

ST-010

การเพิ่มความแม่นยำของระบบนำทางภายในอาคารด้วยเทคนิค WiFi Fingerprinting และ อัลกอริทึม KNN และการแสดงผลแบบเรียลไทม์ Improving Indoor Navigation Accuracy using WiFi Fingerprinting and KNN with Real-time Visualization on OpenStreetMap

พงษ์กร ไถนาเพริยว^{1,*} และ ธนภฤช จันทร์แสง²

Pongsakorn Tainapreaw^{1,*} and Tanagrit Chansaeng²

^{1,2}สาขาเทคโนโลยีดิจิทัล คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏภูเก็ต

^{1,2}Department of Digital Technology, Faculty of Science and Technology, Phuket Rajabhat University

*Corresponding author's e-mail: s6411423123@pkru.ac.th

บทคัดย่อ

ระบบการนำทางภายในอาคาร ได้รับความสนใจมากขึ้นในยุคที่เทคโนโลยีดิจิทัลมีบทบาทในการอำนวยความสะดวกให้กับผู้ใช้งานในพื้นที่ที่มีความซับซ้อน เช่น อาคารเรียนหรืออาคารสำนักงานหลายชั้น โดยเฉพาะในบริเวณที่สัญญาณ GPS ไม่สามารถใช้งานได้มีประสิทธิภาพ งานวิจัยนี้นำเสนอกรอบการพัฒนาการนำทางภายในอาคารที่อาศัยเทคนิค WiFi Fingerprinting ร่วมกับอัลกอริทึม K-Nearest Neighbors (KNN) และการแสดงผลบน OpenStreetMap (OSM) เพื่อเพิ่มความแม่นยำและความสามารถในการใช้งานจริงของระบบ

ระบบประกอบด้วย 3 ส่วนหลัก ได้แก่ การเก็บข้อมูล RSSI จาก Access Points (APs) ณ ตำแหน่งอ้างอิง (Reference Points: RPs) บนพื้นที่จำลอง 9 ชั้น การประมวลผลตำแหน่งด้วยอัลกอริทึม KNN โดยใช้ระยะ Euclidean เพื่อเทียบความคล้ายของเวกเตอร์ RSSI และการแสดงผลเส้นทางนำทางแบบ 3 มิติด้วยเครื่องมือ Plotly และการซ้อนแผนที่ลงบน OSM ทั้งนี้ ได้เพิ่ม Gaussian noise ในข้อมูลเพื่อเลียนแบบสัญญาณในโลกจริง และใช้การสุ่มแบบแบ่งชั้นเพื่อให้ได้ข้อมูลที่หลากหลาย

จากการทดลอง พบว่า KNN ที่ $k=2$ ให้ผลลัพธ์ที่ดีที่สุด โดยมีค่า Mean Error Distance (MED) เท่ากับ 218.42 เมตร และค่า RMSE รวมใน 2 มิติเท่ากับ 179.15 เมตร นอกจากนี้ได้เปรียบเทียบเส้นทางจากอัลกอริทึม A* กับเส้นทางเดินเท้าจริงที่พิจารณาเฉพาะโหนดทางเดินและบันได พบว่าระยะทางเดินจริงทั้งหมดจากชั้น 1 ไปยังชั้น 8 อยู่ที่ประมาณ 1,569.80 เมตร ซึ่งแสดงถึงความแตกต่างของเส้นทางที่คำนวณทางทฤษฎีกับการใช้งานจริง

ข้อจำกัดของระบบอยู่ที่ความไม่เสถียรของสัญญาณ WiFi จาก Multipath Effect และข้อจำกัดของแผนที่ภายในอาคารบน OSM งานวิจัยในอนาคตเสนอให้ผสานข้อมูลจากเซนเซอร์เฉื่อย (IMU) และใช้การปรับปรุงฐานข้อมูล Fingerprint แบบ crowdsourced เพื่อเพิ่มความแม่นยำและความยืดหยุ่นของระบบ

คำสำคัญ: ระบบนำทางภายในอาคาร, การจัดลายนิ้วมือสัญญาณ, อัลกอริทึมเพื่อนบ้านใกล้เคียง,
แผนที่โอเพ่นสตรีทแมป

ABSTRACT

Indoor navigation systems have become increasingly vital for supporting user mobility in complex multi-floor buildings, particularly in environments where GPS signals are weak or unavailable. This research presents a robust indoor navigation framework that leverages WiFi fingerprinting, K-Nearest Neighbors (KNN) algorithm, and OpenStreetMap (OSM) integration to improve the accuracy and usability of indoor positioning in a university building context.

The system consists of three main components: fingerprint data collection, localization, and real-time path visualization. In the fingerprinting phase, Received Signal Strength Indicator (RSSI) values are collected from multiple Access Points (APs) at various Reference Points (RPs) across 9 floors of a simulated university building. Gaussian noise was introduced to simulate real-world signal fluctuation, and stratified sampling was used to optimize the training dataset. For localization, the KNN algorithm is employed, utilizing distance metrics such as Euclidean Distance to estimate user location based on similarity to known RSSI vectors. The optimal value of k was determined experimentally, with $k = 2$ yielding the lowest Mean Error Distance (MED) of 218.42 meters and a 2D RMSE of 179.15 meters. The A* pathfinding algorithm was used to generate the shortest path on a grid graph, while realistic walk paths constrained to hallway and stair nodes were computed separately.

A comparative analysis reveals that while A* finds theoretically shortest paths, realistic navigation requires adjustments to account for vertical transitions and physical constraints. The real walking distance across floors 1 to 8, including stair traversal and horizontal walking, totals approximately 1,569.80 meters.

The visualization component integrates 3D Plotly-based rendering and OpenStreetMap overlays, enhancing clarity and interpretability. Limitations such as RSSI

variability due to multipath effects and incomplete indoor maps are discussed, and future improvements are proposed, including hybrid positioning systems, sensor fusion with IMUs, and dynamic fingerprint updates via crowdsourcing.

The proposed system demonstrates that combining WiFi fingerprinting, machine learning, and real-time path visualization provides a scalable and accurate solution for indoor navigation in multi-floor educational environments.

Keywords: Indoor Navigation, WiFi Fingerprinting, K-Nearest Neighbors (KNN), OpenStreetMap (OSM)

บทนำ

ความสำคัญของระบบระบุตำแหน่งภายในอาคาร (Indoor Positioning Systems - IPS) ในยุคปัจจุบัน

เทคโนโลยีการระบุตำแหน่งได้กลายมาเป็นส่วนสำคัญของชีวิตประจำวัน โดยเฉพาะในแอปพลิเคชันแบบเรียลไทม์ เช่น การนำทาง การจัดการโลจิสติกส์ การติดตามทรัพย์สิน และการจัดการความปลอดภัย อย่างไรก็ตาม ระบบระบุตำแหน่งภายนอกอาคาร (Outdoor Positioning) อย่าง Global Positioning System (GPS) ยังมีข้อจำกัดในการใช้งานภายในอาคาร เนื่องจากสัญญาณ GPS จะถูกบดทอนอย่างมากเมื่อผ่านโครงสร้างต่าง ๆ เช่น ผนังหรือชั้นอาคาร (Brena et al. 2017) เพื่อแก้ไขข้อจำกัดดังกล่าว ระบบระบุตำแหน่งภายในอาคาร (Indoor Positioning Systems: IPS) จึงถูกพัฒนาขึ้น โดยมีเป้าหมายเพื่อระบุตำแหน่งของวัตถุหรือผู้ใช้งานในพื้นที่ที่ GPS ไม่สามารถเข้าถึงได้ ระบบ IPS ใช้เทคโนโลยีหลากหลาย เช่น WiFi, Bluetooth Low Energy (BLE), Ultra-Wideband (UWB), RFID และเซ็นเซอร์ต่าง ๆ เพื่อประมวลผลและคาดการณ์ตำแหน่งที่แม่นยำ (Mendoza-Silva, Torres-Sospedra, and Huerta 2019)

ในยุคของ Smart Campus, Smart City และ Internet of Things (IoT) ความต้องการระบบ IPS ที่มีความแม่นยำสูง ต้นทุนต่ำ และสามารถนำไปประยุกต์ใช้ได้หลากหลายรูปแบบเพิ่มขึ้นอย่างต่อเนื่อง ตัวอย่างเช่น ระบบนำทางในมหาวิทยาลัย โรงพยาบาล ห้างสรรพสินค้า และสนามบิน ล้วนต้องการโซลูชันการระบุตำแหน่งที่สามารถทำงานได้แบบเรียลไทม์ นอกจากนี้ ระบบ IPS ยังมีบทบาทสำคัญในด้านความปลอดภัย เช่น การอพยพฉุกเฉิน การติดตามผู้สูงอายุ และการบริหารทรัพยากรในอาคารขนาดใหญ่ (Sartayeva et al. 2023)

ข้อจำกัดของ GPS ภายในอาคาร

ระบบระบุตำแหน่งบนพื้นโลก (Global Positioning System: GPS) ได้กลายเป็นเทคโนโลยีหลักที่ใช้ในการระบุตำแหน่งในชีวิตประจำวัน ไม่ว่าจะเป็นการนำทาง การติดตามพัสดุ หรือการบริหารจัดการยานพาหนะ อย่างไรก็ตาม GPS ถูกออกแบบมาสำหรับการทำงานภายนอกอาคาร (Outdoor environments)

