



Research Articles

Implementasi Penentuan Lokasi Dalam Gedung Menggunakan LoRa RSSI Dan Jaringan Syaraf Tiruan Pada ESP32

Implementation of Indoor Positioning Using LoRa RSSI and Artificial Neural Network on ESP32

Cipta Ramadhani*, Rosmaliati, Abdullah Zainuddin, Bulkis Kanata, Teti Zubaidah

Jurusan Teknik Elektro, Fakultas Teknik Universitas Mataram, Mataram,
Nusa Tenggara Barat, INDONESIA

**corresponding author, email : cipta.ramadhani@unram.ac.id*

Manuscript received: 07-10-2025. Accepted: 21-12-2025

ABSTRAK

Berdasarkan hasil pengujian data training, didapatkan bahwa ANN memberikan performa yang lebih baik jika Implementasi Penentuan Lokasi di dalam Gedung semakin banyak digunakan, terutama pada fasilitas umum seperti sekolah dan rumah sakit, di mana sinyal GPS tidak dapat memberikan akurasi yang maksimal. Penelitian ini bertujuan untuk mengimplementasikan penentuan lokasi di dalam gedung menggunakan nilai Received Signal Strength Indicator (RSSI) dari perangkat LoRa. Data RSSI yang terkumpul digunakan untuk melatih jaringan syaraf tiruan (ANN) dengan struktur empat neuron sebagai input, sepuluh neuron tersembunyi, dan lima neuron output yang mewakili klasifikasi ruangan. Proses pelatihan dilakukan menggunakan Python dengan library Numpy dan Pandas. Hasil pelatihan ini berupa bobot dan bias yang digunakan sebagai library eksternal pada mikrokontroler ESP32. Berdasarkan hasil pengujian data pelatihan, didapatkan bahwa ANN memberikan performa yang lebih baik dibandingkan dengan SVM. Pada ANN, diperoleh nilai akurasi 0.90, presisi 0.8666, dan recall 0.9333. Sedangkan pada SVM, diperoleh akurasi 0.92, presisi 0.7133, dan recall 0.6932. Hasil ini menunjukkan bahwa ANN lebih akurat dalam mengklasifikasikan ruangan dengan pola nilai RSSI yang mirip, seperti ruangan koridor. Hal ini memberikan informasi bahwa ANN sangat cocok untuk diimplementasikan pada sistem penentuan lokasi di dalam gedung dan sesuai untuk digunakan pada perangkat ESP32. Penelitian selanjutnya diharapkan dapat menggunakan algoritma optimasi untuk mendapatkan nilai bobot dan bias yang lebih baik.

Kata kunci : Indoor Positioning System, Artificial Neural Network, ESP32, LoRa

ABSTRACT

Indoor Positioning Systems (IPS) are increasingly required in public facilities such as hospitals and schools, where conventional GPS signals are inaccurate. This study aims to implement indoor positioning using Received Signal Strength Indicator (RSSI) values collected from LoRa communication modules. The collected RSSI data were used to train an Artificial Neural Network (ANN) model designed with four input neurons, ten hidden neurons, and five output neurons to represent four laboratories and a connecting corridor. The training process was conducted in Python using Numpy and Pandas, and the resulting weights and biases were stored in an external library file for deployment on the ESP32 microcontroller. Based on the training data tests, it was found that the ANN performed better than the Support Vector Machine (SVM). The ANN achieved an accuracy of 0.90,

precision of 0.8666, and recall of 0.9333. In contrast, the SVM achieved an accuracy of 0.92, but significantly lower precision (0.7133) and recall (0.6932). These results indicate that ANN is more accurate in classifying rooms with similar RSSI patterns, such as corridor areas. This suggests that ANN is highly suitable for implementing indoor positioning systems and can be effectively used on devices like ESP32. Future research is expected to explore optimization algorithms to improve the ANN's weights and biases for better performance.

Keywords: Indoor Positioning System, Artificial Neural Network, ESP32, LoRa.

