรียลไทม์ พร้อมทั้งพิจารณาประเด็นด้านการใช้พลังงาน ความเสถียรของระบบ และความสามารถในการทำงานต่อเนื่องในระยะยาว

ประการสุดท้าย สามารถขยายขอบเขตการประยุกต์ใช้งานของระบบไปยังบริบทอื่น ๆ เช่น ห้องเรียน อาคารสำนักงาน หรือยานพาหนะ เพื่อประเมินความเหมาะสมของระบบในสภาพแวดล้อมที่หลากหลาย และเพิ่มศักยภาพในการนำระบบไปใช้งานจริงในด้านความปลอดภัย

5.5 สรุปบท

บทนี้ได้นำเสนอการสรุปผลการดำเนินงานวิจัย การอภิปรายผลการทดลอง รวมถึงข้อจำกัดของงานวิจัยและข้อเสนอแนะสำหรับการพัฒนาในอนาคต โดยอ้างอิงจากผลการทดลองของระบบตรวจจับอัจฉริยะที่นำเสนอไว้ในบทที่ 4

งานวิจัยนี้ได้นำเสนอแนวทางการพัฒนาระบบตรวจจับอัจฉริยะสำหรับการประเมินความเสี่ยงด้านการพกพาอาวุธในพื้นที่ปิด โดยใช้แนวคิด การตรวจจับแบบหลายลำดับขั้น (Multi-Stage Detection) ร่วมกับการผสานข้อมูลจากเซนเซอร์หลายชนิด ได้แก่ เซนเซอร์ภาพความร้อนและเซนเซอร์เรดาร์ เพื่อเพิ่มความสามารถในการตรวจจับบุคคลและวัตถุที่อาจเป็นอาวุธ

ผลการทดลองแสดงให้เห็นว่าระบบสามารถทำงานได้อย่างมีประสิทธิภาพในแต่ละขั้นตอนของกระบวนการตรวจจับ โดยแบบจำลองที่ใช้ในแต่ละขั้นตอนสามารถจำแนกข้อมูลได้อย่างแม่นยำและช่วยลดความซับซ้อนของกระบวนการวิเคราะห์ข้อมูลในระดับระบบโดยรวม

นอกจากนี้ การผสานข้อมูลจากเซนเซอร์หลายชนิดร่วมกับเทคนิค Machine Learning ยังช่วยเพิ่มศักยภาพของระบบในการตรวจจับพฤติกรรมที่มีความเสี่ยงในพื้นที่ปิดได้อย่างมีประสิทธิภาพ ซึ่งแสดงให้เห็นถึงความเป็นไปได้ในการนำระบบที่พัฒนาขึ้นไปประยุกต์ใช้ในงานด้านความปลอดภัยและระบบเฝ้าระวังในสภาพแวดล้อมจริง

ผลลัพธ์จากงานวิจัยนี้จึงสามารถใช้เป็นพื้นฐานสำหรับการพัฒนาและต่อยอดงานวิจัยในด้านระบบตรวจจับอัจฉริยะ การผสานข้อมูลจากเซนเซอร์หลายชนิด และการประยุกต์ใช้เทคนิค Machine Learning ในระบบความปลอดภัยในอนาคตต่อไป

บรรณานุกรม

[1] D. Fonovic, Z. Sirotic, N. Tankovic, and S. Sovilj, “Low-Power Wireless IoT System for Indoor Environment Real-Time Monitoring and Alerting,” in *2021 44th International Convention on Information, Communication and Electronic Technology (MIPRO)*, IEEE, Sep. 2021, pp. 1654–1658. doi: 10.23919/MIPRO52101.2021.9596916.

[2] R. Bolimera, M. Rachana, S. Kaveri, K. R. Kiran, Ch. Venkanna, and G. V. Krishna, “IoT Based Fire and Motion Detection System,” in *2025 IEEE International Students’ Conference on Electrical, Electronics and Computer Science (SCEECS)*, IEEE, Jan. 2025, pp. 1–5. doi: 10.1109/SCEECS64059.2025.10940974.

[3] M. Pavel, S. Moldovanu, and D. Aiordachioaie, “On Classification of the Human Emotions from Facial Thermal Images: A Case Study Based on Machine Learning,” *Mach. Learn. Knowl. Extr.*, vol. 7, no. 2, p. 27, Mar. 2025, doi: 10.3390/make7020027.