และประสิทธิภาพของมันลดลงอย่างมากเมื่อถูกนำไปใช้งานภายในอาคารหรือพื้นที่ที่มีสิ่งกีดขวางจำนวนมาก (Navigine n.d.; Veeranath et al. 2013) หนึ่งในข้อจำกัดสำคัญของ GPS ภายในอาคาร คือ การลดทอนของสัญญาณ (Signal Attenuation) เนื่องจากผนัง คอนกรีต โลหะ และวัสดุอื่น ๆ สามารถดูดซับหรือสะท้อนสัญญาณ GPS ทำให้สัญญาณอ่อนลงหรือหายไป นอกจากนี้ ผลกระทบจากการสะท้อนสัญญาณ (Multipath Effect) ซึ่งเกิดจากสัญญาณ GPS เดินทางผ่านหลายเส้นทางก่อนถึงตัวรับสัญญาณ ก็ทำให้ค่าตำแหน่งที่ได้เกิดความคลาดเคลื่อนสูง (Veeranath et al. 2013) อีกทั้งการสูญเสียเสถียรภาพของสัญญาณ (Signal Instability) ภายในอาคาร เช่น สัญญาณขาดหายเป็นช่วง ๆ หรือค่าความหน่วง (Latency) ที่สูงขึ้น ยังส่งผลให้การนำทางภายในอาคารโดยใช้ GPS มีความผิดพลาดและไม่สามารถใช้งานได้อย่างน่าเชื่อถือ (Navigine n.d.) ดังนั้น ความต้องการระบบระบุตำแหน่งทางเลือกที่สามารถทำงานได้ในสภาพแวดล้อมภายในอาคาร เช่น ระบบ WiFi Fingerprinting, Bluetooth Low Energy (BLE), หรือ Ultra-Wideband (UWB) จึงมีความสำคัญเพิ่มมากขึ้นในการตอบสนองการใช้งานที่ต้องการความแม่นยำในพื้นที่จำกัด (Hoang 2020; Larsson 2015; Zhai et al. 2022)

ด้วยข้อจำกัดที่กล่าวมา การพัฒนาระบบระบุตำแหน่งภายในอาคารที่มีความแม่นยำสูงกว่าจึงเป็นหัวใจสำคัญของงานวิจัยในปัจจุบัน เพื่อเสริมสร้างการนำทางแบบเรียลไทม์ การบริหารทรัพยากร และการเสริมประสบการณ์ของผู้ใช้งานในสภาพแวดล้อมภายในอาคารอย่างมีประสิทธิภาพ (Hoang 2020; Zhai et al. 2022) รวมทั้งการวิจัยและพัฒนาระบบ Indoor Positioning จึงมีความสำคัญอย่างยิ่งในการสนับสนุนการขับเคลื่อนนวัตกรรมใหม่ ๆ และสร้างความสามารถในการแข่งขันในยุคเศรษฐกิจดิจิทัล (Mahdi, Chalechale, and AbdelRaouf 2022)

ปัญหาที่ต้องการแก้ไข และช่องว่างการวิจัย

แม้ว่าระบบระบุตำแหน่งภายในอาคาร (Indoor Positioning Systems: IPS) จะได้รับการพัฒนาอย่างต่อเนื่องในช่วงหลายทศวรรษที่ผ่านมา แต่ปัญหาเกี่ยวกับความแม่นยำ ความเสถียร และความสามารถในการประยุกต์ใช้ในสภาพแวดล้อมจริงยังคงเป็นข้อจำกัดสำคัญที่ต้องการการแก้ไข โดยเทคโนโลยีอย่าง WiFi Fingerprinting, RFID, BLE และ UWB แม้จะตอบสนองความต้องการบางประการได้ แต่ยังพบข้อจำกัดด้านความผันผวนของสัญญาณ (Signal fluctuation) และปัญหา Multipath effect ในอาคารที่มีสิ่งกีดขวางจำนวนมาก (Gadkari et al. 2016; Toshita et al. 2025) สำหรับเทคนิค WiFi Fingerprinting ซึ่งได้รับความนิยมเพราะต้นทุนต่ำและใช้โครงสร้างพื้นฐานที่มีอยู่แล้วนั้น ยังคงประสบปัญหาความเสถียรของค่า Received Signal Strength Indicator (RSSI) ที่อาจเปลี่ยนแปลงได้ตามสภาพแวดล้อม เช่น การเคลื่อนที่ของผู้คนหรือการเปลี่ยนแปลงโครงสร้างภายในอาคาร อีกทั้งฐานข้อมูล Fingerprint ต้องได้รับการอัปเดตอย่างต่อเนื่องเพื่อรักษาความแม่นยำ ซึ่งเป็นภาระสำคัญในกระบวนการบำรุงรักษาระบบ (Gadkari et al. 2016) ในด้านอัลกอริทึม แม้จะมีการประยุกต์ใช้ Machine Learning เช่น K-Nearest Neighbors (KNN),

Support Vector Machines (SVM) และ Deep Learning เพื่อแก้ปัญหาการคาดการณ์ตำแหน่ง แต่การเลือกอัลกอริทึมที่เหมาะสมที่สุดในสภาพแวดล้อมที่มีการเปลี่ยนแปลงสูง เช่น มหาวิทยาลัยหรืออาคารสาธารณะ ยังเป็นหัวข้อที่ต้องการการศึกษาต่อไป อีกทั้งยังขาดมาตรฐานกลางในการประเมินประสิทธิภาพของระบบ (Gadkari et al. 2016; Toshita et al. 2025)

ช่องว่างการวิจัยสำคัญอีกประการหนึ่งคือ การบูรณาการระบบระบุตำแหน่งกับแพลตฟอร์มแผนที่โอเพ่นซอร์ส เช่น OpenStreetMap (OSM) เพื่อแสดงผลการนำทางแบบเรียลไทม์ในอาคาร ซึ่งในปัจจุบันยังอยู่ในช่วงเริ่มต้นและจำเป็นต้องมีการพัฒนาเทคนิค Indoor Mapping ที่เหมาะสมมากขึ้น (Toshita et al. 2025) ดังนั้น งานวิจัยในปัจจุบันจึงมุ่งเน้นไปที่การแก้ไขปัญหาความแม่นยำ ความเสถียร และการนำทางแบบเรียลไทม์ของระบบ IPS โดยใช้ WiFi Fingerprinting ร่วมกับ KNN และผสานเทคโนโลยี OpenStreetMap เพื่อยกระดับประสบการณ์การใช้งานในสภาพแวดล้อมจริง เช่น มหาวิทยาลัย (Toshita et al. 2025)

วัตถุประสงค์การวิจัย

การวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาและประเมินประสิทธิภาพของระบบระบุตำแหน่งภายในอาคารในมหาวิทยาลัย โดยใช้เทคนิค WiFi Fingerprinting ร่วมกับอัลกอริทึม Machine Learning ประเภท K-Nearest Neighbors (KNN) เพื่อเพิ่มความแม่นยำในการระบุตำแหน่งของผู้ใช้งาน และแสดงผลการนำทางแบบเรียลไทม์ผ่านแพลตฟอร์ม OpenStreetMap (OSM) ทั้งนี้ วัตถุประสงค์เชิงเฉพาะของการวิจัยประกอบด้วย

1. เพื่อพัฒนาโมเดลการระบุตำแหน่งภายในอาคาร โดยอาศัยเทคนิค WiFi Fingerprinting และอัลกอริทึม K-Nearest Neighbors (KNN) ในการประมวลผลข้อมูลสัญญาณ WiFi และประมาณค่าตำแหน่งของผู้ใช้งาน
2. เพื่อสร้างฐานข้อมูล Fingerprint Database สำหรับพื้นที่ภายในมหาวิทยาลัย โดยเก็บข้อมูลความแรงของสัญญาณ (RSSI) จาก Access Points (APs) ในจุดอ้างอิง (Reference Points: RPs) เพื่อใช้เป็นข้อมูลอ้างอิงในการคำนวณตำแหน่ง
3. เพื่อประเมินประสิทธิภาพของโมเดลการระบุตำแหน่ง โดยใช้ตัวชี้วัด เช่น ความแม่นยำ (Accuracy), ค่าความคลาดเคลื่อนเฉลี่ย (Mean Error Distance)
4. เพื่อพัฒนาและแสดงผลระบบนำทางแบบเรียลไทม์บน OpenStreetMap (OSM) โดยแสดงตำแหน่งปัจจุบันและเส้นทางที่ดีที่สุดจากตำแหน่งปัจจุบันไปยังจุดหมายภายในอาคารทดสอบ

การทบทวนวรรณกรรม

เทคโนโลยีการระบุตำแหน่ง RFID, BLE, UWB, WiFi

การพัฒนาระบบระบุตำแหน่งภายในอาคารในปัจจุบัน ได้แก่ RFID, BLE, UWB และ WiFi ซึ่งแต่ละเทคโนโลยีมีคุณลักษณะเฉพาะตัวที่เหมาะสมกับบริบทการใช้งานที่แตกต่างกัน (Brena et al. 2017; J et al. 2022)

