

ระบบระบุตำแหน่งภายในอาคารโดยอาศัยการเรียนรู้ของเครื่องและการผสานข้อมูลตัวบ่งชี้ ความแรงสัญญาณที่ได้รับและเซนเซอร์วัดความเร่ง

An Indoor Localization System using Machine Learning and Data Fusion of RSSI and an Accelerometer Sensor

ธราดล วัฒนาวิน^{1*} จุฑดาว บุรณะพาณิชย์กิจ¹ เกียรติศักดิ์ เลี้ยงช่วย¹ และ อภิเดช บุรณวงศ์¹

¹ภาควิชาวิศวกรรมไฟฟ้าและชีวการแพทย์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์ Thradon_wat@nstru.ac.th

dujdow.b@psu.ac.th kiattisak.se@psu.ac.th apidet.b@psu.ac.th

บทคัดย่อ

งานวิจัยนี้นำเสนอการพัฒนาาระบบระบุตำแหน่งภายในอาคาร โดยการผสานข้อมูลตัวบ่งชี้ความแรงสัญญาณที่ได้รับ (Received Signal Strength Indicator: RSSI) กับข้อมูลเซนเซอร์วัดความเร่ง 3 แกน และประยุกต์ใช้การเรียนรู้ของเครื่อง (Machine Learning) การศึกษาใช้โหนดเซนเซอร์ไร้สาย SparkFun Thing Plus - XBee3 Micro ที่ทำงานตามมาตรฐาน IEEE 802.15.4 ความถี่ 2.4 GHz ในการเก็บข้อมูลการเคลื่อนไหวและความแรงสัญญาณจากอาสาสมัคร ระบบได้รับการออกแบบเพื่อจำแนกตำแหน่ง 3 บริเวณภายในอาคาร ได้แก่ บริเวณบันได ห้องนั่งเล่น และห้องรับประทานอาหาร การวิจัยทำการทดสอบเปรียบเทียบตัวจำแนก (Classifier) 33 แบบผ่านโปรแกรม MATLAB R2024b ผลการทดลองพบว่า การใช้ข้อมูลตัวบ่งชี้ความแรงสัญญาณที่ได้รับเพียงอย่างเดียว (จำนวน 12 คุณลักษณะ) ให้ความแม่นยำ 93.0% ในการจำแนกบริเวณ ในขณะที่การผสานข้อมูลตัวบ่งชี้ความแรงสัญญาณที่ได้รับกับข้อมูลเซนเซอร์วัดความเร่ง 3 แกน (51 คุณลักษณะ) ให้ความแม่นยำสูงถึง 99.6% ด้วยตัวจำแนก Fine K-Nearest-Neighbors (KNN) ผลการวิจัยแสดงให้เห็นว่าการรวมข้อมูลเซนเซอร์สามารถเพิ่มความแม่นยำได้อย่างมีนัยสำคัญ โดยมีความแม่นยำเพิ่มขึ้น 6.6%

คำสำคัญ: การระบุตำแหน่งภายในอาคาร ตัวบ่งชี้ความแรงสัญญาณที่ได้รับ การเรียนรู้ของเครื่อง เซนเซอร์วัดความเร่ง การผสานข้อมูลเซนเซอร์

Abstract

This work presents the development of an indoor localization system through the integration of Received Signal Strength Indicator (RSSI) data with 3-axis acceleration data and machine learning techniques. The study employs SparkFun Thing Plus - XBee3 Micro wireless sensor nodes operating under the IEEE 802.15.4 standard at 2.4 GHz to collect RSSI and acceleration data from volunteers. The system was designed to classify three indoor locations: a staircase area, a living room, and a dining room. The research methodology involved testing and comparison of 33 machine learning-based classification models using MATLAB R2024b. Experimental results indicated that using only RSSI data with 12 features, a classification accuracy of 93.0% could be obtained. For the fusion of RSSI data with 3-axis accelerometer data, totaling 51 features, there was an accuracy of 99.6% using the Fine k-Nearest Neighbors (k-NN). Experimental results demonstrate that sensor data fusion can significantly enhance localization accuracy with a 6.6% improvement.

Keywords: Indoor Localization, Received Signal Strength Indicator, Machine Learning, Accelerometer, Sensor Fusion

1. บทนำ

ในยุคปัจจุบันที่เทคโนโลยีมีความก้าวหน้าอย่างรวดเร็ว การระบุตำแหน่งภายในอาคาร (Indoor Localization) ได้กลายเป็นเทคโนโลยีสำคัญที่ขับเคลื่อนการพัฒนาแอปพลิเคชันอัจฉริยะหลากหลายประเภท ตั้งแต่ระบบนำทางภายในอาคารขนาดใหญ่ การจัดการคลังสินค้า ไปจนถึงระบบดูแลสุขภาพของผู้สูงอายุในบ้านอัจฉริยะ ถึงแม้ว่าระบบระบุตำแหน่งด้วยจีพีเอส (Global Positioning System: GPS) จะได้รับความนิยมและถูกใช้อย่างแพร่หลาย แต่ก็มีข้อบกพร่องบางประการที่จำกัดประสิทธิภาพของการใช้งานในการระบุตำแหน่งภายในอาคาร เนื่องจากสภาพแวดล้อมภายในอาคารที่มีความซับซ้อนและมีขนาดที่แตกต่างกัน นอกจากนี้ยังมีวัตถุที่อยู่เบื้องหลังและเคลื่อนไหว เช่น เฟอร์นิเจอร์และผู้คน ปัจจัยเหล่านี้ส่งผลต่อการแพร่กระจายของคลื่นสัญญาณวิทยุอย่างมีนัยสำคัญ ทำให้เกิดการลดทอน (Attenuation) การกระเจิง (Scattering) การบดบัง (Shadowing) และจุดอับสัญญาณ ซึ่งลดความแม่นยำของการระบุตำแหน่งภายในอาคารลงอย่างมาก [1]