[4] C. Devaguptapu, N. Akolekar, M. M. Sharma, and V. N. Balasubramanian, “Borrow From Anywhere: Pseudo Multi-Modal Object Detection in Thermal Imagery,” in *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, IEEE, Jun. 2019, pp. 1029–1038. doi: 10.1109/CVPRW.2019.00135.

[5] X. Gao, H. Liu, S. Roy, G. Xing, A. Alansari, and Y. Luo, “Learning to Detect Open Carry and Concealed Object With 77 GHz Radar,” *IEEE J. Sel. Top. Signal Process.*, vol. 16, no. 4, pp. 791–803, Jun. 2022, doi: 10.1109/JSTSP.2022.3171168.

[6] M. Alizadeh, H. Abedi, and G. Shaker, “Low-cost low-power in-vehicle occupant detection with mm-wave FMCW radar,” in *2019 IEEE SENSORS*, IEEE, Oct. 2019, pp. 1–4. doi: 10.1109/SENSORS43011.2019.8956880.

[7] J. Xiong, Z. Zhou, H. Zhang, and J. Yan, “Human Motion Recognition Based on Integrate Interval Grey Association Degree With Pyroelectric Sensors Node,” *IEEE Sens. J.*, vol. 24, no. 10, pp. 15836–15846, May 2024, doi: 10.1109/JSEN.2024.3383884.

[8] J. Salido, V. Lomas, J. Ruiz-Santaquiteria, and O. Deniz, “Automatic Handgun Detection with Deep Learning in Video Surveillance Images,” *Applied Sciences*, vol. 11, no. 13, p. 6085, Jun. 2021, doi: 10.3390/app11136085.

[9] F. Wu, P. Cornillon, B. Boussidi, and L. Guan, “Determining the Pixel-to-Pixel Uncertainty in Satellite-Derived SST Fields,” *Remote Sens. (Basel).*, vol. 9, no. 9, p. 877, Aug. 2017, doi: 10.3390/rs9090877.

[10] Y. Wanna and T. Intharah, “CONG: Yet Another Human Tracking Dataset, but with a Little Secret,” in *2024 16th International Conference on Knowledge and Smart Technology (KST)*, IEEE, Feb. 2024, pp. 35–39. doi: 10.1109/KST61284.2024.10499663.

[11] C. Kaul *et al.*, “AI-Enabled Sensor Fusion of Time-of-Flight Imaging and mmWave for Concealed Metal Detection,” *Sensors*, vol. 24, no. 18, p. 5865, Sep. 2024, doi: 10.3390/s24185865.

[12] M. M. Moussa, R. Shoitan, Y.-I. Cho, and M. S. Abdallah, “Visual-Based Children and Pet Rescue from Suffocation and Incidence of Hyperthermia Death in Enclosed Vehicles,” *Sensors*, vol. 23, no. 16, p. 7025, Aug. 2023, doi: 10.3390/s23167025.

[13] R. A. Karim, H. Z. Shen, M. Yakno, Y. A. Wahab, and M. Z. Ibrahim, “Child Left in the Car Detection: Image Enhancement for Day and Night,” 2024, pp. 213–223. doi: 10.1007/978-981-97-3851-9_20.

[14] D. Shi, J. Lu, J. Wang, L. Li, K. Liu, and M. Pan, “No One Left Behind: Avoid Hot Car Deaths via WiFi Detection,” in *ICC 2020 - 2020 IEEE International Conference on Communications (ICC)*, IEEE, Jun. 2020, pp. 1–6. doi: 10.1109/ICC40277.2020.9148648.

[15] T. T. Nguyen, Y. Kawanishi, V. John, T. Komamizu, and I. Ide, “MultiSensor-Home: A Wide-area Multi-modal Multi-view Dataset for Action Recognition and Transformer-based Sensor Fusion,” in *2025 IEEE 19th International Conference on Automatic Face and Gesture Recognition (FG)*, IEEE, May 2025, pp. 1–10. doi: 10.1109/FG61629.2025.11099071.