Radio Frequency Identification (RFID) เป็นเทคโนโลยีที่ใช้สัญญาณความถี่วิทยุเพื่อระบุตัวตนของวัตถุหรือบุคคลผ่านการอ่านป้าย (tags) ที่ติดตั้งอยู่บนวัตถุนั้น RFID มีข้อดีคือมีต้นทุนต่ำและประหยัดพลังงาน แต่ข้อจำกัดสำคัญคือระยะทำการสั้นและความแม่นยำต่ำเมื่อเทียบกับเทคโนโลยีอื่น (Brena et al. 2017)

Bluetooth Low Energy (BLE) เป็นเทคโนโลยีการสื่อสารไร้สายที่ใช้พลังงานต่ำ เหมาะสำหรับติดตามตำแหน่งผ่านบีคอน (beacons) ที่กระจายอยู่ภายในพื้นที่ BLE มีข้อได้เปรียบในเรื่องต้นทุนต่ำ การติดตั้งง่าย และการสนับสนุนจากอุปกรณ์พกพาส่วนใหญ่ แต่ความแม่นยำอาจลดลงในสภาพแวดล้อมที่มีสิ่งกีดขวางมาก (J et al. 2022)

Ultra-Wideband (UWB) เป็นเทคโนโลยีที่ใช้สัญญาณกว้างพิเศษในการส่งข้อมูล ทำให้สามารถระบุตำแหน่งได้อย่างแม่นยำในระดับเซนติเมตร และมีความทนทานต่อการรบกวนของสัญญาณ อย่างไรก็ตาม ต้นทุนของอุปกรณ์ UWB ยังสูงกว่าระบบอื่น และจำเป็นต้องมีการติดตั้งโครงสร้างพื้นฐานเพิ่มเติม (J et al. 2022)

WiFi-based Positioning Systems (WPS) ใช้สัญญาณ WiFi ที่มีอยู่แล้วในอาคารในการระบุตำแหน่งของผู้ใช้งาน ผ่านวิธีการเช่น WiFi Fingerprinting หรือ Trilateration WiFi เป็นทางเลือกยอดนิยมเนื่องจากไม่ต้องติดตั้งอุปกรณ์เพิ่มเติม และสามารถครอบคลุมพื้นที่กว้างได้ดี แต่ข้อจำกัดคือความแม่นยำอาจต่ำกว่าระบบที่ออกแบบมาเฉพาะสำหรับการระบุตำแหน่ง (Brena et al. 2017; J et al. 2022) การเลือกเทคโนโลยีระบุตำแหน่งที่เหมาะสมจำเป็นต้องพิจารณาปัจจัยหลายประการ เช่น ความแม่นยำที่ต้องการ ต้นทุนการติดตั้ง ความสะดวกในการบำรุงรักษา และลักษณะของสภาพแวดล้อมเป้าหมาย เพื่อให้ได้ระบบที่มีประสิทธิภาพสูงสุดตามวัตถุประสงค์ของการใช้งานนั้น ๆ (J et al. 2022)

การประยุกต์ใช้ WiFi Fingerprinting และ Machine Learning (KNN)

การพัฒนาระบบระบุตำแหน่งภายในอาคาร (Indoor Positioning System: IPS) จำเป็นต้องเลือกเทคโนโลยีและวิธีการที่เหมาะสมที่สุด เพื่อให้สามารถระบุตำแหน่งได้อย่างแม่นยำ ครอบคลุม และมีต้นทุนที่คุ้มค่า ในกลุ่มเทคโนโลยีที่มีอยู่ การใช้สัญญาณ WiFi เป็นหนึ่งในแนวทางที่ได้รับความนิยมสูง เนื่องจากเครือข่าย WiFi มีการติดตั้งอย่างแพร่หลายในอาคารต่าง ๆ เช่น มหาวิทยาลัย โรงพยาบาล และสนามบิน จึงสามารถนำมาใช้โดยไม่ต้องลงทุนติดตั้งโครงสร้างพื้นฐานเพิ่มเติม (Shang and Wang 2022) เทคนิค WiFi

Fingerprinting อาศัยการเก็บข้อมูลค่าความแรงของสัญญาณ (RSSI) จาก Access Points (APs) ที่มีอยู่ในอาคาร ณ จุดต่าง ๆ แล้วนำข้อมูลนี้มาสร้างเป็นฐานข้อมูล (Fingerprint Database) เพื่อใช้ในการเปรียบเทียบกับค่าที่วัดได้จริงในภายหลัง ช่วยให้การประมาณตำแหน่งของผู้ใช้มีความแม่นยำในระดับที่เพียงพอสำหรับการใช้งานทั่วไป เมื่อเปรียบเทียบกับวิธีการแบบ Trilateration หรือ Angle of Arrival (AoA) แล้ว WiFi Fingerprinting มีความทนทานต่อความผิดพลาดที่เกิดจากการสะท้อนและลดทอนของสัญญาณได้ดีกว่า (Naderi Salim et al. 2023; Shang and Wang 2022)

ในด้านอัลกอริทึมสำหรับการประมาณตำแหน่ง Machine Learning มีบทบาทสำคัญในการวิเคราะห์ข้อมูล RSSI และทำนายตำแหน่งได้อย่างมีประสิทธิภาพ โดยเฉพาะเทคนิค K-Nearest Neighbors (KNN) ซึ่งเป็นวิธีการพื้นฐานที่ใช้งานง่าย มีประสิทธิภาพ และให้ผลลัพธ์ที่น่าเชื่อถือในการคำนวณตำแหน่ง KNN ทำงานโดยการค้นหาตำแหน่งในฐานข้อมูลที่มีรูปแบบของค่า RSSI ใกล้เคียงกับข้อมูลที่วัดได้จริงมากที่สุด แล้วใช้การคำนวณระยะห่าง (เช่น Euclidean Distance) เพื่อประมาณพิกัดของผู้ใช้งาน (Naderi Salim et al. 2023) นอกจากนี้ KNN ยังมีข้อได้เปรียบคือไม่จำเป็นต้องมีการฝึกโมเดลที่ซับซ้อน (Non-parametric Method) ทำให้สามารถปรับปรุงหรือขยายฐานข้อมูล Fingerprint ได้อย่างยืดหยุ่นโดยไม่ต้องทำการฝึกโมเดลใหม่ตั้งแต่ต้น จึงเหมาะสมอย่างยิ่งกับระบบนำทางภายในอาคาร เช่น ในมหาวิทยาลัย ที่มีสภาพแวดล้อมเปลี่ยนแปลงบ่อยและต้องการการปรับปรุงระบบอย่างต่อเนื่อง (Shang and Wang 2022; Naderi Salim et al. 2023)

ด้วยเหตุผลดังกล่าว การเลือกใช้ WiFi Fingerprinting ร่วมกับ KNN จึงเป็นแนวทางที่สมเหตุสมผลในการพัฒนาระบบนำทางภายในมหาวิทยาลัยที่สามารถทำงานได้แบบเรียลไทม์ มีความแม่นยำที่ยอมรับได้ และมีต้นทุนในการติดตั้งและบำรุงรักษาที่ต่ำ (Shang and Wang 2022; Naderi Salim et al. 2023)

การทบทวนวรรณกรรม: WiFi Fingerprinting สำหรับ Indoor Positioning

ความสำคัญและหลักการของ WiFi Fingerprinting

WiFi Fingerprinting เป็นเทคนิคที่ได้รับความนิยมอย่างแพร่หลายในการระบุตำแหน่งภายในอาคาร เนื่องจากสามารถใช้โครงสร้างพื้นฐานของเครือข่าย WiFi ที่มีอยู่แล้ว โดยไม่จำเป็นต้องติดตั้งอุปกรณ์เพิ่มเติม หลักการทำงานประกอบด้วยสองขั้นตอนหลัก ได้แก่

ขั้นตอนการเก็บข้อมูล (Offline Phase): ทำการรวบรวมค่าความแรงของสัญญาณ (RSSI) จาก Access Points (APs) ณ จุดอ้างอิงต่าง ๆ ภายในพื้นที่เป้าหมาย เพื่อสร้างฐานข้อมูลของลายนิ้วมือสัญญาณ (Fingerprint Database)

ขั้นตอนการระบุตำแหน่ง (Online Phase): เมื่อผู้ใช้งานต้องการทราบตำแหน่งปัจจุบัน ระบบจะเปรียบเทียบค่าความแรงของสัญญาณที่วัดได้กับข้อมูลในฐานข้อมูล เพื่อประมาณตำแหน่งที่ใกล้เคียงที่สุด

เทคนิคนี้มีข้อดี คือ ความง่ายในการนำไปใช้และต้นทุนต่ำ แต่ก็มีข้อจำกัด เช่น ความผันผวนของสัญญาณและความจำเป็นในการอัปเดตฐานข้อมูลอย่างสม่ำเสมอ (Xia et al. 2017)