ด้วยเหตุนี้การพัฒนาาระบบระบุตำแหน่งภายในอาคารให้มีความแม่นยำจึงเป็นประเด็นที่น่าสนใจและมีความท้าทายอย่างมาก โดยเฉพาะอย่างยิ่งในสถานการณ์ที่ต้องการการติดตามการเคลื่อนไหวของบุคคลหรือวัตถุภายในอาคารแบบเรียลไทม์ เช่น การช่วยเหลือผู้พิการหรือผู้สูงอายุในการนำทาง การจัดการบุคลากรในโรงงานอุตสาหกรรม หรือระบบรักษาความปลอดภัยในอาคาร ในช่วงล่าสุด วิธีการระบุตำแหน่งแบบอิงระยะทาง (Range-based) โดยอิงตัวบ่งชี้ความแรงของสัญญาณที่ได้รับ เป็นวิธีการหนึ่งที่มีความนิยม [2-7] วิธีการดังกล่าวต้องการโหนดอ้างอิงที่ทราบตำแหน่งอย่างน้อยสามจุดเพื่อคำนวณตำแหน่งของเป้าหมายที่ไม่ทราบตำแหน่ง แนวทางนี้ต้องประสบกับความท้าทายอย่างมาก ได้แก่ ความแปรปรวนของสัญญาณวิทยุที่ส่งผลต่อความแม่นยำ และความซับซ้อนในการคำนวณ อย่างไรก็ตามช่วงไม่กี่ปีที่ผ่านมา การเรียนรู้ของเครื่อง (Machine Learning: ML) ได้พบความสำเร็จที่ดีในการระบุตำแหน่งไม่ว่าจะเป็นภายนอกอาคาร [8] และการระบุตำแหน่งภายในอาคาร [9] ข้อได้เปรียบหลักของแนวทางการเรียนรู้ของเครื่อง คือความสามารถในการตัดสินใจอย่างมีประสิทธิภาพโดยใช้ข้อมูลที่สังเกตได้โดยไม่ต้องมีการสร้างสูตรทางคณิตศาสตร์ที่แม่นยำ [1]

จากการทบทวนวรรณกรรม พบช่องว่างของการวิจัยหลายประการที่ยังสามารถพัฒนาต่อได้ งานวิจัยส่วนใหญ่มุ่งเน้นไปที่การพัฒนาอัลกอริทึมเฉพาะ แม้ว่าจะมีการศึกษาอัลกอริทึมต่าง ๆ เช่น K-Nearest-Neighbors (KNN) [2, 10, 11] Support Vector Machine (SVM) [11] Random Forest (RF) [11, 12] และ Artificial Neural Network (ANN) [12, 13] แต่ยังคงขาดการเปรียบเทียบประสิทธิภาพในสภาพแวดล้อมเดียวกันและด้วยชุดข้อมูลเดียวกัน งานวิจัยส่วนใหญ่ทำการทดลองในสภาพแวดล้อมที่ควบคุมได้ เช่น ห้องปฏิบัติการหรือสำนักงาน ซึ่งอาจไม่สะท้อนถึงความซับซ้อนและความท้าทายที่เกิดขึ้นในสภาพแวดล้อมที่อยู่อาศัยจริง


งานวิจัยนี้มุ่งเน้นการพัฒนาาระบบระบุตำแหน่งภายในอาคารที่รวมการวัดตัวบ่งชี้ความแรงของสัญญาณที่ได้รับเข้ากับข้อมูลจากเซนเซอร์วัดความแรงเพื่อจำแนกรูปแบบการเคลื่อนไหวของมนุษย์ในตำแหน่งต่าง ๆ ภายในอาคาร โดยเปรียบเทียบแบบจำลองการเรียนรู้ของเครื่องจำนวน 33 แบบใน 8 กลุ่มตัวจำแนกในสภาพแวดล้อมเดียวกัน เพื่อหาแบบจำลองที่ให้ประสิทธิภาพสูงสุดสำหรับการจำแนกตำแหน่งภายในอาคาร

บทความนี้จัดโครงสร้างดังต่อไปนี้ ส่วนที่ 2 วิธีการดำเนินการวิจัย ซึ่งประกอบไปด้วย สภาพแวดล้อมการทดลอง ส่วนประกอบฮาร์ดแวร์ ขั้นตอนการเก็บข้อมูล และการใช้งานการเรียนรู้ของเครื่อง ส่วนที่ 3 ผลการวิจัยและการวิเคราะห์ และสุดท้ายส่วนที่ 4 บทสรุป

2. วิธีการดำเนินงานวิจัย

2.1 สภาพแวดล้อมการทดลอง


ลักษณะของพื้นที่ที่ใช้ในทดลองเป็นอาคารที่อยู่อาศัย 2 ชั้น ขนาดประมาณ 8.40 x 8.23 เมตร ชั้นล่างประกอบด้วยห้องต่าง ๆ หลายห้อง คือ ห้องครัว ห้องเก็บวัสดุอุปกรณ์ ห้องซักผ้า ห้องรับประทานอาหาร ห้องสวดมนต์ ห้องนั่งเล่น และห้องน้ำ กำหนดเส้นทางที่ใช้ครอบคลุมพื้นที่หลัก ได้แก่ ตำแหน่งที่ 1 บริเวณบันได (ป้ายกำกับ 1 หรือ Label 1) ตำแหน่งที่ 2 ห้องนั่งเล่น (ป้ายกำกับ 2) และตำแหน่งที่ 3 ห้องรับประทานอาหาร (ป้ายกำกับ 3) โดยให้อาสาสมัครทำการเดินตามเส้นทางที่กำหนดไว้ล่วงหน้า เริ่มจากห้องรับประทานอาหาร เคลื่อนผ่านห้องนั่งเล่น และขึ้นบันไดไปยังชั้นที่สอง ตามที่แสดงด้วยลูกศรสีเขียวในแผนผังอาคาร ดังรูปที่ 1 ทำการเก็บข้อมูลเส้นทางนี้ซ้ำทั้งหมด 20 ครั้ง เพื่อใช้ในการวิเคราะห์ผล