PENDAHULUAN

Sistem penentuan lokasi dalam ruangan (indoor positioning system, IPS) semakin banyak dibutuhkan untuk mendukung layanan berbasis lokasi di area publik seperti rumah sakit, sekolah, dan pusat perbelanjaan (Liu et al., 2007). Sistem ini dibutuhkan terutama pada kondisi di mana Global Positioning System (GPS) tidak dapat bekerja secara optimal, misalnya di dalam gedung dengan struktur yang kompleks seperti rumah sakit, sekolah, maupun pusat perbelanjaan. Pada konteks ini, akurasi penentuan lokasi dapat membantu berbagai layanan, mulai dari navigasi pasien di rumah sakit, monitoring pergerakan siswa di sekolah, hingga sistem keamanan dan manajemen aset. Namun banyak penelitian masih mencari kriteria desain implementasi yang tepat (Wichmann et al., 2024).

Berbagai teknologi telah dikembangkan untuk mendukung IPS, seperti Wi-Fi dan Bluetooth Low Energy (BLE). Namun, pendekatan tersebut memiliki beberapa keterbatasan. Wi-Fi dan BLE misalnya, cenderung boros energi dan kurang stabil ketika digunakan pada perangkat dengan keterbatasan daya. Sementara itu, LoRa (Long Range) sebagai salah satu teknologi komunikasi nirkabel berbasis low power wide area network (LPWAN) dikenal sebagai salah satu teknologi yang hemat energi dan mampu menjangkau area luas (Garcia, n.d.).

LoRa banyak diteliti untuk mendukung IPS dengan memanfaatkan parameter Received Signal Strength Indicator (RSSI) sebagai dasar penentuan posisi (Lutakamale et al., 2024). LoRa (Long Range) menawarkan karakteristik unik berupa jangkauan sinyal yang luas, serta kemampuan penetrasi sinyal yang baik di dalam gedung. Hal ini menjadikan LoRa lebih efisien dan ekonomis untuk implementasi IPS, khususnya pada area publik yang memerlukan cakupan luas dengan jumlah perangkat banyak (Teymuri et al., 2023). Dengan pengaturan yang baik, konsumsi energi perangkat berbasis LoRa akan dapat beroperasi lebih lama dibandingkan dengan Wi-Fi tanpa sering melakukan pengisian daya, yang sangat penting untuk skenario rumah sakit maupun sekolah (Garcia, n.d.; Kim et al., 2021).

Namun demikian, tantangan utama dalam pemanfaatan RSSI adalah sifatnya yang fluktuatif akibat multipath, gangguan lingkungan, dan keberadaan manusia (Carpi et al., 2023). Algoritma konvensional seperti k-nearest neighbor (k-NN) atau Support Vector Machine (SVM) sering kali tidak cukup efektif dalam menangkap pola non-linear pada data RSSI. Oleh karena itu, dibutuhkan pendekatan yang lebih adaptif dan mampu melakukan generalisasi pada kondisi lingkungan yang bervariasi.

Artificial Neural Network (ANN) muncul sebagai salah satu solusi yang menjanjikan. ANN memiliki kemampuan untuk memodelkan hubungan non-linear yang kompleks antara sinyal RSSI dan lokasi aktual. Beberapa penelitian telah menunjukkan bahwa ANN dapat meningkatkan akurasi sistem penentuan lokasi berbasis LoRa (Perković et al., 2023). Selain

itu, dengan kemajuan pada bidang tiny machine learning, ANN kini dapat diimplementasikan pada perangkat terbatas sumber daya seperti ESP32 dengan menggunakan teknik optimasi model, misalnya quantization dan pruning (Dobrilovic, 2025; Immonen & Hämäläinen, 2022).

Berdasarkan latar belakang tersebut, penelitian ini mengusulkan implementasi sistem penentuan lokasi dalam ruangan berbasis RSSI LoRa dengan algoritma ANN ringan yang dapat dijalankan secara real-time pada perangkat ESP32. Sistem ini ditujukan untuk mendukung aplikasi di area publik, terutama rumah sakit dan sekolah, dengan keunggulan berupa akurasi tinggi sekaligus efisiensi pemrosesan. Pendekatan ini memanfaatkan keunggulan LoRa (low-power, jangkauan luas, penetrasi sinyal baik)

METODE PENELITIAN

Pengumpulan Data

Data RSSI dikumpulkan pada beberapa titik referensi di dalam Gedung B Fakultas Teknik lantai 3 Universitas Mataram pada bulan Agustus 2025 menggunakan modul LoRa. Setiap titik dilakukan pengukuran terhadap sinyal RSSI yang dipancarkan dari empat ruangan berbeda. Ruangan yang digunakan dalam pengambilan data meliputi Laboratorium Jaringan dan Komputer, Laboratorium Sistem Kendali, Laboratorium Elektronika, Laboratorium Telekomunikasi, serta koridor yang menghubungkan keempat ruangan tersebut. Tabel 1 berisi jumlah data untuk masing-masing ruangan lokasi pengukuran nilai RSSI.