ฐานข้อมูลและชุดข้อมูลสำหรับการสร้าง WiFi Fingerprinting

การมีชุดข้อมูลที่มีคุณภาพเป็นสิ่งสำคัญสำหรับการพัฒนาและประเมินผลระบบ WiFi Fingerprinting งานวิจัยโดย Feng et al. (2024) ได้ทำการรวบรวมชุดข้อมูลสาธารณะมากกว่า 50 ชุด ซึ่งมีความหลากหลายในด้านขนาด พื้นที่ที่ใช้ทดสอบ และรูปแบบของข้อมูล อย่างไรก็ตาม ยังขาดมาตรฐานกลางในการจัดเก็บและเผยแพร่ข้อมูลเหล่านี้

การเปรียบเทียบการประยุกต์ใช้ KNN, Random Forest และ Neural Networks ในระบบระบุตำแหน่งภายในอาคาร

K-Nearest Neighbors (KNN) เป็นอัลกอริธึมที่ได้รับความนิยมในการระบุตำแหน่งภายในอาคาร เนื่องจากความเรียบง่ายและประสิทธิภาพที่ดี โดยทำงานโดยการเปรียบเทียบค่าความแรงของสัญญาณ (RSSI) ที่วัดได้กับฐานข้อมูลที่มีอยู่ และเลือกตำแหน่งที่มีความใกล้เคียงที่สุด อย่างไรก็ตาม KNN มีข้อจำกัดในด้านความไวต่อสัญญาณรบกวนและความผันผวนของสัญญาณ ซึ่งอาจส่งผลต่อความแม่นยำในการระบุตำแหน่ง (Dai et al. 2019)

Random Forest (RF) Random Forest เป็นอัลกอริธึมที่ใช้การรวมผลของต้นไม้ตัดสินใจหลายต้น เพื่อเพิ่มความแม่นยำในการทำนาย โดยมีความสามารถในการจัดการกับข้อมูลที่มีมิติสูงและลดปัญหาการฝึกมากเกินไป (Overfitting) ในบริบทของการระบุตำแหน่งภายในอาคาร RF สามารถจัดการกับความผันผวนของสัญญาณ WiFi ได้ดี และให้ผลลัพธ์ที่แม่นยำมากขึ้นเมื่อเทียบกับ KNN (Dai et al. 2019)

Neural Networks (NN) โดยเฉพาะอย่างยิ่ง Deep Neural Networks (DNN) และ Convolutional Neural Networks (CNN) ได้รับการนำมาใช้ในการระบุตำแหน่งภายในอาคารเพื่อเพิ่มความแม่นยำและความสามารถในการเรียนรู้รูปแบบที่ซับซ้อนของสัญญาณ งานวิจัยหนึ่งเสนอการใช้ DNN เพื่อเรียนรู้การกระจายของตัวอย่าง RSSI ที่มีอยู่แทนการเฉลี่ย ซึ่งช่วยเพิ่มความเร็วและความแม่นยำในการระบุตำแหน่งแบบเรียลไทม์ อีกงานวิจัยหนึ่งเสนอระบบ WiFiNet ที่ใช้ CNN ในการประมวลผลข้อมูล RSSI เพื่อปรับปรุงความแม่นยำในการระบุตำแหน่งภายในอาคาร (Dai et al. 2019)

การใช้ OpenStreetMap (OSM) และอัลกอริทึมการวางแผนเส้นทางในระบบนำทางภายในอาคาร

OpenStreetMap (OSM) เป็นแหล่งข้อมูลภูมิสารสนเทศที่ได้รับความนิยมในการพัฒนาแผนที่ภายในอาคาร เนื่องจากมีโครงสร้างข้อมูลที่ยืดหยุ่นและสามารถปรับปรุงได้โดยชุมชนผู้ใช้ งานวิจัยโดย Wang และ Niu (2018) ได้เสนอโมเดลข้อมูลที่ใช้โครงสร้างพื้นฐานของ OSM เช่น nodes, ways และ relations เพื่อ

สร้างกราฟการนำทางภายในอาคาร โดยสามารถรวมการนำทางภายในและภายนอกอาคารเข้าด้วยกันได้อย่างมีประสิทธิภาพ (Wang and Niu 2018)

อัลกอริทึมการวางแผนเส้นทาง: A* และ Dijkstra

อัลกอริทึม A* และ Dijkstra เป็นเทคนิคที่ได้รับความนิยมในการคำนวณเส้นทางที่สั้นที่สุดในกราฟการนำทางภายในอาคาร งานวิจัยโดย García-Catalá et al. (2024) ได้พัฒนาแอปพลิเคชันนำทางภายในอาคารสำหรับผู้ที่มีความบกพร่องทางสติปัญญา โดยใช้ข้อมูลจาก OSM ร่วมกับอัลกอริทึม Dijkstra เพื่อคำนวณเส้นทางที่เหมาะสมภายในอาคาร (García-Catalá et al. 2024)

การสร้างกราฟการนำทางจากข้อมูล OSM

การสร้างกราฟการนำทางจากข้อมูล OSM จำเป็นต้องมีการประมวลผลข้อมูลเพื่อแปลงโครงสร้างของอาคารให้เป็นกราฟที่สามารถใช้งานได้ งานวิจัยโดย Wang และ Niu (2018) ได้เสนอขั้นตอนการสร้างกราฟการนำทาง 3 มิติจากข้อมูล OSM โดยพิจารณาการเชื่อมต่อระหว่างชั้นต่าง ๆ ของอาคาร เช่น บันไดและลิฟต์ เพื่อให้การนำทางภายในอาคารมีความแม่นยำและสอดคล้องกับโครงสร้างจริง (Wang and Niu 2018)

การนำทางแบบเรียลไทม์

การนำทางภายในอาคารจำเป็นต้องมีความสามารถในการปรับตัวตามผู้ใช้และสถานการณ์ต่าง ๆ งานวิจัยโดย García-Catalá et al. (2024) ได้พัฒนาแอปพลิเคชันที่สามารถให้คำแนะนำการนำทางแบบเรียลไทม์ โดยพิจารณาความต้องการเฉพาะของผู้ใช้ เช่น ผู้ที่มีความบกพร่องทางสติปัญญา เพื่อให้การนำทางภายในอาคารเป็นไปอย่างมีประสิทธิภาพและปลอดภัย (García-Catalá et al. 2024)

การเปรียบเทียบเทคนิคการระบุตำแหน่งภายในอาคารและข้อจำกัดที่ยังไม่ได้รับการแก้ไข

เทคนิคการระบุตำแหน่งภายในอาคารมีความหลากหลาย โดยสามารถแบ่งออกเป็นหลายประเภทตามลักษณะของสัญญาณและวิธีการประมวลผล เช่น

เทคนิคที่ใช้สัญญาณวิทยุ (Radio Frequency-Based): เช่น Wi-Fi, Bluetooth Low Energy (BLE), Ultra-Wideband (UWB), และ ZigBee (Obeidat et al. 2021)


เทคนิคที่ใช้สัญญาณแสง (Optical-Based): เช่น Visible Light Communication (VLC) และ Infrared

เทคนิคที่ใช้เซนเซอร์เฉื่อย (Inertial-Based): เช่น Inertial Measurement Units (IMUs)

เทคนิคที่ใช้การประมวลผลภาพ (Vision-Based): เช่น กล้องและการประมวลผลภาพ

งานวิจัยโดย Obeidat et al. (2021) ได้ทำการเปรียบเทียบเทคนิคต่าง ๆ เหล่านี้ในแง่ของความแม่นยำ ค่าใช้จ่าย ข้อดี และข้อจำกัด โดยพบว่าแต่ละเทคนิคมีข้อดีและข้อจำกัดที่แตกต่างกันไป และการเลือกใช้เทคนิคใดขึ้นอยู่กับบริบทของการใช้งาน (Obeidat et al. 2021)

วิธีดำเนินการวิจัย



ภาพที่ 1 สถาปัตยกรรมของระบบ

ระบบสถาปัตยกรรมของระบบ (System Architecture)

ระบบที่พัฒนาขึ้นในงานวิจัยนี้ออกแบบมาเพื่อรองรับการระบุตำแหน่งภายในอาคารและการนำทางแบบเรียลไทม์ โดยอาศัยเทคนิค WiFi Fingerprinting ร่วมกับอัลกอริทึม K-Nearest Neighbors (KNN)

สำหรับการประมาณตำแหน่ง และการใช้ OpenStreetMap (OSM) สำหรับการแสดงผลเส้นทางในรูปแบบ Web Application ซึ่งระบบถูกแบ่งออกเป็น 3 ชั้นหลัก (Three-tier Architecture) ได้แก่ Frontend Layer, Backend Layer และ Data Layer ดังแสดงในภาพที่ 1 สถาปัตยกรรมของระบบ

Frontend Layer : ในระดับชั้นผู้ใช้งาน (Frontend) อุปกรณ์ของผู้ใช้งาน เช่น สมาร์ทโฟนหรือโน้ตบุ๊ก จะทำการสแกนและวัดค่าความแรงของสัญญาณ (Received Signal Strength Indicator: RSSI) จาก Access Points (APs) ที่อยู่โดยรอบภายในพื้นที่ของอาคาร ค่าที่ได้จะถูกจัดรูปแบบและส่งไปยังเซิร์ฟเวอร์ผ่าน RESTful API ที่สร้างขึ้นด้วย Flask Framework