2.2 ส่วนประกอบฮาร์ดแวร์

เซนเซอร์โหนดไร้สายที่ใช้ในงานวิจัยทั้งหมดจำนวน 2 โหนด ถูกออกแบบขึ้นจากบอร์ดไมโครคอนโทรลเลอร์ SparkFun Thing Plus - XBee3 Micro [14] มาพร้อมเสาอากาศแบบชิปติดตั้งอยู่บนบอร์ด ผลิตโดยบริษัท SparkFun Electronics บอร์ดไมโครคอนโทรลเลอร์ดังกล่าวอ้างอิงมาตรฐาน IEEE 802.15.4 ความถี่ 2.4 GHz โดยมีอัตราบิต 250 kbps และอัตราการ

ถ่ายโอนข้อมูลแบบอนุกรม 1 Mbps งานวิจัยนี้กำหนดให้กำลังส่งสัญญาณเท่ากับ +8 dBm [15]



รูปที่ 2 ส่วนประกอบของระบบเซนเซอร์โหนดไร้สาย

เซนเซอร์โหนดตัวที่หนึ่งเป็นโหนดส่งสัญญาณ (Transmitter: Tx) ซึ่งเป็นโหนดเคลื่อนที่สวมใส่ที่ข้อมือของอาสาสมัครชาย (อายุ 38 ปี ส่วนสูง 165 เซนติเมตร น้ำหนัก 57 กิโลกรัม) เนื่องจากผู้สวมใส่ให้คะแนนความสบายและความสะดวกในการสวมใส่เป็นปัจจัยสำคัญที่สุดในการตัดสินใจเลือกตำแหน่งการวางเซนเซอร์ โดยตำแหน่งที่ได้รับความพึงพอใจมากที่สุดคือ บริเวณข้อมือข้อเท้า และเอว [16, 17] โหนดส่งสัญญาณ (Tx) ประกอบด้วยเซนเซอร์วัดความแรง GY-521 ที่ใช้ชิป MPU-6050 ซึ่งเป็นเซนเซอร์ความเร่งแบบ 3 แกนที่สามารถวัดข้อมูลความเร่งในทิศทางแกน x แกน y และแกน z เซนเซอร์ GY-521 มีความยืดหยุ่นในการวัดเนื่องจากมีช่วงการวัดความเร่งที่สามารถปรับเปลี่ยนได้ 4 ระดับ ได้แก่ $\pm 2g$, $\pm 4g$, $\pm 8g$ และ $\pm 16g$ งานวิจัยนี้กำหนดค่าดังกล่าวไว้ที่ $\pm 2g$ เพื่อให้เหมาะสมกับการเก็บสัญญาณความเร่งขณะมนุษย์มีการเคลื่อนที่ การเชื่อมต่อกับบอร์ดไมโครคอนโทรลเลอร์ทำผ่าน I²C (Inter-Integrated Circuit) ข้อมูลจำเพาะของบอร์ด XBee3 Micro และเซนเซอร์วัดความแรง GY-521 แสดงดังตารางที่ 1

เซนเซอร์โหนดตัวที่สองทำหน้าที่เป็นสถานีฐาน (Base Station: BS) สำหรับรับข้อมูลเซนเซอร์และเชื่อมต่อกับคอมพิวเตอร์เป็นศูนย์กลางประมวลผล แสดงดังรูปที่ 2

ตารางที่ 1 ข้อมูลจำเพาะของบอร์ด SparkFun Thing Plus - XBee3 Micro และเซนเซอร์วัดความแรง GY-521 [14, 15]

ข้อมูลจำเพาะของบอร์ดไมโครคอนโทรลเลอร์	
ไมโครคอนโทรลเลอร์	Silicon Labs EFR32MG SoC
หน่วยความจำแฟลช	1 MB (รองรับไมโครโปรตอน 32 KB)
หน่วยความจำแรม	128 KB
ย่านความถี่	2.4 GHz (2.4 – 2.4835 GHz)
อัตราบิต	250 Kbps
ระยะการสื่อสารภายในอาคาร/เมือง	สูงสุด 200 ฟุต (60 m)
ระยะการสื่อสารภายนอกอาคาร/ทางตรง	สูงสุด 4,000 ฟุต (1,200 m)
กำลังส่ง	-5 dBm, -1 dBm, +2 dBm, +5 dBm และ +8 dBm
ความไวของตัวรับ	-103 dBm
การสื่อสารแบบอนุกรม	UART, I2C
แรงดันไฟฟ้า	2.6 VDC – 3.6 VDC
กระแสไฟฟ้าในการทำงาน (ส่ง, ปกติ)	40 mA @ +3.3 V, +8 dBm
กระแสไฟฟ้าในการทำงาน (รับ, ปกติ)	17 mA
จำนวนช่องสัญญาณ	16 ช่อง (11 - 26)
การจัดการพลังงาน	รองรับการชาร์จแบตเตอรี่ LiPo

ข้อมูลจำเพาะของเซนเซอร์วัดความเร่ง GY-521

ชิป	MPU-6050
ช่วงการวัดความเร่ง	2g, ±4g, ±8g และ ±16g
ความละเอียดของ ADC	16 บิต
การสื่อสารแบบอนุกรม	I2C
แรงดันไฟฟ้า	2.375 V - 3.46 V
กระแสไฟฟ้าในการทำงาน (ปกติ)	500 µA
กระแสไฟฟ้าในการทำงาน (ประหยัต์)	10 µA @ 1.25 Hz, 20 µA @ 5 Hz, 60 µA @ 20 Hz และ 110 µA @ 40 Hz