Tabel 1. Jumlah data pengukuran untuk tiap ruangan

No	Nama Ruangan	Jumlah Data
1	Lab Jaringan Komputer	129
2	Lab Sistem Kendali	96
3	Lab Elektronika	86
4	Lab Telekomunikasi	94
5	Koridor	90

Jumlah data pada tiap ruangan tidak seragam. Hal ini disebabkan oleh kondisi nyata di lapangan, di mana beberapa laboratorium berisi peralatan berukuran besar dan permanen (fixed), sehingga tidak memungkinkan untuk dipindahkan. Keberadaan peralatan tersebut menyebabkan keterbatasan dalam penempatan titik referensi, sehingga jumlah sampel data yang terkumpul di tiap ruangan berbeda.

Pengukuran dilakukan dengan menempatkan modul LoRa pada titik-titik referensi yang dipisahkan dengan jarak sekitar 1 meter antara satu titik dengan titik lainnya. Dengan cara ini, diperoleh variasi nilai RSSI dari empat access point. Secara keseluruhan, proses ini menghasilkan total 495 data yang kemudian digunakan sebagai dataset fingerprinting untuk sistem Indoor Positioning System (IPS). Tujuan akhir dari pengumpulan data ini adalah agar hasil penelitian dapat dimanfaatkan dalam pengembangan sistem IPS untuk lingkungan laboratorium lantai 3 Jurusan Teknik Elektro. Gambar 1 menunjukkan denah ruangan yang digunakan dalam proses pengambilan data, yang meliputi empat laboratorium serta koridor penghubung.



Gambar 1. Denah ruangan uji sistem IPS berbasis RSSI

Metode Pengembangan.

Pengembangan sistem Indoor Positioning System (IPS) berbasis LoRa dalam penelitian ini dilakukan dengan pendekatan prototype model. Model terdiri atas lima tahapan utama, yaitu pengumpulan kebutuhan, pembuatan prototipe, evaluasi prototipe, serta perbaikan dan pengujian akhir, sebagaimana dijelaskan berikut ini.

Pengumpulan Kebutuhan (*Requirement Gathering*)

Pada tahap ini dilakukan identifikasi kebutuhan sistem baik dari sisi perangkat keras maupun perangkat lunak. Sistem ini menggunakan lima modul ESP32 LoRa (LilyGo LoRa32), di mana empat unit berfungsi sebagai pengirim sinyal (transmitter) dan satu unit sebagai penerima (receiver). Setiap transmitter memancarkan sinyal LoRa yang diukur nilai RSSI-nya oleh receiver di berbagai titik dalam ruangan. Dari sisi perangkat lunak, pengolahan data dan pelatihan model jaringan syaraf tiruan dilakukan menggunakan bahasa pemrograman Python, dengan pustaka pandas untuk manajemen data dan numpy untuk perhitungan numerik. Hasil dari tahap ini adalah spesifikasi sistem dan kebutuhan data untuk proses pelatihan model.

Pembuatan Prototipe (*Prototype Development*)

Tahap ini bertujuan untuk membangun versi awal sistem yang mewakili fungsi utama yang ingin dicapai. Model ANN dirancang dengan arsitektur sederhana yang terdiri dari 4 neuron input (RSSI), 10 neuron pada hidden layer dengan fungsi aktivasi ReLU, dan 5 neuron output menggunakan fungsi aktivasi softmax. Model dilatih menggunakan learning rate dan iterasi yang bervariasi sampai ditemukannya nilai akurasi yang maksimum. Setelah proses pelatihan, bobot dan bias hasil pelatihan diekstrak menjadi file weight.h dan diintegrasikan ke dalam program ESP32 untuk proses inferensi secara real-time.

Evaluasi Prototipe (*Prototype Evaluation*)

Tahap ini dilakukan untuk menilai kinerja awal prototipe sistem. Pengujian difokuskan pada akurasi hasil klasifikasi lokasi. Hasil pengujian digunakan untuk mengevaluasi kesesuaian sistem dengan kebutuhan awal serta untuk mengidentifikasi area yang memerlukan perbaikan, seperti kestabilan sinyal RSSI dan ketepatan hasil prediksi pada kondisi lingkungan yang berbeda.