ภาคผนวก

ภาคผนวก ก
โครงสร้างชุดข้อมูล (Dataset Structure)

ชุดข้อมูลที่ใช้ในการพัฒนาและฝึกแบบจำลองในงานวิจัยนี้ได้มาจากการเก็บข้อมูลจากเซนเซอร์หลายชนิด ได้แก่ เซนเซอร์ภาพความร้อน MLX90640 และเรดาร์คลื่นมิลลิเมตร HLK-LD2410C โดยข้อมูลถูกบันทึกในรูปแบบไฟล์ CSV ซึ่งประกอบด้วยคุณลักษณะ (features) จากทั้งสองเซนเซอร์ รวมถึงป้ายกำกับ (label) สำหรับใช้ในการฝึกแบบจำลองการเรียนรู้ของเครื่อง

ชุดข้อมูลประกอบด้วยข้อมูลจำนวนประมาณ 18,000 ตัวอย่าง และมีจำนวนตัวแปรมากกว่า 800 ตัวแปร ซึ่งประกอบด้วยข้อมูลจากเซนเซอร์เรดาร์ ข้อมูลภาพความร้อน และป้ายกำกับสำหรับการจำแนกประเภทในแต่ละขั้นตอนของระบบตรวจจับ

ตารางที่ ก-1 ตัวอย่างโครงสร้างของข้อมูลที่ใช้ในงานวิจัย

Column	Description
scenario_id	รหัสสถานการณ์การทดลอง
segment_id	รหัสช่วงข้อมูล
motion	สถานะการตรวจจับการเคลื่อนไหวจากเรดาร์
motion_distance	ระยะทางของวัตถุที่ตรวจพบ
motion_energy	พลังงานการเคลื่อนไหว
static_energy	พลังงานของวัตถุที่อยู่นิ่ง
p_0 – p_767	ค่าพิกเซลของภาพความร้อนจาก MLX90640
label_person	ป้ายกำกับสำหรับการตรวจจับบุคคล
label_weapon	ป้ายกำกับสำหรับการตรวจจับการพกพาอาวุธ
label_weapon_type	ป้ายกำกับประเภทของอาวุธ

ตารางที่ ก-2 ตัวอย่างข้อมูลในรูปแบบ CSV

scenario_id	segment_id	label_person	label_weapon	label_weapon	timestamp	motion	motion_dista	motion_energ	static_energy	eng_move_m	eng_move_su	eng_static_m	eng_static_su
Condo	Co__seg_2026-02-06T15-48-47-363Z	0	0	none	1/1/1970 08:15	1	30	100	100	100	353	100	468
Condo	Co__seg_2026-02-06T15-48-47-363Z	1	0	none	1/1/1970 07:57	1	30	100	100	100	227	100	309
Condo	Co__seg_2026-02-06T15-48-47-363Z	1	1	knife	1/1/1970 08:09	1	42	100	100	100	358	100	475
Condo	Co__seg_2026-02-06T15-48-47-363Z	1	1	gun	1/1/1970 08:03	1	49	100	100	100	372	100	483

จากตารางจะเห็นได้ว่า ข้อมูลแต่ละระเบียนประกอบด้วยทั้งข้อมูลจากเซนเซอร์เรดาร์และป้ายกำกับสำหรับใช้ในการจำแนกแบบลำดับขั้น โดยค่าของ label_person ใช้ใน Stage 1A, label_weapon ใช้ใน Stage 2A และ label_weapon_type ใช้ใน Stage 2B
นอกจากนี้ ชุดข้อมูลยังมีตัวแปรค่าพลังงานในแต่ละ gate ของเรดาร์ และค่าพิกเซลของภาพความร้อน ซึ่งไม่ได้แสดงทั้งหมดในตารางนี้เนื่องจากมีจำนวนมาก

ตารางที่ ก-3 ตัวอย่างค่าพิกเซลภาพความร้อนจากชุดข้อมูล

p_0	p_1	p_2	p_3	p_4	p_5	p_6	p_7
32.85	32.71	32.27	33.86	32.45	32.08	32.52	32.68

ค่าดังกล่าวแสดงอุณหภูมิที่ตรวจวัดได้ในแต่ละตำแหน่งพิกเซลของภาพความร้อน ซึ่งถูกใช้ร่วมกับข้อมูลเรดาร์เพื่อสร้างคุณลักษณะสำหรับแบบจำลองการเรียนรู้ของเครื่อง

ตัวอย่างข้อมูลในรูปแบบ JSON

ในระบบต้นแบบ ข้อมูลจากเซนเซอร์สามารถจัดเก็บหรือส่งต่อในรูปแบบ **JSON** ได้ ซึ่งเหมาะสมกับการรับส่งข้อมูลผ่านเครือข่ายระหว่าง ESP32 และ Raspberry Pi หรือเซิร์ฟเวอร์ประมวลผล