2.3 ขั้นตอนการเก็บข้อมูล

การกำหนดค่าการสุ่มตัวอย่างการส่งข้อมูลเกิดขึ้นทุก ๆ 100 มิลลิวินาที (อัตราการสุ่ม 10 Hz) [15, 16] จากโหนดส่งสัญญาณไปยังโหนดสถานีฐาน ซึ่งข้อมูลแต่ละแพ็กเก็ตประกอบด้วย หมายเลขบิตไบนารี ลำดับของแพ็กเก็ต ค่าความเร่งในแนวแกน x แกน y และแกน z ตามลำดับ หลังจากโหนดสถานีฐานได้รับแพ็กเก็ตข้อมูลจะทำการอ่านค่าตัวบ่งชี้ความเร่งสัญญาณที่ได้รับ จากนั้นข้อมูลทั้งหมดจะถูกจัดเก็บในรูปแบบของไฟล์ .CSV สำหรับใช้วิเคราะห์ข้อมูลในขั้นตอนต่อไป ชุดข้อมูลทั้งหมดประกอบด้วยข้อมูลจากการทดลอง 20 ครั้ง ส่งผลให้ได้ตัวอย่างข้อมูลทั้งหมด 13,342 ตัวอย่าง

2.4 การใช้งานการเรียนรู้ของเครื่อง

2.4.1 การสกัดคุณลักษณะและการประมวลผลสัญญาณ

การสกัดคุณลักษณะ (Feature Extraction) ตัวบ่งชี้ความเร่งสัญญาณที่ได้รับ ใช้เทคนิคหน้าต่างเลื่อน (Sliding window) ที่มีขนาดหน้าต่าง 25 ตัวอย่าง เพื่อสกัดคุณลักษณะทางสถิติ งานวิจัยนี้กำหนดให้สกัดคุณลักษณะทางสถิติจำนวน 11 ตัว แสดงดังสมการที่ (1) - (11)

ค่าสูงสุด (Maximum)

$$\max_{w,i} = \max\{x[k] : k \in [i - w + 1, i]\} \quad (1)$$

ค่าต่ำสุด (Minimum)

$$\min_{w,i} = \min\{x[k] : k \in [i - w + 1, i]\} \quad (2)$$

ค่าเฉลี่ย (Mean)

$$\mu_{w,i} = \frac{1}{w} \sum_{k=i-w+1}^i x[k] \quad (3)$$

ส่วนเบี่ยงเบนมาตรฐาน (Standard deviation)

$$\sigma_{w,i} = \sqrt{\frac{1}{w} \sum_{k=i-w+1}^i (x[k] - \mu_{w,i})^2} \quad (4)$$

พิสัย (Range)

$$\text{range}_i = \max_{w,i} - \min_{w,i} \quad (5)$$

มัธยฐาน (Median)

$$\text{median}_{w,i} = \begin{cases} \text{sorted}_{x_k} \left[\frac{(w+1)}{2} \right] & \text{if } w \text{ is odd} \\ \frac{(\text{sorted}_{x_k} \left[\frac{w}{2} \right] + \text{sorted}_{x_k} \left[\frac{(w+1)}{2} \right])}{2} & \text{if } w \text{ is even} \end{cases} \quad (6)$$

โดย $\text{sorted}_{x_k} = \text{sorted}(\{x[k] : k \in [i - w + 1, i]\})$

พิสัยระหว่างควอร์ไทล์ (Interquartile range)

$$IQR_{w,i} = Q_{3,w,i} - Q_{1,w,i} \quad (7)$$

โดยที่ $Q_{1,w,i}$ คือเปอร์เซ็นต์ไทล์ที่ 25 (25th percentile) และ $Q_{3,w,i}$

เปอร์เซ็นต์ไทล์ที่ 75 (75th percentile)

เปอร์เซ็นต์ไทล์ที่ 10 (10th percentile)

$$P_{10,w,i} = \text{value at position } [0.10 \times w] \text{ in sorted array} \quad (8)$$

เปอร์เซ็นต์ไทล์ที่ 25 (25th percentile)

$$P_{25,w,i} = \text{value at position } [0.25 \times w] \text{ in sorted array} \quad (9)$$

เปอร์เซ็นต์ไทล์ที่ 75 (75th percentile)

$$P_{75,w,i} = \text{value at position } [0.75 \times w] \text{ in sorted array} \quad (10)$$

เปอร์เซ็นต์ไทล์ที่ 90 (90th percentile)

$$P_{90,w,i} = \text{value at position } [0.90 \times w] \text{ in sorted array} \quad (11)$$

โดยที่ w ขนาดหน้าต่าง


สำหรับการสกัดคุณลักษณะจากเซนเซอร์วัดความเร่งดำเนินการในลักษณะเดียวกันกับการสกัดคุณลักษณะจากตัวบ่งชี้ความเร่งสัญญาณที่ได้รับ เซนเซอร์วัดความเร่งให้ข้อมูล 3 แกน ได้แก่ แกน x, y และ z ซึ่งในแต่ละแกนจะถูกสกัดคุณลักษณะทางสถิติ 11 ตัว เช่นเดียวกับกรณีตัวบ่งชี้ความเร่งสัญญาณที่ได้รับ ทำให้ได้คุณลักษณะรวมจากเซนเซอร์วัดความเร่งทั้ง 3 แกนเท่ากับ 33 คุณลักษณะ นอกจากการสกัดคุณลักษณะจากแต่ละแกนแล้ว ยังได้คำนวณหาขนาดเวกเตอร์ความเร่ง (Signal Vector Magnitude) จากข้อมูลความเร่งทั้ง 3 แกน ตามสมการ (12)

$$SVM_i = \sqrt{a_{x,i}^2 + a_{y,i}^2 + a_{z,i}^2} \quad (12)$$

โดยที่ $a_{x,i}$, $a_{y,i}$ และ $a_{z,i}$ คือ ความเร่งในแนวแกน x, y และ z จากขนาดเวกเตอร์ความเร่งที่คำนวณได้ จะถูกนำมาสกัดคุณลักษณะเพิ่มเติมโดยใช้เทคนิคหน้าต่างเลื่อนที่มีขนาดหน้าต่าง 25 ตัวอย่าง เพื่อให้ได้คุณลักษณะทางสถิติอีก 2 ตัว ประกอบด้วย ค่าเฉลี่ยของขนาดเวกเตอร์ความเร่ง (Mean of acceleration magnitude) และส่วนเบี่ยงเบนมาตรฐานของขนาดเวกเตอร์ความเร่ง (Standard deviation of acceleration magnitude)