Perbaikan dan Pengujian Akhir (*Refinement and Final Testing*)

Tahap akhir bertujuan untuk menyempurnakan sistem berdasarkan hasil evaluasi sebelumnya. Perbaikan dilakukan pada parameter pelatihan model ANN, seperti penyesuaian learning rate dan jumlah iterasi untuk meningkatkan akurasi klasifikasi. Setelah dilakukan penyempurnaan, sistem diuji kembali untuk memastikan peningkatan performa dalam hal akurasi lokasi, kecepatan pemrosesan, dan efisiensi komputasi pada perangkat ESP32. Hasil pengujian akhir ini menjadi dasar dalam penarikan kesimpulan terhadap efektivitas sistem yang dikembangkan.

Pra-Pemrosesan Data Dan Perancangan Model ANN

Nilai RSSI yang umumnya bernilai negatif ditransformasikan menjadi bilangan positif untuk mempermudah pemrosesan selanjutnya. Pada tahap ini tidak dilakukan normalisasi karena rentang nilai RSSI masih konsisten dan dapat langsung digunakan oleh model ANN. Model Artificial Neural Network (ANN) dirancang dengan arsitektur sederhana yang terdiri atas: **Input layer:** 4 neuron yang mewakili nilai RSSI dari empat node LoRa. Jumlah neuron ini dipilih secara langsung berdasarkan jumlah fitur yang tersedia, sehingga seluruh informasi RSSI dari setiap ruangan dapat diolah tanpa reduksi dimensi tambahan. **Hidden layer:** 10 neuron dengan fungsi aktivasi ReLU (Rectified Linear Unit). Pemilihan 10 neuron dilakukan untuk memberikan kapasitas yang cukup dalam mengenali variasi pola RSSI, tanpa membuat model menjadi terlalu kompleks yang dapat menyebabkan overfitting. Fungsi aktivasi ReLU dipilih karena sederhana, mampu mengatasi masalah vanishing gradient, serta efisien secara komputasi, sehingga sesuai dengan keterbatasan perangkat keras seperti ESP32. **Output layer:** 5 neuron yang mewakili lima kelas lokasi (empat laboratorium dan koridor), menggunakan fungsi aktivasi softmax untuk menghasilkan distribusi probabilitas yang mudah diinterpretasikan pada klasifikasi multi-kelas. **Model** dilatih menggunakan learning rate sebesar 0,001 dengan jumlah iterasi 5000. Nilai learning rate ini dipilih setelah beberapa percobaan awal, di mana nilai yang lebih besar menyebabkan model tidak stabil, sedangkan nilai yang lebih kecil membuat proses training terlalu lambat. Jumlah iterasi 5000 dianggap cukup untuk mencapai konvergensi tanpa membebani waktu komputasi secara berlebihan.

Arsitektur ini dipilih karena seimbang antara kompleksitas model dan keterbatasan perangkat komputasi. Model dengan satu hidden layer dan jumlah neuron moderat (10 neuron) sudah mampu menangkap hubungan non-linear dari pola RSSI antar-ruangan, tanpa memerlukan jaringan yang lebih dalam. Dengan demikian, desain ini memastikan bahwa hasil klasifikasi tetap akurat, tetapi tetap memungkinkan implementasi pada perangkat yang dengan sumberdaya yang terbatas seperti ESP32. Gambar 2 menunjukkan arsitektur ANN yang digunakan dalam penelitian ini penentuan lokasi didalam gedung.



Gambar 2. Arsitektur ANN

Pelatihan Model dan Integrasi ESP32

Proses pelatihan dilakukan menggunakan bahasa Python hanya dengan memanfaatkan pandas untuk manajemen data dan numpy untuk perhitungan numerik. Algoritma backpropagation digunakan untuk memperbarui bobot dan bias hingga jaringan mencapai konvergensi. Dataset dibagi menjadi data latih dan data uji untuk mengevaluasi kinerja model.



Gambar 3. Diagram Implementasi ANN pada ESP32

Bobot dan bias hasil pelatihan diekstrak dari Python dan dikonversi menjadi file `weight.h`, yang berisi representasi data numerik dari parameter jaringan saraf. File `weight.h` ini dimasukkan sebagai external library dalam proyek ESP32. Dengan pendekatan ini, kode utama di ESP32 tetap ringkas, karena proses inferensi hanya perlu memanggil bobot dan bias dari file tersebut. Perhitungan inferensi dilakukan dengan metode feedforward, sehingga ESP32 dapat memprediksi lokasi secara real-time berdasarkan input RSSI terbaru. Gambar 3 berisi Diagram tahapan implementasi ANN pada ESP32.