ตัวอย่างข้อมูล JSON ที่แปลงจากข้อมูลจริงในชุดข้อมูลแสดงดังนี้


```
{
  "scenario_id": "Condo",
  "segment_id": "Co__seg_2026-02-06T15-48-47-363Z",
  "label_person": 1,
  "label_weapon": 1,
  "label_weapon_type": "knife",
  "timestamp": "1/1/1970 08:09",
  "radar": {
    "motion": 1,
    "motion_distance": 42,
    "motion_energy": 100,
    "static_energy": 100,
    "enableEngineeringMode": 1,
    "eng_move_gate_count": 8,
    "eng_static_gate_count": 8,
    "eng_move_max": 100,
    "eng_move_sum": 358,
    "eng_static_max": 100,
    "eng_static_sum": 475,
    "eng_move_gate_energy": [0, 0, 0, 0, 0, 0, 0, 0],
    "eng_static_gate_energy": [0, 0, 0, 0, 0, 0, 0, 0]
  },
  "thermal": {
    "w": 32,
    "h": 24,
    "pixels_sample": [32.85, 32.71, 32.27, 33.86, 32.45, 32.08, 32.52, 32.68]
  }
```


จากตัวอย่างข้างต้นจะเห็นว่า JSON สามารถแบ่งโครงสร้างข้อมูลออกเป็นส่วนต่าง ๆ ได้อย่างชัดเจน ได้แก่ ข้อมูลระบุตัวอย่าง (scenario_id, segment_id), ป้ายกำกับ (label_person, label_weapon, label_weapon_type), ข้อมูลเรดาร์ (radar) และข้อมูลภาพความร้อน (thermal) ทำให้เหมาะสมต่อการใช้งานในระบบตรวจจับแบบเรียลไทม์

ภาคผนวก ข

Hardware Specification และระยะการทำงานของระบบ

Hardware Specification

ระบบตรวจจับบุคคลและการพกพาอาวุธในงานวิจัยนี้ถูกพัฒนาขึ้นโดยใช้การบูรณาการข้อมูลจากเซนเซอร์หลายประเภท (Multi-Sensor Fusion) โดยฮาร์ดแวร์หลักประกอบด้วยไมโครคอนโทรลเลอร์ ESP32, เซนเซอร์ภาพความร้อน MLX90640 และเซนเซอร์ mmWave Radar HLK-LD2410C ซึ่งทำหน้าที่ตรวจจับการเคลื่อนไหวและลักษณะทางความร้อนของวัตถุในพื้นที่

ตารางที่ ข-1 แสดงรายละเอียดของฮาร์ดแวร์ที่ใช้ในระบบ

Hardware	Specification	Purpose
ESP32S WROOM	Dual-core 240 MHz, WiFi/Bluetooth	ทำหน้าที่เป็นหน่วยประมวลผลหลักและเชื่อมต่อเครือข่าย
MLX90640 Thermal Camera	Resolution 32×24 pixels, FOV 55°/110°, I2C interface	ตรวจจับภาพความร้อนของบุคคลและวัตถุ
HLK-LD2410C mmWave Radar	24 GHz radar, detection range up to 6 m	ตรวจจับการเคลื่อนไหวและระยะของวัตถุ
Raspberry Pi 4	Quad-core ARM processor, Linux OS	ทำหน้าที่เป็น AI Server สำหรับรัน Machine Learning model
Power Supply	5V / 2A	จ่ายพลังงานให้กับระบบ
Communication	Wi-Fi (HTTP / MQTT)	ส่งข้อมูลเซนเซอร์ไปยังเซิร์ฟเวอร์

ในการทำงานของระบบ ESP32 จะทำหน้าที่รวบรวมข้อมูลจากเซนเซอร์ MLX90640 และ LD2410C จากนั้นข้อมูลจะถูกส่งไปยัง Raspberry Pi 4 ผ่านเครือข่าย Wi-Fi เพื่อทำการประมวลผลด้วยแบบจำลอง Machine Learning และแสดงผลผ่าน Dashboard

Sensor Placement

ในต้นแบบของระบบ เซนเซอร์ถูกติดตั้งในลักษณะ ติดตั้งด้านบน (Top-view configuration) โดยมีความสูงจากพื้นประมาณ 2–2.5 เมตร เพื่อให้สามารถครอบคลุมพื้นที่ตรวจจับได้อย่างเหมาะสม