งานวิจัยนี้กำหนดชุดข้อมูลทดสอบเป็นสองกรณี โดยกรณีแรกใช้เฉพาะข้อมูลตัวบ่งชี้ความเร่งสัญญาณที่ได้รับและคุณลักษณะทางสถิติของตัวบ่งชี้ความเร่งสัญญาณที่ได้รับ รวม 12 คุณลักษณะ ส่วนกรณีที่สองใช้คุณลักษณะทั้งหมดจากตัวบ่งชี้ความเร่งสัญญาณที่ได้รับ 12 คุณลักษณะและเซนเซอร์วัดความเร่ง 39 คุณลักษณะ รวมเป็น 51 คุณลักษณะ

2.4.2 การจำแนกประเภท



Note
S11-S1K: acceleration signal in x-axis (Ax) for K samples
S21-S2K: acceleration signal in y-axis (Ay) for K samples
S31-S3K: acceleration signal in z-axis (Az) for K samples
S41-S4K: RSSI signal for K samples

F11-F1K to F111-F11K: RSSI features (11 features according to equations 1-11)
F121-F12K to FN1-FNK: 3-axis acceleration features (36 features according to equations 1-12)

รูปที่ 3 แผนภาพโครงสร้างระบบการจำแนกประเภทตำแหน่ง

รูปที่ 3 แสดงภาพรวมของการจำแนก ตั้งแต่การเก็บข้อมูลไปจนถึงการจำแนกตำแหน่ง ขั้นตอนการประมวลผลเริ่มต้นด้วยการสกัดคุณลักษณะ โดยรับข้อมูลดิบจากเซนเซอร์ความเร่งสามแกนและตัวบ่งชี้ความเร่งสัญญาณที่ได้รับ จากนั้นประมวลผลด้วยหน้าต่างเลื่อนขนาด 25 ตัวอย่าง เพื่อสกัดคุณลักษณะตามที่อธิบายไว้ในหัวข้อย่อย 2.4.1 สำหรับขั้นตอนการจำแนกประเภท งานวิจัยนี้ได้ใช้โปรแกรม MATLAB 2024b ทำการประเมินแบบจำลองการเรียนรู้ของเครื่องทั้งหมด 33 โมเดลย่อย ใน 8 กลุ่มตัวจำแนกแสดงดังตารางที่ 2 โดยใช้การตรวจสอบไขว้ 10-fold cross-validation และแบ่งชุดข้อมูล 80% สำหรับฝึกสอน (10,674 ตัวอย่าง) และ 20% สำหรับทดสอบ (2,668 ตัวอย่าง) [11] ในขั้นตอนการตัดสินใจ ระบบให้ผลลัพธ์การจำแนกประเภทเป็นตัวเลข 1-3 โดยหมายเลข 1 แทนบริเวณบันได หมายเลข 2 แทนห้องนั่งเล่น และหมายเลข 3 แทนห้องรับประทานอาหาร สุดท้ายขั้นตอนการประเมินผลด้วยตัวชี้วัดประสิทธิภาพ เพอร์เซ็นต์ความแม่นยำการจำแนกประเภท (Classification Accuracy %) และเมตริกซ์ความสับสน



ตารางที่ 2 ข้อมูลตัวจำแนก

ตัวจำแนก (Classifier)	โมเดลย่อย (Sub-model)	ตัวจำแนก (Classifier)	โมเดลย่อย (Sub-model)
Tree	1) Fine Tree 2) Medium Tree 3) Coarse Tree	KNN	1) Fine KNN 2) Weighted KNN 3) Medium KNN 4) Cubic KNN 5) Cosine KNN 6) Coarse KNN
Discriminant	1) Quadratic Discriminant 2) Linear Discriminant	Kernel	1) SVM Kernel 2) Logistic Regression Kernel
SVM	1) Fine Gaussian SVM 2) Cubic SVM 3) Medium Gaussian SVM 4) Quadratic SVM 5) Coarses Gaussian SVM 6) Linear SVM	Ensemble	1) Subspace KNN 2) Bagged Trees 3) Boosted Trees 4) RUSBoosted Trees 5) Subspace Discriminant
Efficient Linear	1) Efficient Logistic Regression 2) Efficient Linear SVM	Neural Network	1) Wide Neural Network 2) Medium Neural Network 3) Trilayered Neural Network 4) Bilayered Neural Network 5) Narrow Neural Network


3. ผลการวิจัยและการวิเคราะห์ผล

รูปที่ 4 (ก) แสดงสัญญาณความเร่ง 3 แกน ขณะที่รูปที่ 4 (ข) แสดงค่าตัวบ่งชี้ความเร่งสัญญาณที่ได้รับ ซึ่งเป็นสัญญาณที่บันทึกได้ในเวลาเดียวกันระหว่างทางทดสอบ 1 ครั้ง โดยการกระจายสัญญาณ ช่วงตัวอย่างที่ 1-180 เป็นสัญญาณจากห้องรับประทานอาหาร ขณะที่ช่วงตัวอย่างที่ 181-529 เป็นสัญญาณจากห้องนั่งเล่น และช่วงตัวอย่างที่ 530-730 เป็นสัญญาณจากบริเวณบันได จากรูปที่ 4 (ก) หากคำนวณหาค่าเฉลี่ยพิสัยของความเร่งแกน x และแกน y จากตัวอย่างที่ 530-730 จะได้ค่าดังกล่าวเท่ากับ 0.90 และ 1.07 ตามลำดับ ในขณะที่หากคำนวณหาค่าเฉลี่ยพิสัยของความเร่งแกน x และแกน y จากตัวอย่างที่ 1-180 จะได้ค่าดังกล่าวเท่ากับ 0.63 และ 0.38 ซึ่งจะเห็นได้ว่าค่าเฉลี่ยพิสัยของความเร่งแกน x และแกน y จากทั้งสองช่วงตัวอย่างมีความแตกต่างกันอย่างชัดเจน ดังนั้นหากนำข้อมูลความเร่งเข้ามาช่วยในการ