Backend Layer : เซิร์ฟเวอร์ฝั่ง Backend จะทำการรับค่าข้อมูล RSSI และส่งผ่านเข้าสู่กระบวนการประมาณตำแหน่งด้วยอัลกอริทึม KNN โดยระบบจะทำการเปรียบเทียบเวกเตอร์ RSSI กับฐานข้อมูล Fingerprint ที่จัดเก็บไว้ล่วงหน้า เพื่อหาค่าพิกัดตำแหน่งของผู้ใช้งานในรูปแบบ (X, Y) จากนั้นระบบจะทำการวางแผนเส้นทางจากตำแหน่งปัจจุบันไปยังจุดหมายที่ผู้ใช้กำหนด โดยใช้ A* Pathfinding Algorithm ซึ่งเป็นอัลกอริทึมเชิงกราฟที่มีประสิทธิภาพสูงสำหรับการค้นหาเส้นทางที่เหมาะสมที่สุด และนำผลลัพธ์ไปเชื่อมต่อกับแผนที่โอเพ่นสตรีต OpenStreetMap (OSM) เพื่อเตรียมข้อมูลสำหรับการแสดงผล

Data Layer : ฐานข้อมูลลายนิ้วมือ WiFi (Fingerprint Database) ถูกจัดเก็บในรูปแบบ CSV หรือฐานข้อมูลเชิงสัมพันธ์ (SQL) โดยประกอบด้วยข้อมูลพิกัดตำแหน่ง (X, Y) และค่าความแรงของสัญญาณจากแต่ละ AP ณ จุดอ้างอิง (Reference Point: RP) ต่าง ๆ ภายในอาคาร โดยฐานข้อมูลนี้เป็นข้อมูลหลักสำหรับการใช้ในการเปรียบเทียบกับข้อมูลใหม่ที่ส่งมาจากผู้ใช้งานในแต่ละครั้ง เพื่อให้ได้ตำแหน่งที่แม่นยำสูง

Real-time Visualization : ตำแหน่งและเส้นทางที่คำนวณได้จะถูกแสดงผลผ่าน Web Application โดยมีการอัปเดตตำแหน่งของผู้ใช้งานแบบเรียลไทม์ด้วยเทคโนโลยี WebSocket ซึ่งทำให้สามารถติดตามตำแหน่งของผู้ใช้งานในระหว่างการเคลื่อนที่ได้อย่างต่อเนื่องและแม่นยำ อีกทั้งยังรองรับการปรับปรุงแผนที่หรือการเปลี่ยนแปลงสภาพแวดล้อมได้อย่างยืดหยุ่น

WiFi Fingerprinting และฐานข้อมูลลายนิ้วมือ (Fingerprint Database)

แนวทาง WiFi Fingerprinting อาศัยการวัดค่าความแรงของสัญญาณ (RSSI) จาก Access Points (APs) ภายในอาคาร เพื่อสร้างชุดข้อมูลอ้างอิง (Fingerprint Database) โดยข้อมูลที่เก็บไว้จะอยู่ในรูปเวกเตอร์ของ RSSI ตามพิกัดตำแหน่งจริง ดังนี้:

$$F_1 = [RSSI_i^{(1)}, RSSI_i^{(2)}, \dots, RSSI_i^{(n)}] \quad (1)$$

โดยที่:

- F_i คือ ลายนิ้วมือสัญญาณจากตำแหน่งอ้างอิงที่ i
- $RSSI_i^{(j)}$ คือ ค่าความแรงของสัญญาณจาก Access Point ลำดับที่ j ที่ตำแหน่ง i
- n คือ จำนวน Access Points

ในขั้นตอนใช้งานจริง (Online Phase) ระบบจะรับค่าข้อมูล RSSI จากอุปกรณ์ผู้ใช้งาน ซึ่งมีลักษณะเป็นเวกเตอร์ Q ดังนี้:

$$F_1 = [RSSI_i^{(1)}, RSSI_i^{(2)}, \dots, RSSI_i^{(n)}] \quad (2)$$

การประมาณตำแหน่งด้วย K-Nearest Neighbors (KNN)

ระบบจะคำนวณระยะทางระหว่างเวกเตอร์ Q กับลายนิ้วมือทั้งหมดในฐานข้อมูล โดยใช้ระยะทาง Euclidean (Youssef and Agrawala 2005) ดังนี้:

$$d(Q, F_i) = \sqrt{(RSSI^{(j)} - RSSI_i^{(j)})^2} \quad (3)$$

จากนั้นจะเลือกลายนิ้วมือ k จุด ที่มีระยะทางใกล้ที่สุด (Nearest Neighbors) และนำตำแหน่งที่เกี่ยวข้องมาคำนวณพิกัดตำแหน่งที่คาดการณ์ได้ของผู้ใช้งาน โดยใช้การถ่วงน้ำหนักระยะทาง (Youssef and Agrawala 2005):

$$\hat{P} = \frac{\sum_{i=1}^K \frac{1}{d_i} \cdot P_i}{\sum_{i=1}^K \frac{1}{d_i}} \quad (4)$$

โดยที่:

- d_i คือระยะทางจากผู้ใช้งานไปยังลายนิ้วมือที่ i
- P_i คือพิกัดตำแหน่ง (X, Y) ของลายนิ้วมือที่ i
- $\hat{P}$ คือค่าพิกัดตำแหน่งที่ประมาณได้ของผู้ใช้งาน

ค่าพารามิเตอร์ k มีผลโดยตรงต่อความแม่นยำของตำแหน่ง หากเลือกค่าน้อยเกินไปจะไวต่อ noise มากเกินไป แต่หากมากเกินไปจะทำให้ความแม่นยำลดลงเพราะข้อมูลไม่จำเพาะเจาะจง

การคำนวณเส้นทางด้วย A Algorithm*

เมื่อทราบตำแหน่งของผู้ใช้งานและจุดหมายปลายทางแล้ว ระบบจะใช้ A Pathfinding Algorithm* เพื่อค้นหาเส้นทางที่สั้นที่สุดบนกราฟที่สร้างจากข้อมูลของ OpenStreetMap (OSM) (2023)

A* จะคำนวณฟังก์ชันค่าใช้จ่ายรวม $f(n)$ สำหรับแต่ละโหนด n ดังนี้:

$$f(n) = g(n) + h(n) \quad (5)$$

โดยที่:


- $g(n)$ คือค่าระยะทางสะสมจากจุดเริ่มต้นไปยังโหนด n
- $h(n)$ คือค่าประมาณ (heuristic) ของระยะทางที่เหลือจากโหนด n ไปยังจุดหมายปลายทาง โดยทั่วไปใช้ระยะทาง Euclidean หรือ Manhattan:

$$h(n) = \sqrt{(x_n - x_{goal})^2 + (y_n - y_{goal})^2} \quad (6)$$

A* จะเลือกขยายโหนดที่มีค่ารวม $f(n)$ ต่ำที่สุดในแต่ละรอบการค้นหา เพื่อหาลำดับเส้นทางที่มีระยะทางรวมน้อยที่สุด

การแสดงผลแบบ Real-time


ระบบจะส่งข้อมูลตำแหน่งผู้ใช้งานและเส้นทางที่คำนวณได้ไปยัง Web Application เพื่อแสดงผล โดยใช้ WebSocket สำหรับการอัปเดตข้อมูลแบบเรียลไทม์ ซึ่งช่วยให้ผู้ใช้งานสามารถติดตามตำแหน่งและเส้นทางได้อย่างต่อเนื่องโดยไม่ต้องรีเฟรชหน้าเว็บไซต์ กระบวนการกระบวนการทำงานของระบบนำทางภายในอาคาร แสดงในภาพที่ 2 กระบวนการทำงานของระบบนำทางภายในอาคาร




ภาพที่ 2 กระบวนการทำงานของระบบนำทางภายในอาคาร

ชุดข้อมูล RSSI จำลองสำหรับการวิจัยระบบนำทางภายในอาคาร

สำหรับการทดลองในงานวิจัยนี้ ได้ใช้ชุดข้อมูล RSSI ซึ่งประกอบด้วยข้อมูลจากจุดตัวอย่างทั้งหมด 189 จุดภายในอาคาร โดยเก็บค่าความแรงของสัญญาณ (Received Signal Strength Indicator: RSSI) จาก Access Points (APs) จำนวนกว่า 130 จุด ครอบคลุมหลายชั้นของอาคาร (floor 1 ถึง floor 9) และหลากหลายตำแหน่งในแนวระนาบ (ค่าพิกัด x และ y ระหว่าง 250–765 และ 90–1380 ตามลำดับ) ข้อมูล RSSI มีค่าตั้งแต่ประมาณ -100 dBm จนถึง -25 dBm โดยมีการจำลอง noise และ multipath effect อย่างสมจริง ซึ่งสะท้อนถึงความแปรปรวนของสัญญาณที่พบในสภาพแวดล้อมภายในอาคารจริง ชุดข้อมูลนี้ยังรวมถึงคอลลัมน์พิกัดตำแหน่งจริง (X, Y) และหมวดหมู่ตำแหน่ง (เช่น Room101, Elevator, Stairs) ซึ่งสามารถนำไปใช้ประเมินประสิทธิภาพของอัลกอริทึมการระบุตำแหน่ง เช่น K-Nearest Neighbors (KNN) ได้อย่างมีประสิทธิภาพ ความหลากหลายของตำแหน่งและคุณลักษณะของสัญญาณในชุดข้อมูลนี้ทำให้เหมาะสมสำหรับการวิจัยระบบนำทางภายในอาคารที่ต้องการความแม่นยำและความทนต่อ noise สูง ดังแสดง ภาพที่ 3 กราฟแสดงจุดที่เก็บ RSSI 2 มิติ และภาพที่ 4 กราฟแสดงจุดที่เก็บ RSSI 3 มิติ