ตำแหน่งการติดตั้งเซนเซอร์มีลักษณะดังนี้

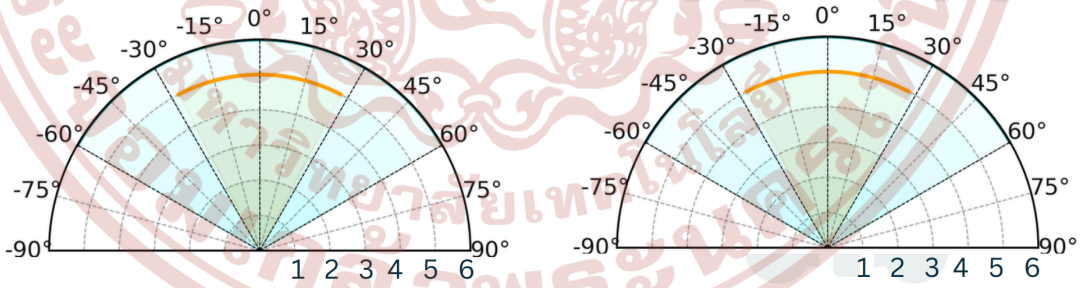
- MLX90640 ใช้สำหรับตรวจจับ thermal pattern ของร่างกายมนุษย์
- LD2410C ใช้สำหรับตรวจจับ การเคลื่อนไหวและระยะของวัตถุ

ทั้งสองเซนเซอร์ถูกติดตั้งในกล่องเดียวกันเพื่อให้ field of view ใกล้เคียงกัน

การติดตั้งในลักษณะดังกล่าวช่วยให้ระบบสามารถตรวจจับบุคคลในพื้นที่ได้อย่างมีประสิทธิภาพ

Detection Range of Sensors

เซนเซอร์แต่ละประเภทมีระยะการตรวจจับที่แตกต่างกัน โดยขึ้นอยู่กับคุณสมบัติของเซนเซอร์และสภาพแวดล้อมในการใช้งาน



ภาพที่ ข-1 a) Top View of Sensor Detection Range (b) Side View of Sensor Detection Range

จากรูป แสดงมุมมองการตรวจจับของเซนเซอร์จากสองมุมมอง ได้แก่ Top View และ Side View โดยเซนเซอร์สามารถครอบคลุมพื้นที่ตรวจจับในมุมประมาณ ±60 องศา และมีระยะตรวจจับสูงสุดประมาณ 6 เมตร อย่างไรก็ตาม ในงานวิจัยนี้ได้กำหนดระยะการทดลองหลักอยู่ในช่วง 0.5–3 เมตร เพื่อให้ได้ข้อมูลภาพความร้อนที่มีความละเอียดเพียงพอสำหรับการประมวลผลด้วยแบบจำลอง Machine Learning

ตารางที่ ข-2 แสดงระยะการตรวจจับของเซนเซอร์ที่ใช้ในระบบ

Sensor	Detection Range	Description
MLX90640 Thermal Sensor	0.5 – 3 meters	สามารถตรวจจับความแตกต่างของอุณหภูมิของร่างกายมนุษย์
LD2410C mmWave Radar	0 – 6 meters	ตรวจจับการเคลื่อนไหวและระยะของวัตถุ
System Effective Range	0.5 – 3 meters	ระยะที่ระบบให้ผลลัพธ์ที่มีความแม่นยำสูง

จากการทดลองพบว่า ระยะการตรวจจับที่เหมาะสมของระบบอยู่ในช่วงประมาณ 0.5 – 3 เมตร ซึ่งเป็นระยะที่เซนเซอร์ภาพความร้อนสามารถแยกแยะรูปแบบของร่างกายมนุษย์ได้ชัดเจน และเรดาร์สามารถตรวจจับการเคลื่อนไหวได้อย่างมีประสิทธิภาพ

พระจอมเกล้าพระนครเหนือ มหาวิทยาลัยเทคโนโลยี

ภาคผนวก ค

ตัวอย่าง Source Code ของระบบ

มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

โค้ดสำหรับการรับข้อมูลจากเซนเซอร์และส่งข้อมูลไปยังเซิร์ฟเวอร์

โค้ดส่วนนี้ทำงานบนบอร์ด ESP32 โดยมีหน้าที่เชื่อมต่อเครือข่ายไร้สาย อ่านข้อมูลจากเซนเซอร์ภาพความร้อน MLX90640 และเซนเซอร์เรดาร์ HLK-LD2410 จากนั้นจัดรูปแบบข้อมูลให้อยู่ในรูปแบบไบนารีและส่งไปยังเซิร์ฟเวอร์ผ่านโปรโตคอล HTTPS เพื่อใช้ในการประมวลผลและทำนายผลด้วยแบบจำลอง Machine Learning