จำแนกประเภทก็จะช่วยจำแนกบริเวณบันไดกับห้องรับประทานอาหารได้อย่างแม่นยำยิ่งขึ้น ขณะที่รูปที่ 4 (ข) แสดงค่าตัวบ่งชี้ความเร่งสัญญาณที่ได้รับ ซึ่งจะเห็นได้ว่าค่าดังกล่าวจะค่อย ๆ เพิ่มขึ้นเมื่อมีการเคลื่อนที่จากห้องรับประทานอาหารมายังห้องนั่งเล่น และค่อย ๆ ลดลงเมื่อเคลื่อนที่จากห้องนั่งเล่นไปยังบริเวณบันได เนื่องจากเซนเซอร์โหนดที่ทำหน้าที่เป็นสถานีฐานติดตั้งอยู่ที่ห้องนั่งเล่น




รูปที่ 4 สัญญาณข้อมูลเซนเซอร์ตัวอย่างจากการทดลอง 1 ครั้ง: (ก) สัญญาณความเร่ง 3 แกน และ (ข) ค่าตัวบ่งชี้ความเร่งสัญญาณที่ได้รับ



รูปที่ 5 การเปรียบเทียบประสิทธิภาพของตัวจำแนกทั้ง 33 แบบ สำหรับกรณีที่ 2


จากการวิเคราะห์ผลลัพธ์จากแบบจำลองทั้งหมดแสดงให้เห็นว่าแบบจำลอง Fine KNN (K=1, Euclidean Distance) ให้ประสิทธิภาพสูงสุดด้วยความแม่นยำ 99.4% สำหรับการฝึกสอน ดังนั้นงานวิจัยนี้จึงเลือกโมเดลย่อยดังกล่าวมานำเสนอการวิเคราะห์ประสิทธิภาพเปรียบเทียบระหว่างการทำหาค่าคุณลักษณะสองกรณี อย่างไรก็ตามแบบจำลองที่ให้ประสิทธิภาพใกล้เคียงกัน ได้แก่ Bagged Trees, Weighted KNN, Wide Neural Network และ Cubic SVM โดยให้ความแม่นยำมากกว่า 98% ดังรูปที่ 5




รูปที่ 6 การเปรียบเทียบประสิทธิภาพโมเดลย่อย Fine k-NN

จากรูปที่ 6 จะเห็นว่าโมเดล Fine KNN ให้ประสิทธิภาพที่ต่างกัน อย่างชัดเจนระหว่างสองกรณี โดยกรณีที่หนึ่งใช้เฉพาะข้อมูลตัวบ่งชี้ความแรงสัญญาณที่ได้รับและคุณลักษณะของตัวบ่งชี้ความแรงสัญญาณที่ได้รับ รวม 12 คุณลักษณะ ระบบให้ความแม่นยำการฝึกสอน 93.2% และความแม่นยำการทดสอบ 93.0% ในขณะที่กรณีที่สองซึ่งใช้ชุดคุณลักษณะทั้งหมดจากการผสานข้อมูลส่งผลให้ได้ความแม่นยำการฝึกสอน 99.4% และความแม่นยำการทดสอบ 99.6% ผลลัพธ์ดังกล่าวนี้แสดงการปรับปรุงประสิทธิภาพอย่างมีนัยสำคัญเมื่อผสานคุณลักษณะเซนเซอร์วัดความแรงเข้ากับการวัดตัวบ่งชี้ความแรงสัญญาณที่ได้รับ โดยชุดคุณลักษณะทั้งหมดในกรณีที่สองให้ความแม่นยำการจำแนกด้วยการปรับปรุงความแม่นยำการทดสอบเพิ่มขึ้น 6.6% เมื่อเทียบกับแนวทางที่ใช้ตัวบ่งชี้ความแรงสัญญาณที่ได้รับเพียงอย่างเดียว

Confusion Matrix สำหรับกรณีที่หนึ่ง ดังรูปที่ 7 แสดงให้เห็นประสิทธิภาพการจำแนกประเภทที่ต่างกันในแต่ละตำแหน่ง โดยตำแหน่งที่หนึ่งซึ่งเป็นบริเวณบันไดมีความแม่นยำ 92.2% ด้วยข้อผิดพลาดรวม 7.8% ซึ่งประกอบด้วยการจำแนกผิดเป็นตำแหน่งที่สอง (ห้องนั่งเล่น) 2.5% และเป็นตำแหน่งที่สาม (ห้องรับประทานอาหาร) 5.3% ตำแหน่งที่สองคือห้องนั่งเล่นแสดงประสิทธิภาพที่ดีที่สุดด้วยความแม่นยำ 94.5% และข้อผิดพลาดรวม 5.5% จากการจำแนกผิดเป็นตำแหน่งที่หนึ่ง (บริเวณบันได) 2.1% และเป็นตำแหน่งที่สาม (ห้องรับประทานอาหาร) 3.4% ส่วนตำแหน่งที่สามซึ่งเป็นห้องรับประทานอาหารมีความแม่นยำ 91.4% พร้อมข้อผิดพลาดรวม 8.6% จากการจำแนกผิดเป็นตำแหน่งที่หนึ่ง (บริเวณบันได) 5.7% และเป็นตำแหน่งที่สอง 2.9%