HASIL DAN PEMBAHASAN

Dataset

Dataset yang digunakan dalam penelitian ini diperoleh melalui pengukuran nilai RSSI dari modul LoRa yang dipasang pada empat access point berbeda. Data dikumpulkan di beberapa titik referensi pada area uji yang telah ditentukan dengan tujuan merepresentasikan variasi kekuatan sinyal di setiap lokasi. Jumlah total data sebanyak 495 titik pengukuran dimana nilai RSSI yang semula berada pada rentang negatif diubah menjadi positif agar lebih mudah diolah oleh model jaringan saraf tiruan (ANN). Dataset kemudian dibagi menjadi data latih dan data uji dengan perbandingan tertentu, sehingga model dapat dievaluasi secara objektif. Tabel 2 berisi sampel dataset RSSI yang diukur.

Tabel 2. Sampel Dataset RSSI


Titik Uji (x,y)	RSSI Node 1 (dBm)	RSSI Node 2 (dBm)	RSSI Node 3 (dBm)	RSSI Node 4 (dBm)	Label Lokasi
0,1	-83	-91	-62	-78	Lab Jaringan Komputer
0,2	-92	-95	-63	-79	Lab Jaringan Komputer
1,1	-98	-88	-78	-64	Lab Sistem Kendali
1,2	-97	-98	-77	-75	Lab Sistem Kendali
2,1	-56	-73	-75	-92	Lab Elektronika
2,2	-59	-75	-85	-89	Lab Elektronika
3,1	-84	-78	-81	-74	Lab Teleko-munikasi
3,2	-83	-76	-86	-75	Lab Teleko-munikasi
4,1	-73	-76	-87	-91	Koridor
4,2	-75	-72	-87	-95	Koridor

Tabel grid X dan Y dibuat untuk merepresentasikan posisi titik pengambilan data di dalam masing-masing ruangan. Setiap ruangan dibagi ke dalam grid sesuai dengan ukuran luas ruangan, dengan jarak antar titik pengukuran sebesar satu meter. Penomoran grid dimulai dari sudut barat laut (utara–barat) sebagai titik awal dengan koordinat (0,0). Nilai X merepresentasikan pergeseran ke arah timur, sedangkan nilai Y merepresentasikan pergeseran ke arah selatan. Sebagai contoh, titik (0,1) menunjukkan posisi satu meter ke arah timur dari titik awal, sedangkan titik (1,1) menunjukkan posisi satu meter ke arah selatan sekaligus satu meter ke arah timur dari titik awal. Dengan sistem grid ini, distribusi titik pengambilan data dapat terdokumentasi dengan baik, sehingga variasi nilai RSSI yang diperoleh dapat dipetakan secara terstruktur di seluruh ruangan.

Pengujian Data

Pengujian dilakukan untuk mengevaluasi kinerja sistem dalam menentukan lokasi berdasarkan nilai RSSI yang diperoleh dari node LoRa. Pada tahap ini, model Artificial Neural Network (ANN) dibandingkan dengan model Support Vector Machine (SVM) sebagai algoritma pembanding.

Untuk model ANN, arsitektur yang digunakan terdiri atas 4 neuron pada input layer (mewakili empat nilai RSSI), 10 neuron pada hidden layer dengan fungsi aktivasi ReLU, serta 5 neuron pada output layer dengan fungsi aktivasi softmax. Bobot dan bias diperoleh dari proses pelatihan menggunakan Python (pandas dan numpy), kemudian disimpan dalam file weight.h agar dapat diimplementasikan pada ESP32. Beberapa percobaan dilakukan dengan variasi nilai learning rate dan jumlah iterasi. Hasilnya menunjukkan bahwa nilai learning rate 0,001 memberikan kestabilan training, sedangkan jumlah iterasi 5000 cukup untuk mencapai konvergensi tanpa menimbulkan overfitting. Oleh karena itu, konfigurasi ini dipilih sebagai parameter akhir dalam pelatihan ANN. Sedangkan untuk model SVM, pendekatan yang digunakan adalah multiclass classification dengan metode one-vs-all. Nilai RSSI yang sama dijadikan masukan bagi SVM, dan hasil klasifikasi dibandingkan dengan hasil ANN pada data uji.