ตัวอย่างโค้ดที่สำคัญแสดงดังนี้

```
#include <WiFi.h>
#include <Wire.h>
#include <Adafruit_MLX90640.h>
#include <WiFiClientSecure.h>
#include <HTTPClient.h>

const char* ssid = "YOUR_WIFI_SSID";
const char* password = "YOUR_WIFI_PASSWORD";
const char* SERVER_URL = "https://your-server-domain.com/ingest/px";

WiFiClientSecure tlsClient;
Adafruit_MLX90640 mlx;
HardwareSerial LD2410_Serial(2);

float pixels[32 * 24];
bool isMotionDetected = false;
uint16_t motionDistance = 0;
uint16_t motionEnergy = 0;
uint16_t staticEnergy = 0;

void connectWiFi() {
  WiFi.mode(WIFI_STA);
  WiFi.setSleep(false);
  WiFi.begin(ssid, password);

  while (WiFi.status() != WL_CONNECTED) {
    delay(500);
  }
}
```

```
void setup() {
  Serial.begin(115200);
  LD2410_Serial.begin(256000, SERIAL_8N1, 33, 32);
  Wire.begin(5, 22);

  if (!mlx.begin(MLX90640_I2CADDR_DEFAULT, &Wire)) {
    while (1) delay(10);
  }

  mlx.setMode(MLX90640_CHESS);
  mlx.setResolution(MLX90640_ADC_18BIT);
  mlx.setRefreshRate(MLX90640_16_HZ);

  connectWiFi();
  tlsClient.setInsecure();
}
```

โค้ดข้างต้นแสดงการกำหนดค่าพื้นฐานของระบบ ได้แก่ การเชื่อมต่อ Wi-Fi การเริ่มต้นใช้งานเซนเซอร์ MLX90640 ผ่าน I2C และการเปิดใช้งานพอร์ต UART สำหรับเซนเซอร์ LD2410

โค้ดสำหรับการอ่านข้อมูลและส่งข้อมูลผ่าน HTTPS

ในขั้นตอนการทำงานจริง ระบบจะอ่านข้อมูลจากเซนเซอร์ภาพความร้อนและเรดาร์ จากนั้นรวมข้อมูลให้อยู่ในรูปแบบ payload ก่อนส่งไปยังเซิร์ฟเวอร์ผ่าน HTTPS ดังตัวอย่าง

```
bool readMLXData() {
  return (mlx.getFrame(pixels) == 0);
}
bool postPXBinary(const uint8_t* data, size_t len, int &httpCodeOut) {
  httpCodeOut = -1;
  if (WiFi.status() != WL_CONNECTED) return false;

  HTTPClient https;
  https.setTimeout(6000);
  if (!https.begin(tlsClient, SERVER_URL)) return false;
  https.addHeader("Content-Type", "application/octet-stream");

  int code = https.POST((uint8_t*)data, len);
  httpCodeOut = code;
  https.end();
  return (code >= 200 && code < 300);
}

void loop() {
  bool okMlx = readMLXData();

  if (!okMlx) {
    Serial.println("[MLX] read fail");
    return;
  }
  int httpCode = -1;
  int payloadLen = 0;
  bool ok = sendFrameBinaryHTTPS(httpCode, payloadLen);

  Serial.printf("[HTTPS] POST %s code=%d bytes=%d\n",
                ok ? "OK" : "FAIL",
                httpCode,
                payloadLen);
}
```

โค้ดส่วนนี้แสดงตัวอย่างการอ่านข้อมูลจากเซนเซอร์ภาพความร้อน และการส่งข้อมูลไปยังเซิร์ฟเวอร์ผ่าน HTTPS โดยข้อมูลที่ส่งจะถูกนำไปใช้ในกระบวนการประมวลผลและทำนายผลของระบบ