ภาพที่ 3 กราฟแสดงจุดที่เก็บ RSSI 2 มิติ



ภาพที่ 4 กราฟแสดงจุดที่เก็บ RSSI 3 มิติ

การสร้างชุดข้อมูลและขั้นตอนการรวบรวมข้อมูล (Dataset Construction and Data Collection)

เพื่อให้การประเมินระบบระบุตำแหน่งภายในอาคารมีความน่าเชื่อถือและสามารถสะท้อนสภาพแวดล้อมจริงได้อย่างเหมาะสม งานวิจัยนี้ได้ทำการออกแบบและสร้างชุดข้อมูล RSSI แบบจำลองจากพื้นที่ภายในอาคารจำลองจำนวน 9 ชั้น โดยมีจำนวนตำแหน่งอ้างอิง (Reference Points: RPs) ทั้งหมด 500 ตำแหน่ง กระบวนการกำหนดขนาดตัวอย่างใช้สูตร Finite Population Correction (FPC) เพื่อให้ได้ขนาดตัวอย่างที่เหมาะสมกับประชากรจำกัด โดยใช้พารามิเตอร์ $N=500$, $e=0.05$, และ $Z=1.96$ (ระดับความเชื่อมั่น 95%) ทำให้ได้จำนวนตำแหน่งตัวอย่างที่ใช้ในการวัดเท่ากับ $n=218$ ตำแหน่ง

การสุ่มตัวอย่างดำเนินการโดยใช้วิธี Stratified Sampling ซึ่งแบ่งพื้นที่ตาม “ชั้นของอาคาร” และ “ประเภทพื้นที่” (เช่น ห้องเรียน, โถงทางเดิน) เพื่อให้ได้ชุดข้อมูลที่ครอบคลุมลักษณะทางกายภาพที่หลากหลาย ทั้งนี้เพื่อรองรับความผันแปรของสัญญาณในสภาพแวดล้อมต่าง ๆ

สำหรับขั้นตอนการจำลองข้อมูล ได้ทำการสร้างตำแหน่ง Access Point (AP) ทั้งหมด 15 จุด และตำแหน่งอ้างอิง (RP) ชั้นละ 19 จุด โดยกระจายอย่างสม่ำเสมอภายในพื้นที่แต่ละชั้น จากนั้นทำการคำนวณค่า RSSI ที่แต่ละ RP ด้วยแบบจำลอง Log-Distance Path Loss Model (Phunthawornwong, Pengwang, and Silapunt 2018) :

$$RSSI(d) = RSSI(d_0) - 10n \log_{10} \left(\frac{d}{d_0} \right) + X_\sigma \quad (7)$$

โดยที่:

d คือ ระยะทางจาก RP ถึง AP

n คือ path loss exponent (กำหนดเป็น 2-3)

X_σ คือ Gaussian noise มีค่าเฉลี่ย $\mu=0$ และส่วนเบี่ยงเบนมาตรฐาน $\sigma=3$ dBm

ขั้นตอนการฝึกโมเดล ใช้อัลกอริทึม K-Nearest Neighbors (KNN) โดยกำหนดพารามิเตอร์ $k=1$ ถึง $k=15$ และใช้ weights = 'distance' เพื่อถ่วงน้ำหนักตามระยะห่างของแต่ละ Neighbor โมเดลนี้ใช้พยากรณ์ พิกัดตำแหน่ง (x,y) และชั้นของอาคาร (floor)

ในขั้นตอนการทดสอบระบบ ข้อมูล RSSI ที่จำลองไว้จะถูกส่งผ่าน WebSocket ไปยัง Web Application แบบเรียลไทม์ เพื่อทดสอบการประมวลผลแบบ online และทำการคำนวณเส้นทางที่สั้นที่สุด ระหว่างตำแหน่งเริ่มต้นและจุดหมายด้วย A Pathfinding Algorithm* บนกราฟที่ได้จากข้อมูล OpenStreetMap ซึ่งถูกจัดเก็บในรูปแบบ GeoJSON (Vargas-Munoz et al. 2021)

เครื่องมือที่ใช้ในงานวิจัยและสถิติที่ใช้ในการวิเคราะห์ข้อมูล

ซอฟต์แวร์: Python (Pandas, NumPy), Scikit-learn (KNN), NetworkX (A*), Flask (API), WebSocket

ฮาร์ดแวร์: สมาร์ทโฟน Android และ WiFi Scanner (สำหรับทดสอบข้อมูลจริง)

ความเชื่อมั่นของเครื่องมือ: ทดสอบความสอดคล้องของข้อมูลด้วยค่า Cronbach's Alpha ≥ 0.85 และตรวจสอบความสามารถในการจำแนก (Discriminant Validity) โดยเปรียบเทียบค่า RSSI ระหว่างตำแหน่ง RP ต่างกัน

Mean Error Distance (MED): วัดความคลาดเคลื่อนของตำแหน่งระหว่างค่าจริงกับค่าที่พยากรณ์
ได้

Root Mean Square Error (RMSE): ประเมินความแม่นยำเฉพาะแกน X/Y

ANOVA: เปรียบเทียบประสิทธิภาพของ KNN กับอัลกอริทึมอื่น (เช่น RF, NN)

การวิเคราะห์ค่าพารามิเตอร์ k ที่เหมาะสมสำหรับ KNN

ค่าพารามิเตอร์ k คือ จำนวน "เพื่อนบ้าน" ที่ใกล้ที่สุดในชุดข้อมูล Fingerprint ซึ่งจะถูกนำมาใช้ในการคำนวณตำแหน่งของผู้ใช้งาน

การเลือก k ที่เหมาะสมจะช่วยเพิ่ม ความแม่นยำ (Accuracy) และลดความไวต่อ noise หรือสัญญาณรบกวนได้ ถ้า k น้อยเกินไป หมายถึง เสี่ยงต่อ Overfitting และไวต่อสัญญาณผิดปกติ หรือในกรณีถ้า k มากเกินไป หมายถึง อาจเจอจากข้อมูลสำคัญ ทำให้เกิด Underfitting และความแม่นยำลดลง

วิธีการหาค่าที่เหมาะสมของ k

ขั้นตอนการทดลอง (Cross-validation Approach)

ขั้นตอนที่ 1: เตรียมชุดข้อมูล Fingerprint ที่แยกเป็น Training Set และ Test Set

ขั้นตอนที่ 2: กำหนดช่วงของค่าพารามิเตอร์ k ที่จะทดสอบ เช่น k=1 ถึง k=15

ขั้นตอนที่ 3: สำหรับแต่ละค่า k ให้ทำการประเมินค่าความผิดพลาดโดยใช้ Mean Error Distance (MED) และ Accuracy ดังนี้:

โมเดลทางคณิตศาสตร์ที่ใช้ในการวัดผลค่าต่างๆในการวิจัย


Mean Error Distance (MED)

$$MED = \frac{1}{N} \sum_{i=1}^N \sqrt{(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2} \quad (8)$$

- N: จำนวนตัวอย่างทั้งหมด
- (x_i, y_i) : พิกัดตำแหน่งจริง
- $(\hat{x}_i, \hat{y}_i)$: พิกัดที่โมเดลคำนวณได้

Accuracy (%):

$$\text{Accuracy} = \frac{\text{จำนวนตัวอย่างที่ตำแหน่งคาดการณ์อยู่ในรัศมีที่กำหนด}}{\text{จำนวนตัวอย่างทั้งหมด}} \times 100 \quad (9)$$



ภาพที่ 5 กราฟแสดงค่า K ประเมินผลโดยใช้ค่า Mean Error Distance (MED) เป็นตัวชี้วัดหลัก

การวิเคราะห์ค่าพารามิเตอร์ k ที่เหมาะสมสำหรับ KNN

ในการประเมินประสิทธิภาพของอัลกอริทึม K-Nearest Neighbors (KNN) สำหรับการระบุตำแหน่งภายในอาคารผ่านเทคนิค WiFi Fingerprinting จำเป็นต้องกำหนดค่าพารามิเตอร์ k ที่เหมาะสม เนื่องจากค่าดังกล่าวมีผลโดยตรงต่อความแม่นยำของการคาดคะเนตำแหน่ง โดยในงานวิจัยนี้ ได้ทำการทดลองกำหนดค่า k ตั้งแต่ 1 ถึง 15 และประเมินผลโดยใช้ค่า Mean Error Distance (MED) เป็นตัวชี้วัดหลัก