Gambar 4. Perbandingan Akurasi, Precision dan Recall antara algoritma ANN dan SVM

Gambar 4 memperlihatkan perbandingan akurasi, precision, dan recall dari kedua algoritma. Hasil pengujian menunjukkan bahwa performa ANN dan SVM memiliki karakteristik yang berbeda. Dari sisi akurasi, nilai yang dicapai keduanya relatif mirip, yaitu 0,90 untuk ANN dan 0,92 untuk SVM. Hal ini menandakan bahwa secara keseluruhan jumlah prediksi benar kedua algoritma tidak jauh berbeda. Namun, jika dilihat dari metrik precision dan recall, perbedaan yang cukup mencolok dapat diamati. ANN berhasil mencapai precision sebesar 0,8933 dan recall sebesar 0,893, sedangkan SVM hanya memperoleh precision 0,7133 dan recall 0,6932. Nilai ini menunjukkan bahwa meskipun akurasi SVM sedikit lebih tinggi, ANN jauh lebih unggul dalam konsistensi klasifikasi di semua kelas.

Secara khusus, kelemahan SVM tampak jelas pada kelas koridor. Karena koridor berada di posisi tengah yang menerima sinyal RSSI dengan pola mirip dari keempat laboratorium, SVM gagal melakukan pemisahan yang tepat, sehingga banyak data koridor diklasifikasikan ke dalam kelas lain. Hal ini menyebabkan precision dan recall SVM menurun signifikan.

Sebaliknya, ANN mampu mengenali hubungan non-linear antar nilai RSSI, sehingga dapat membedakan koridor dari ruangan lain dengan lebih baik dan menjaga nilai recall tetap tinggi. Hal ini menunjukkan bahwa ANN secara konsisten menunjukkan kinerja yang lebih stabil dibandingkan SVM.

KESIMPULAN

Penelitian ini berhasil mengembangkan sistem Indoor Positioning System (IPS) berbasis RSSI dari modul LoRa dengan perbandingan performa antara algoritma Artificial Neural Network (ANN) dan Support Vector Machine (SVM). Data diperoleh dari pengukuran nilai RSSI pada empat laboratorium dan koridor penghubung di lantai 3 Gedung Fakultas Teknik Universitas Mataram, kemudian diolah untuk melatih dan menguji kedua model.

Hasil pengujian menunjukkan bahwa meskipun akurasi SVM (0,92) sedikit lebih tinggi dibandingkan ANN (0,90), namun dari sisi precision dan recall, ANN secara signifikan lebih unggul dengan nilai 0,8933 dan 0,893 dibandingkan SVM yang hanya mencapai 0,7133 dan 0,6932. Hal ini terutama dipengaruhi oleh ketidakmampuan SVM dalam mengklasifikasikan kelas koridor, karena pola RSSI pada koridor mirip dengan pola dari keempat laboratorium. Sebaliknya, ANN mampu memodelkan hubungan non-linear antar nilai RSSI, sehingga dapat membedakan koridor dari kelas lain dengan lebih baik.

Berdasarkan hasil tersebut, dapat disimpulkan bahwa ANN lebih sesuai digunakan untuk sistem IPS berbasis LoRa pada lingkungan publik seperti sekolah dan rumah sakit, karena memiliki kemampuan klasifikasi yang lebih stabil pada area dengan pola sinyal yang kompleks. Sebagai tindak lanjut, penelitian berikutnya dapat diarahkan pada penggunaan algoritma optimasi (seperti Particle Swarm Optimization atau Firefly Algorithm) untuk memperbaiki bobot (weight) dan bias ANN, sehingga model dapat mencapai kinerja yang lebih tinggi. Selain itu, perlu dilakukan pengujian performa inferensi langsung pada perangkat ESP32, agar sistem tidak hanya unggul dari segi akurasi, tetapi juga efisien untuk implementasi real-time.

Ucapan Terimakasih.

Kami mengucapkan terima kasih kepada Fakultas Teknik Universitas Mataram atas pendanaan penelitian PNPB tahun 2025.