โค้ด main.py สำหรับการอนุมานผลด้วยแบบจำลอง Machine Learning

โค้ดส่วนนี้ทำงานบนเซิร์ฟเวอร์ โดยใช้เฟรมเวิร์ก FastAPI เพื่อรับข้อมูลจาก ESP32 ผ่าน API, แปลงข้อมูลจากเซนเซอร์ให้อยู่ในรูปแบบที่สอดคล้องกับ schema ของโมเดล, และทำนายผลการตรวจจับแบบลำดับขั้น ได้แก่ Stage 1A, Stage 2A และ Stage 2B ทั้งนี้ในระบบได้กำหนด schema ของข้อมูลนำเข้าไว้ที่ 794 คุณลักษณะ ประกอบด้วยข้อมูลภาพความร้อน 768 ค่า และข้อมูลจากเรดาร์รวมทั้งค่าพลังงานของ gate ต่าง ๆ

```
from fastapi import FastAPI, HTTPException, Request
from fastapi.responses import HTMLResponse, JSONResponse
import numpy as np
import joblib
import time
from pathlib import Path

PIXEL_PREFIX = "p_"
N_PIXELS = 32 * 24   # 768

RADAR_PACKET_COLS = [
"motion",
"motion_distance",
"motion_energy",
"static_energy",
"eng_move_gate_count",
"eng_static_gate_count",
]

RADAR_EXTRA_ZERO_COLS = [
"eng_move_max",
"eng_move_sum",
"eng_static_max",
"eng_static_sum",
]

MOVE_GATE_PREFIX = "eng_move_gate_energy_"
STATIC_GATE_PREFIX = "eng_static_gate_energy_"
N_GATES = 8

RADAR_BASE_COLS = RADAR_PACKET_COLS + RADAR_EXTRA_ZERO_COLS

RAW_COLS = (
[f"{PIXEL_PREFIX}{i}" for i in range(N_PIXELS)]
+ list(RADAR_BASE_COLS)
+ [f"{MOVE_GATE_PREFIX}{i}" for i in range(N_GATES)]
+ [f"{STATIC_GATE_PREFIX}{i}" for i in range(N_GATES)]
)

app = FastAPI()
MODELS = {}
THRESHOLDS = {"1A": 0.5, "2A": 0.5}
```

การโหลดโมเดลและตรวจสอบจำนวนคุณลักษณะ

```
def _expected_n_features(model):
    if hasattr(model, "n_features_in_"):
        return int(model.n_features_in_)
    if hasattr(model, "steps"):
        for _, step in reversed(model.steps):
            if hasattr(step, "n_features_in_"):
                return int(step.n_features_in_)
    return None

def load_model(stage: str) -> None:
    pkl = MODELS_DIR / f"model{stage}" / "best_model.pkl"
    if not pkl.exists():
        return

    m = joblib.load(pkl)
    MODELS[stage] = m
    nexp = _expected_n_features(m)

    if nexp is not None and nexp != len(RAW_COLS):
        raise RuntimeError(
            f"Model {stage} expects {nexp} features but server builds {len(RAW_COLS)}."
        )
```

โค้ดส่วนนี้ใช้โหลดโมเดลของแต่ละขั้นจากไฟล์ best_model.pkl และตรวจสอบว่าโมเดลต้องการจำนวนคุณลักษณะตรงกับข้อมูลที่เซิร์ฟเวอร์สร้างขึ้นหรือไม่ เพื่อป้องกันปัญหา feature mismatch ระหว่างช่วงฝึกโมเดลและช่วงใช้งานจริง

C.3.3 การแปลงข้อมูล PX packet จาก ESP32

```
_PACKET_HEADER_LEN = 34
_PACKET_TOTAL_LEN = _PACKET_HEADER_LEN + N_PIXELS * 2

def parse_px(body: bytes):
    if len(body) < _PACKET_TOTAL_LEN:
        raise ValueError("PX packet too small")

    if body[0:2] != b"PX":
        raise ValueError("PX magic mismatch")

    ver = body[2]
    if ver != 1:
        raise ValueError(f"PX version not supported: {ver}")

    frame_id = int.from_bytes(body[3:7], "little", signed=False)
    ms = int.from_bytes(body[7:11], "little", signed=False)

    motion = int(body[11])
    motion_distance = int.from_bytes(body[12:14], "little", signed=False)
    motion_energy = int(body[14])
    static_energy = int(body[15])

    move_gate_count = int(body[16])
    static_gate_count = int(body[17])

    move_gates = list(body[18:26])
    static_gates = list(body[26:34])

    px_i16 = np.frombuffer(body, dtype="<i2", count=N_PIXELS, offset=_PACKET_HEADER_LEN)
    pixels = (px_i16.astype(np.float32) / 100.0).astype(np.float32, copy=False)
```

โค้ดนี้ทำหน้าที่ถอดรหัสข้อมูลไบนารีที่ส่งมาจาก ESP32 ตามรูปแบบ PX packet ซึ่งประกอบด้วย frame_id, เวลา ms, ข้อมูลเรดาร์ และค่าพิกเซลภาพความร้อน 768 ค่า โดยข้อมูลพิกเซลถูกแปลงจาก int16 ให้กลับมาเป็นอุณหภูมิหน่วยองศาเซลเซียส