จากกราฟในภาพที่ 5 กราฟแสดงค่า K ประเมินผลโดยใช้ค่า Mean Error Distance (MED) เป็นตัวชี้วัดหลัก พบว่า เมื่อ k=2 จะให้ค่า MED ต่ำที่สุดที่ 218.42 เมตร ซึ่งหมายความว่าระบบสามารถทำนายตำแหน่งได้ใกล้เคียงกับตำแหน่งจริงมากที่สุดภายใต้พารามิเตอร์นี้ โดยแนวโน้มของค่า MED จะเพิ่มขึ้นอย่างชัดเจนเมื่อ k มีค่ามากขึ้น โดยเฉพาะตั้งแต่ k=7 เป็นต้นไป ซึ่งอาจเกิดจากการที่ KNN พิจารณาข้อมูลจากเพื่อนบ้านที่อยู่ห่างออกไปมากขึ้น ทำให้เกิด ค่าเฉลี่ยที่เบี่ยงเบน จากตำแหน่งเป้าหมายจริง

การใช้ k ที่ต่ำเกินไป เช่น k=1 แม้จะให้ผลลัพธ์ที่ใกล้เคียง แต่ก็อาจไวต่อ Noise และ Outlier ซึ่งเป็นลักษณะทั่วไปในข้อมูล RSSI ที่มีการแปรปรวนสูง ดังนั้นการเลือก k=2 จึงเป็นทางเลือกที่สมดุลที่สุดระหว่างความแม่นยำและความทนทานต่อความผิดพลาดของสัญญาณ

นอกจากนี้ ยังได้มีการปรับปรุงขั้นตอน Preprocessing และ Feature Selection ซึ่งรวมถึงการกรอง Access Points (APs) ที่มีการกระจายข้อมูลต่ำออก และทำการ Normalize ข้อมูล RSSI ส่งผลให้โมเดลมีความเสถียรมากขึ้น ซึ่งแสดงให้เห็นจากค่า Root Mean Square Error (RMSE) ทั้งในแกน X และ Y ที่ลดลงอย่างมีนัยสำคัญ

การทดลองนี้ยืนยันว่า ค่า $k=2$ คือพารามิเตอร์ที่เหมาะสมที่สุดสำหรับโมเดล KNN ภายใต้บริบทของงานวิจัยนี้ โดยให้ผลลัพธ์ที่ดีที่สุดทั้งในแง่ของ MED และ RMSE รวม อีกทั้งสามารถนำไปประยุกต์ใช้กับระบบระบุตำแหน่งแบบเรียลไทม์ได้อย่างมีประสิทธิภาพ

สรุปผลการวิจัย



ภาพที่ 6 กราฟแสดงเส้นทางการที่ได้จาก A* Algorithm


เส้นทางที่ได้จาก A* Algorithm

จากการประยุกต์ใช้อัลกอริทึม A* บนชุดข้อมูลตำแหน่งจำลองในอาคาร 9 ชั้น โดยกำหนดจุดเริ่มต้นที่ชั้น 1 และจุดสิ้นสุดที่ชั้น 8 พบว่า A* สามารถหาค่าเส้นทางระหว่างตำแหน่งอ้างอิง (Reference Points: RPs) ได้อย่างมีประสิทธิภาพ โดยภาพที่ 6 กราฟแสดงเส้นทางการที่ได้จาก A* Algorithm แสดงเส้นทางที่ได้เป็นเส้นสีแดงบนกราฟ 3 มิติ ซึ่งแสดงแนวการเคลื่อนที่ทั้งในแกน x, y และแกน z (ชั้นอาคาร)

เส้นทางเดินเท้าจริง (Realistic Walking Path)

แม้ว่าเส้นทางของ A* จะมีประสิทธิภาพในการหาเส้นทางสั้นที่สุดทางทฤษฎี แต่เพื่อให้สอดคล้องกับการใช้งานในสถานการณ์จริง จึงได้จำลองเส้นทางการเดินเท้าในอาคารโดยอ้างอิงจากเงื่อนไขจริง คือ เดินจากจุดเริ่มต้นไปยังจุดขึ้นบันไดชั้น 1 และขึ้นบันไดจากชั้น 1 ไปยังชั้น 8 (ผ่านทางลาดชัน 30°) และการเดินจากจุดบันไดชั้น 8 ไปยังตำแหน่งเป้าหมาย

จากแผนภาพ ภาพที่ 6 กราฟแสดงเส้นทางการเดินทางผ่านบันได ได้แสดงเส้นทางที่เดินเท้าได้จริงด้วยเส้นสีเขียว โดยสามารถสังเกตได้ว่าเส้นทางเริ่มต้นและสิ้นสุดไม่ได้ซ้อนทับตำแหน่งบันได ซึ่งทำให้เกิดระยะทางเดินในแนวราบที่มีนัยสำคัญ



ภาพที่ 6 กราฟแสดงเส้นทางการเดินทางผ่านบันได

ระยะทางเดินเท้าจริง (Total Realistic Walking Distance)

เพื่อสะท้อนสภาพแวดล้อมการเดินจริงในอาคาร ระบบได้ทำการประเมินระยะทางการเดินในแต่ละองค์ประกอบดังนี้

ตารางที่ 1 กราฟแสดงผลลัพธ์การเดิน

ประเภทการเดิน	ระยะทาง (เมตร)
เดินในแนวราบทั้งหมด	1,527.80
เดินขึ้นบันไดแบบ slope 30°	42.00
รวมระยะทางเดินจริงทั้งหมด	1,569.80

ผลการทดลองนี้สะท้อนให้เห็นว่า การประเมินระยะทางบนกราฟเครือข่ายเพียงอย่างเดียวอาจไม่เพียงพอ โดยเฉพาะเมื่อพิจารณาถึงเงื่อนไขเชิงกายภาพของอาคาร เช่น จุดขึ้นบันไดหรือจุดเชื่อมต่อระหว่างชั้น ซึ่งมีผลต่อการวางแผนเส้นทางนำทางที่สมจริง (realistic navigation) สำหรับระบบ Indoor Navigation ในแอปพลิเคชันจริง

การวิเคราะห์ข้อจำกัด (Analysis of Limitations)

แม้ว่า WiFi Fingerprinting จะสามารถนำมาใช้ในการระบุตำแหน่งได้อย่างกว้างขวาง แต่ก็ยังมีข้อจำกัดที่สำคัญในด้านความเสถียรของสัญญาณ เนื่องจากผลกระทบของปรากฏการณ์ Multipath Effect และสัญญาณรบกวนจากอุปกรณ์อื่นในเครือข่าย ส่งผลให้ค่า RSSI มีความผันผวนสูง และอาจกระทบต่อความแม่นยำของการประมาณตำแหน่ง นอกจากนี้ การประยุกต์ใช้ OpenStreetMap (OSM) สำหรับการแสดงแผนที่ในอาคารยังพบข้อจำกัด เช่น ความละเอียดของแผนที่ภายในอาคารไม่ครอบคลุมครบทุกชั้น หรือมีความคลาดเคลื่อนในการแปลงพิกัดพิกัดอาคารเข้าสู่ระบบพิกัดภูมิศาสตร์ ทำให้ไม่สามารถแสดงเส้นทางบนแผนที่ได้อย่างแม่นยำ 100%

ข้อเสนอแนะสำหรับการปรับปรุงระบบในอนาคต

เพื่อเพิ่มความแม่นยำและความน่าเชื่อถือของระบบนำทางภายในอาคารในอนาคต ควรผสมผสานข้อมูลจาก WiFi Fingerprinting เข้ากับข้อมูลจากเซนเซอร์เฉื่อย (IMU Sensors) เช่น Accelerometer, Gyroscope และ Magnetometer ซึ่งจะช่วยให้การติดตามตำแหน่งของผู้ใช้งานเมื่ออยู่ในพื้นที่ที่มีความแปรปรวนของสัญญาณสูง หรือไม่มีสัญญาณ WiFi เพียงพอ นอกจากนี้ ควรมีการออกแบบฐานข้อมูล Fingerprint ให้สามารถอัปเดตแบบ Crowdsourced เพื่อให้ระบบมีความยืดหยุ่นและปรับตัวกับการเปลี่ยนแปลงของสภาพแวดล้อมในอาคารได้อย่างต่อเนื่อง

อภิปรายผลการวิจัย

งานวิจัยนี้มุ่งเน้นการพัฒนาและประเมินระบบระบุตำแหน่งภายในอาคาร (Indoor Positioning System: IPS) โดยใช้เทคนิค WiFi Fingerprinting ร่วมกับอัลกอริทึม K-Nearest Neighbors (KNN) และการแสดงผลบนแผนที่แบบเรียลไทม์ผ่าน OpenStreetMap (OSM) เพื่อสนับสนุนระบบนำทางในพื้นที่มหาวิทยาลัยที่มีหลายชั้น โดยเฉพาะอย่างยิ่งในบริเวณที่สัญญาณ GPS ไม่สามารถเข้าถึงได้อย่างมีประสิทธิภาพ

ผลการทดลองแสดงให้เห็นว่าอัลกอริทึม KNN มีความแม่นยำในการคาดคะเนตำแหน่งได้อย่างมีประสิทธิภาพเมื่อใช้กับข้อมูล RSSI ที่จำลองสภาพแวดล้อมภายในอาคาร ค่า Mean Error Distance (MED) และ Root Mean Square Error (RMSE) ที่ได้จากการประเมินโมเดลแสดงให้เห็นว่าค่า k ที่เหมาะสมสามารถลดค่าความผิดพลาดได้อย่างมีนัยสำคัญ นอกจากนี้ยังพบว่า การนำเทคนิค WiFi Fingerprinting มาใช้ร่วมกับแผนที่ OSM ทำให้สามารถนำทางผู้ใช้งานได้อย่างแม่นยำในระดับที่ใช้งานจริงได้ โดยแสดงผลเส้นทางผ่าน Web Application หรือ Mobile Application แบบเรียลไทม์ โดยใช้ Flask API และ WebSocket ในการอัปเดตตำแหน่ง