DAFTAR PUSTAKA

- Carpi, F., Martalò, M., Davoli, L., Cilfone, A., Yu, Y., Wang, Y., & Ferrari, G. (2023). Experimental analysis of RSSI-based localization algorithms with NLOS pre-mitigation for IoT applications. *Computer Networks*, 225, 109663. <https://doi.org/10.1016/j.comnet.2023.109663>
- Chen, H., Yang, J., Hao, Z., Ga, M., Han, X., Zhang, X., & Chen, Z. (2023). Research on indoor positioning method based on LoRa-improved fingerprint localization algorithm. *Scientific Reports*, 13(1), 13981. <https://doi.org/10.1038/s41598-023-41250-x>
- Chen, H., Yang, J., Hao, Z., Qi, T., & Liu, T. (2024). Research on indoor multi-floor positioning method based on LoRa. *Computer Networks*, 254, 110838. <https://doi.org/10.1016/j.comnet.2024.110838>
- Dobrilovic, D. (2025). Experience with the Implementation of Machine Learning on ESP32-

-
- Based Edge Devices (pp. 144–155). https://doi.org/10.1007/978-3-031-72483-1_11
- Garcia, L. (n.d.). Pascal Lorenz. WiFi and LoRa Energy Consumption Comparison in IoT ESP 32/ SX1278 Devices. SMART 2019 : The Eighth International Conference on Smart Cities, Systems, Devices and Technologies, pp.26-31.
- Heydari, S., & Mahmoud, Q. H. (2025). Tiny Machine Learning and On-Device Inference: A Survey of Applications, Challenges, and Future Directions. *Sensors*, 25(10), 3191. <https://doi.org/10.3390/s25103191>
- Immonen, R., & Hämäläinen, T. (2022). Tiny Machine Learning for Resource-Constrained Microcontrollers. *Journal of Sensors*, 2022, 1–11. <https://doi.org/10.1155/2022/7437023>
- Islam, K. Z., Murray, D., Diepeveen, D., Jones, M. G. K., & Sohel, F. (2024). LoRa-based outdoor localization and tracking using unsupervised symbolization. *Internet of Things*, 25, 101016. <https://doi.org/10.1016/j.iot.2023.101016>
- Kim, K., Li, S., Heydariaan, M., Smaoui, N., Gnawali, O., Suh, W., Suh, M. J., & Kim, J. I. (2021). Feasibility of LoRa for Smart Home Indoor Localization. *Applied Sciences*, 11(1), 415. <https://doi.org/10.3390/app11010415>
- Liu, H., Darabi, H., Banerjee, P., & Liu, J. (2007). Survey of Wireless Indoor Positioning Techniques and Systems. *IEEE Transactions on Systems, Man and Cybernetics, Part C (Applications and Reviews)*, 37(6), 1067–1080. <https://doi.org/10.1109/TSMCC.2007.905750>
- Lutakamale, A. S., Myburgh, H. C., & de Freitas, A. (2024). RSSI-based fingerprint localization in LoRaWAN networks using CNNs with squeeze and excitation blocks. *Ad Hoc Networks*, 159, 103486. <https://doi.org/10.1016/j.adhoc.2024.103486>
- Nahshon Mokua Obiri, K. V. L. (2025). EnviKal-Loc: Sub-10m Indoor LoRaWAN Localization using an Environmen. In *Computer Science, Networking and Internet Architecture*, Cornell University.
- Perković, T., Dujčić Rodić, L., Šabić, J., & Šolić, P. (2023). Machine Learning Approach towards LoRaWAN Indoor Localization. *Electronics*, 12(2), 457. <https://doi.org/10.3390/electronics12020457>
- Teymuri, B., Serati, R., Anagnostopoulos, N. A., & Rasti, M. (2023). LP-MAB: Improving the Energy Efficiency of LoRaWAN Using a Reinforcement-Learning-Based Adaptive Configuration Algorithm. *Sensors*, 23(4), 2363. <https://doi.org/10.3390/s23042363>
- Vishwakarma, R., Joshi, R. B., & Mishra, S. (2023). IndoorGNN: A Graph Neural Network Based Approach for Indoor Localization Using WiFi RSSI (pp. 150–165). https://doi.org/10.1007/978-3-031-49601-1_11
- Wichmann, J., Paetow, T., Leyer, M., Aweno, B., & Sandkuhl, K. (2024). Determining design criteria for indoor positioning system projects in hospitals: A design science approach. *DIGITAL HEALTH*, 10. <https://doi.org/10.1177/20552076241229148>