การสร้างเวกเตอร์คุณลักษณะสำหรับป้อนเข้าโมเดล

```
def build_X(pixels: np.ndarray, radar: dict) -> np.ndarray:
    feat = np.zeros((len(RAW_COLS),), dtype=np.float32)

    if pixels.shape[0] != N_PIXELS:
        raise ValueError(f"pixels length mismatch: {pixels.shape[0]} != {N_PIXELS}")

    feat[:N_PIXELS] = pixels

    base_off = N_PIXELS
    for i, k in enumerate(RADAR_BASE_COLS):
        feat[base_off + i] = float(radar.get(k, 0.0))

    g0 = base_off + len(RADAR_BASE_COLS)
    for i in range(N_GATES):
        feat[g0 + i] = float(radar.get(f"{MOVE_GATE_PREFIX}{i}", 0.0))

    g1 = g0 + N_GATES
    for i in range(N_GATES):
        feat[g1 + i] = float(radar.get(f"{STATIC_GATE_PREFIX}{i}", 0.0))

    return feat.reshape(1, -1)
```

โค้ดส่วนนี้ใช้รวมข้อมูลจากภาพความร้อนและข้อมูลเรดาร์ให้เป็นเวกเตอร์คุณลักษณะ 1 แถว สำหรับนำไปใช้กับโมเดล Machine Learning ในการทำนายผลของแต่ละขั้น

การทำนายผลแบบลำดับขั้น

```
@app.post("/ingest/px")
async def ingest_px(req: Request):
    body = await req.body()
    frame_id, ms, radar, pixels = parse_px(body)
    X = build_X(pixels, radar)

    s1 = LATEST["stages"]["1A"]
    m1 = MODELS.get("1A")
    if m1 is not None:
        p1 = safe_proba(m1, X)
        th1 = THRESHOLDS.get("1A", 0.5)
        y1 = int(p1 >= th1)
        s1.update({"proba": p1, "pred": y1, "loaded": True, "th": th1})

    s2 = LATEST["stages"]["2A"]
    m2 = MODELS.get("2A")
    if m2 is not None and s1.get("pred") == 1:
        p2 = safe_proba(m2, X)
        th2 = THRESHOLDS.get("2A", 0.5)
        y2 = int(p2 >= th2)
        s2.update({"proba": p2, "pred": y2, "loaded": True, "th": th2})

    s3 = LATEST["stages"]["2B"]
    m3 = MODELS.get("2B")
    if m3 is not None and s2.get("pred") == 1:
        p3 = safe_proba(m3, X)
        pred = m3.predict(X)[0]
        s3.update({"proba": p3, "pred": str(pred), "loaded": True})

    return {"ok": True, "frame_id": frame_id}
```

ในส่วนนี้ เซิร์ฟเวอร์จะดำเนินการทำนายผลแบบลำดับขั้น โดยเริ่มจาก Stage 1A เพื่อตรวจจับว่ามีบุคคลหรือไม่ หากผลเป็น “มีบุคคล” จึงเข้าสู่ Stage 2A เพื่อตรวจจับการพกพาอาวุธ และเมื่อพบอาวุธแล้วจึงเข้าสู่ Stage 2B เพื่อจำแนกประเภทของอาวุธต่อไป แนวทางนี้ช่วยลดการประมวลผลที่ไม่จำเป็นและสอดคล้องกับโครงสร้างระบบแบบ hierarchical detection ของงานวิจัย

ประวัติผู้เขียน

ชื่อ	นายเอกคณิต ซุ้นสุวรรณ
ชื่อการค้นคว้าอิสระ	การพัฒนาระบบอัจฉริยะสำหรับตรวจจับการพกอาวุธของบุคคลในพื้นที่โดยเทคนิคการเรียนรู้ของเครื่องและเทคโนโลยีอินเทอร์เน็ตของสรรพสิ่ง
สาขาวิชา	ระบบสารสนเทศเพื่อการจัดการ
ประวัติ	สำเร็จการศึกษาระดับปริญญาตรี หลักสูตรวิศวกรรมศาสตร์บัณฑิต สาขาวิศวกรรมคอมพิวเตอร์ มหาวิทยาลัยเกษตรศาสตร์ วิทยาเขตศรีราชา ปี พ.ศ.2559

มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