รูปที่ 7 Confusion Matrix สำหรับการจำแนกตำแหน่งโดยใช้คุณลักษณะ RSSI เพียงอย่างเดียว (12 คุณลักษณะ) ด้วยโมเดลย่อย Fine k-NN



รูปที่ 8 Confusion Matrix สำหรับการจำแนกตำแหน่งโดยการผสานข้อมูล RSSI และเซนเซอร์วัดความแรง (51 คุณลักษณะ) ด้วยโมเดลย่อย Fine k-NN

Confusion Matrix สำหรับกรณีที่สอง ดังรูปที่ 8 แสดงให้เห็นประสิทธิภาพการจำแนกประเภทที่แม่นยำในทุกตำแหน่ง บริเวณบันไดซึ่งมีความแม่นยำ 99.5% ด้วยข้อผิดพลาดรวมเพียง 0.5% ซึ่งแบ่งเป็นการจำแนกผิดเป็นตำแหน่งที่สอง (ห้องนั่งเล่น) และตำแหน่งที่สาม (ห้องรับประทานอาหาร) อย่างละ 0.2% ห้องนั่งเล่นหรือตำแหน่งที่สองให้ความแม่นยำ 99.6% พร้อมข้อผิดพลาดรวม 0.4% จากการจำแนกผิดเป็นตำแหน่งที่หนึ่ง (บริเวณบันได) 0.1% และเป็นตำแหน่งที่สาม (ห้องรับประทานอาหาร) 0.3% ห้องรับประทานอาหารซึ่งเป็นตำแหน่งที่สามแสดงประสิทธิภาพสูงสุดด้วยความแม่นยำ 99.7% และข้อผิดพลาดรวม 0.3% จากการจำแนกผิดเป็นตำแหน่งที่สองเพียง 0.3% โดยไม่มีการจำแนกผิดเป็นตำแหน่งที่หนึ่งเลย

4. บทสรุป

งานวิจัยนี้ได้พัฒนาระบบระบุตำแหน่งภายในอาคารผ่านการผสานข้อมูลตัวบ่งชี้ความแรงสัญญาณที่ได้รับ (RSSI) กับข้อมูลเซนเซอร์วัดความแรง 3 แกน และประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่อง ผลการศึกษาแสดงให้เห็นความสำเร็จในการจำแนกตำแหน่ง 3 บริเวณภายในอาคาร ได้แก่ บริเวณบันได ห้องนั่งเล่น และห้องรับประทานอาหาร ด้วยความแม่นยำสูง การเปรียบเทียบประสิทธิภาพพบว่า การใช้ข้อมูล RSSI (12 คุณลักษณะ) ให้ความแม่นยำการจำแนก 93.0% ในขณะที่การผสานข้อมูล RSSI กับข้อมูลเซนเซอร์วัดความแรง 3 แกน (51 คุณลักษณะ) สามารถเพิ่มความแม่นยำได้ถึง 99.6% ด้วยแบบจำลอง Fine k-Nearest Neighbors ซึ่งแสดงการปรับปรุงประสิทธิภาพ 6.6% เมื่อเปรียบเทียบกับการใช้ RSSI เพียงอย่างเดียว อย่างไรก็ตามการเลือกใช้ชุดคุณลักษณะควรพิจารณาความสมดุลระหว่างความแม่นยำและภาระการคำนวณ สำหรับการใช้งานทั่วไปที่อุปกรณ์มีข้อจำกัดด้านทรัพยากร การใช้ข้อมูล RSSI (12 คุณลักษณะ) อาจเหมาะสมกว่าเนื่องจากให้ความแม่นยำ 93.0% ที่ยังคงอยู่ในระดับสูงพร้อมภาระการคำนวณที่ต่ำ ในขณะที่ระบบที่ต้องการความแม่นยำสูงสุด เช่น ระบบดูแลผู้สูงอายุหรือการดูแลทางการแพทย์ การเพิ่มขึ้นของประสิทธิภาพ 6.6% นี้ อาจมีความสำคัญมาก

สำหรับข้อจำกัดของงานวิจัยนี้ประกอบด้วย การวิจัยในสภาพแวดล้อมเฉพาะเจาะจงคือในอาคารที่อยู่อาศัยแห่งเดียว การใช้อาสาสมัครเพียงคนเดียว และการจำกัดตำแหน่งเป้าหมายเพียง 3 บริเวณ ซึ่งอาจส่งผลกระทบต่อความเสถียรในการใช้งานจริง ผลการวิจัยนี้มีความสำคัญต่อการพัฒนาระบบนำทางภายในอาคาร การติดตามสุขภาพผู้สูงอายุ และระบบบ้านอัจฉริยะ การ

ผลจากข้อมูลเซนเซอร์หลายชนิดแสดงให้เห็นว่าเป็นแนวทางที่มีประสิทธิภาพในการเพิ่มความแม่นยำของระบบระบุตำแหน่ง สำหรับงานวิจัยในอนาคตควรขยายการทดสอบในสภาพแวดล้อมที่หลากหลายมากขึ้น การศึกษาผลกระทบของจำนวนและตำแหน่งการติดตั้งเซนเซอร์โหนดต่อประสิทธิภาพของระบบ การพัฒนาอัลกอริทึมที่สามารถทำงานแบบเรียลไทม์ และการรวมข้อมูลจากเซนเซอร์ชนิดอื่น ๆ เช่น ไจโรสโคป แมกนีโตมิเตอร์ หรือเซนเซอร์ความดัน เพื่อเพิ่มความแม่นยำและความน่าเชื่อถือของระบบให้สูงขึ้น

5. กิตติกรรมประกาศ

ผู้วิจัยขอขอบคุณกระทรวงอุดมศึกษา วิทยาศาสตร์ วิจัยและนวัตกรรม ที่ให้การสนับสนุนทุนวิจัยในการดำเนินงานวิจัยครั้งนี้