ผลการเปรียบเทียบระหว่างเส้นทาง A* Pathfinding กับเส้นทางเดินจริงในอาคาร ยังสะท้อนให้เห็นถึงความสำคัญของการออกแบบระบบที่คำนึงถึงข้อจำกัดทางกายภาพ เช่น ตำแหน่งบันไดและเส้นทางเดินแนวราบ การจำลองเส้นทางเดินจริงทำให้ได้ระยะทางเดินเท้า (Realistic Walking Distance) ที่ใกล้เคียงกับการใช้งานในสถานการณ์จริงมากขึ้น ซึ่งมีความสำคัญต่อการพัฒนาระบบนำทางที่เป็นมิตรกับผู้ใช้

ในภาพรวม งานวิจัยนี้ยืนยันว่า การผสานระหว่าง WiFi Fingerprinting, อัลกอริทึม KNN และการประยุกต์ใช้ OSM สามารถเพิ่มความแม่นยำและประสิทธิภาพของระบบ Indoor Navigation ได้อย่างมีนัยสำคัญ อย่างไรก็ตาม ยังมีข้อจำกัดในด้านความไม่เสถียรของสัญญาณ WiFi และความไม่สมบูรณ์ของข้อมูลแผนที่ภายในอาคารที่ได้จาก OSM ซึ่งควรได้รับการพัฒนาเพิ่มเติม

สำหรับแนวทางการวิจัยในอนาคต ผู้วิจัยเสนอให้มีการผสมผสานเทคนิค Hybrid Positioning Systems ที่รวมข้อมูลจาก WiFi, Bluetooth, RFID และเซนเซอร์เฉื่อย (IMU) เพื่อเพิ่มความเสถียรของการติดตามตำแหน่ง รวมถึงการประยุกต์ใช้โมเดล Deep Learning เช่น Convolutional Neural Networks (CNN) หรือ Recurrent Neural Networks (RNN) เพื่อเรียนรู้ลักษณะของสัญญาณแบบลำดับและเชิงพื้นที่อย่างมีประสิทธิภาพ อีกทั้งยังสามารถนำแนวคิด Crowdsourced Data Updates มาใช้ในการปรับปรุงฐานข้อมูล Fingerprint ให้สามารถอัปเดตแบบอัตโนมัติ เพื่อให้ระบบมีความยืดหยุ่นต่อการเปลี่ยนแปลงของสภาพแวดล้อมในอาคารอย่างต่อเนื่อง

เอกสารอ้างอิง

- Brena, Ramon F., Juan Pablo García-Vázquez, Carlos E. Galván-Tejada, David Muñoz-Rodriguez, Cesar Vargas-Rosales, and James Fangmeyer Jr. 2017. “Evolution of Indoor Positioning Technologies: A Survey.” *Journal of Sensors* 2017(1):2630413. doi: 10.1155/2017/2630413.
- Dai, Peng, Yuan Yang, Manyi Wang, and Ruqiang Yan. 2019. “Combination of DNN and Improved KNN for Indoor Location Fingerprinting.” *Wireless Communications and Mobile Computing* 2019(1):4283857. doi: 10.1155/2019/4283857.
- Gadkari, Kaustubh, M. Lawrence Weikum, Dan Massey, and Christos Papadopoulos. 2016. “Pragmatic Router FIB Caching.” *Computer Communications* 84:52–62. doi: 10.1016/j.comcom.2016.02.006.
- García-Catalá, María Teresa, Estefanía Martín-Barroso, María Cristina Rodríguez-Sánchez, Marcos Delgado-Álvaro, and Robert Novak. 2024. “Sensory Navigation System for Indoor Localization and Orientation of Users with Cognitive Disabilities in Daily Tasks and Emergency Situations.” *Sensors* 24(22):7154. doi: 10.3390/s24227154.

- Hoang, Minh Tu. 2020. “WiFi Fingerprinting Based Indoor Localization with Autonomous Survey and Machine Learning.”
- J, N. Syazwani C., Nur Haliza Abdul Wahab, Noorhazirah Sunar, Sharifah H. S. Ariffin, Keng Yinn Wong, and Yichiet Aun. 2022. “Indoor Positioning System: A Review.” *International Journal of Advanced Computer Science and Applications (IJACSA)* 13(6). doi: 10.14569/IJACSA.2022.0130659.
- Larsson, Johan. 2015. “Distance Estimation and Positioning Based on Bluetooth Low Energy Technology.”
- Mahdi, Alaa A., Abdolah Chalechale, and Ashraf AbdelRaouf. 2022. “A Hybrid Indoor Positioning Model for Critical Situations Based on Localization Technologies.” *Mobile Information Systems* 2022(1):8033380. doi: 10.1155/2022/8033380.
- Mendoza-Silva, Germán Martín, Joaquín Torres-Sospedra, and Joaquín Huerta. 2019. “A Meta-Review of Indoor Positioning Systems.” *Sensors* 19(20):4507. doi: 10.3390/s19204507.
- Naderi Salim, S., M. M. Alizadeh, S. Chamankar, and H. Schuh. 2023. “IMPROVED INDOOR POSITIONING USING FINGERPRINT TECHNIQUE AND WEIGHTED K-NEAREST NEIGHBOUR.” *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* X-4-W1-2022:575–80. doi: 10.5194/isprs-annals-X-4-W1-2022-575-2023.
- Navigine. n.d. “Why Is GPS Ineffective Inside Buildings? GPS Alternatives for Positioning and Tracking.” Retrieved April 28, 2025 (<https://navigine.com/blog/why-is-gps-ineffective-inside-buildings/>).
- Obeidat, Huthaifa, Wafa Shuaieb, Omar Obeidat, and Raed Abd-Alhameed. 2021. “A Review of Indoor Localization Techniques and Wireless Technologies.” *Wireless Personal Communications* 119(1):289–327. doi: 10.1007/s11277-021-08209-5.
- Phunthawornwong, Minthorn, Eakkachai Pengwang, and Rardchawadee Silapunt. 2018. “Indoor Location Estimation of Wireless Devices Using the Log-Distance Path Loss Model.” Pp. 0499–0502 in *TENCON 2018 - 2018 IEEE Region 10 Conference*.
- Racum. 2023. “OpenStreetMap to GeoJSON.” Retrieved May 12, 2025 (<https://racum.blog/articles/osm-to-geojson/>).

- Sartayeva, Yerkezhan, Henry C. B. Chan, Yik Him Ho, and Peter H. J. Chong. 2023. “A Survey of Indoor Positioning Systems Based on a Six-Layer Model.” *Computer Networks* 237:110042. doi: 10.1016/j.comnet.2023.110042.
- Shang, Shuang, and Lixing Wang. 2022. “Overview of WiFi Fingerprinting-Based Indoor Positioning.” *IET Communications* 16(7):725–33. doi: 10.1049/cmu2.12386.
- Toshita, Satpute, Titarmare Anchal, Tekam Aarti, Ighe Nikita, Manutai Ghahgre, and Dr N. K. Choudhari. 2025. “Indoor Positioning System.” 12(4).
- Vargas-Munoz, John E., Shivangi Srivastava, Devis Tuia, and Alexandre X. Falcão. 2021. “OpenStreetMap: Challenges and Opportunities in Machine Learning and Remote Sensing.” *IEEE Geoscience and Remote Sensing Magazine* 9(1):184–99. doi: 10.1109/MGRS.2020.2994107.
- Veeranath, P., Dr D. N. Rao, Dr S. Vathsar, and N. Bhasker. 2013. “Reducing Multipath Effects in Indoor Channel for Analysis of GPS/Pseudolite Signal Acquisition.”
- Wang, Zhiyong, and Lei Niu. 2018. “A Data Model for Using OpenStreetMap to Integrate Indoor and Outdoor Route Planning.” *Sensors* 18(7):2100. doi: 10.3390/s18072100.
- Xia, Shixiong, Yi Liu, Guan Yuan, Mingjun Zhu, and Zhaohui Wang. 2017. “Indoor Fingerprint Positioning Based on Wi-Fi: An Overview.” *ISPRS International Journal of Geo-Information* 6(5):135. doi: 10.3390/ijgi6050135.
- Youssef, Moustafa, and Ashok Agrawala. 2005. “The Horus WLAN Location Determination System.” Pp. 205–18 in *Proceedings of the 3rd international conference on Mobile systems, applications, and services, MobiSys '05*. New York, NY, USA: Association for Computing Machinery.
- Zhai, Yongjie, Zhedong Hu, Qianming Wang, Qiang Yang, and Ke Yang. 2022. “Multi-Geometric Reasoning Network for Insulator Defect Detection of Electric Transmission Lines.” *Sensors* 22(16):6102. doi: 10.3390/s22166102.