เอกสารอ้างอิง

- [1] A. Nessa, B. Adhikari, F. Hussain, and X. N. Fernando, "A Survey of Machine Learning for Indoor Positioning," *IEEE Access*, vol. 8, pp. 214945-214965, 2020, doi: 10.1109/ACCESS.2020.3039271.
- [2] H. S. Fahama, K. Ansari-Asl, Y. S. Kaviani, and M. N. Soorki, "An Experimental Comparison of RSSI-Based Indoor Localization Techniques Using ZigBee Technology," *IEEE Access*, vol. 11, pp. 87985-87996, 2023, doi: 10.1109/ACCESS.2023.3305396.
- [3] F. Y. M. Adiyatma, D. J. Suroso, and P. Cherntanomwong, "TLB & WC-TLB-MM: The Improved Min-Max Algorithms for Multi Targets Indoor Localization," *IEEE Access*, vol. 11, pp. 129733-129748, 2023, doi: 10.1109/ACCESS.2023.3333901.
- [4] A. Booranawong, K. Sengchua, D. Buranapanichkit, N. Jindapetch, and H. Saito, "RSSI-Based Indoor Localization Using Multi-Lateration With Zone Selection and Virtual Position-Based Compensation Methods," *IEEE Access*, vol. 9, pp. 46223-46239, 2021, doi: 10.1109/ACCESS.2021.3068295.
- [5] B. Yang, L. Guo, R. Guo, M. Zhao, and T. Zhao, "A Novel Trilateration Algorithm for RSSI-Based Indoor Localization," *IEEE Sensors Journal*, vol. 20, no. 14, pp. 8164-8172, 2020, doi: 10.1109/JSEN.2020.2980966.
- [6] T. Wattananavin, K. Sengchua, N. Jindapetch, and A. Booranawong, "A Comparative Study of RSSI-Based Localization Methods: RSSI Variation Caused by Human Presence and Movement," *Sensing and Imaging*, vol. 21, no. 1, p. 31, 2020/07/03 2020, doi: 10.1007/s11220-020-00296-1.
- [7] A. Booranawong, K. Sengchua, and N. Jindapetch, "Implementation and test of an RSSI-based indoor target localization system: Human movement effects on the accuracy," *Measurement*, vol. 133, pp. 370-382, 2019/02/01/2019, doi: <https://doi.org/10.1016/j.measurement.2018.10.031>.
- [8] D. Dogan, Y. Dalveren, A. Kara, and M. Derawi, "A Simplified Method Based on RSSI Fingerprinting for IoT Device Localization in Smart Cities," *IEEE Access*, vol. 12, pp. 163752-163763, 2024, doi: 10.1109/ACCESS.2024.3491977.
- [9] S. Singh, K. Kumar, and S. Gupta, "Machine Learning based Indoor Localization Techniques for Wireless Sensor Networks,"

in 2020 2nd International Conference on Advances in Computing, Communication Control and Networking (ICACCCN), 18-19 Dec. 2020 2020, pp. 373-380, doi: 10.1109/ICACCCN51052.2020.9362802.

- [10] M. T. Hoang et al., "A Soft Range Limited K-Nearest Neighbors Algorithm for Indoor Localization Enhancement," *IEEE Sensors Journal*, vol. 18, no. 24, pp. 10208-10216, 2018, doi: 10.1109/JSEN.2018.2874453.
- [11] L. Polak, S. Rozum, M. Slanina, T. Bravenec, T. Fryza, and A. Pikrakis, "Received Signal Strength Fingerprinting-Based Indoor Location Estimation Employing Machine Learning," *Sensors*, vol. 21, no. 13, p. 4605, 2021. [Online]. Available: <https://www.mdpi.com/1424-8220/21/13/4605>.
- [12] D. Csik, O. Á, and P. Sarcevic, "Comparison of RSSI-Based Fingerprinting Methods for Indoor Localization," in 2022 IEEE 20th Jubilee International Symposium on Intelligent Systems and Informatics (SISY), 15-17 Sept. 2022 2022, pp. 000273-000278, doi: 10.1109/SISY56759.2022.10036270.
- [13] Z. Munadhil, S. K. Gharghan, A. H. Mutlag, A. Al-Naji, and J. Chahl, "Neural Network-Based Alzheimer's Patient Localization for Wireless Sensor Network in an Indoor Environment," *IEEE Access*, vol. 8, pp. 150527-150538, 2020, doi: 10.1109/ACCESS.2020.3016832.
- [14] "SparkFun Thing Plus - XBee3 Micro (Chip Antenna)." <https://www.sparkfun.com/sparkfun-thing-plus-xbee3-micro-chip-antenna.html> (accessed 26, 2025).
- [15] A. Booranawong, S. Sukveeraphan, L. Pan, N. Jindapetch, P. Phukpattaranont, and H. Saito, "A real-time system for monitoring and classification of human falls on stairs using 2.4 GHz XBee3 micro modules with a tri-axial accelerometer and KNN algorithms," *Egyptian Informatics Journal*, vol. 30, p. 100643, 2025/06/01/2025, doi: <https://doi.org/10.1016/j.eij.2025.100643>.
- [16] O. Reich, E. Hübner, B. Ghita, M. F. Wagner, and J. Schäfer, "A Survey Investigating the Combination and Number of IMUs on the Human Body Used for Detecting Activities and Human Tracking," in 2020 World Conference on Computing and Communication Technologies (WCCCT), 13-15 May 2020 2020, pp. 20-27, doi: 10.1109/WCCCT49810.2020.9170009.
- [17] J. O'Day et al., "Assessing inertial measurement unit locations for freezing of gait detection and patient preference," *Journal of NeuroEngineering and Rehabilitation*, vol. 19, no. 1, p. 20, 2022/02/13 2022, doi: 10.1186/s12984-022-00992-x.