

Rancang Bangun Sistem Deteksi Posisi Objek dalam Rumah dengan Metode Support Vector Machine Berdasar Kekuatan Sinyal Wi-Fi

Damar Buana Murti*¹, Danang Lelono², Roghib Muhammad Hujja³

¹Program Studi Elektronika dan Instrumentasi, DIKE, FMIPA, UGM, Yogyakarta, Indonesia

^{2,3}Departemen Ilmu Komputer dan Elektronika, FMIPA UGM, Yogyakarta, Indonesia

e-mail: *¹damarbm30@mail.ugm.ac.id, ²danang@ugm.ac.id, ³roghib.muh@ugm.ac.id

Abstrak

Indoor Positioning System (IPS) merupakan teknologi pelacakan objek yang memanfaatkan jaringan seperti Wireless Fidelity (Wi-Fi) untuk mengetahui lokasi suatu objek. IPS erat kaitannya dengan implementasi Internet of Things (IoT) untuk melakukan suatu perintah di dalam smart home. Namun, kelemahan IPS adalah terjadinya pelemahan sinyal yang diterima pada saat tag atau target berpindah ruangan yang berbatasan dengan ruangan lain sehingga menyebabkan kesalahan dalam pelacakan. Implementasi IPS akan dilakukan berdasarkan sinyal Wi-Fi 2.4 GHz yang dipancarkan dari ESP32.

Penelitian akan menggunakan metode trilaterasi yang membutuhkan tiga sink node untuk menerima kekuatan sinyal, kemudian algoritma pembelajaran mesin, yaitu Support Vector Machine (SVM), untuk melakukan klasifikasi ruangan pada tiga skenario berbeda, yaitu target dalam keadaan diam, berpindah ruangan, dan berada di tepi ruangan yang berbatasan dengan ruangan lain.

Hasil dari pengujian menunjukkan bahwa ketiga skenario memberikan tingkat akurasi yang berbeda. Akurasi sistem pada skenario target dalam keadaan diam di ruangan mencapai 100%, pada skenario target berpindah ruangan mencapai 86.15%, dan pada skenario target berada di tepi ruangan yang berbatasan dengan ruangan lain mencapai 80%.

Kata kunci—Indoor positioning system, trilaterasi, SVM, Wi-Fi

Abstract

Indoor Positioning System (IPS) is an object tracking technology that utilizes networks such as Wireless Fidelity (Wi-Fi) to determine the location of an object. IPS is closely related to the implementation of the Internet of Things (IoT) to carry out an order in a smart home. However, the weakness of IPS is the attenuation of the signal received when the tag or target moves to a room that borders another room, causing errors in tracking. The IPS implementation will be carried out based on the 2.4 GHz Wi-Fi signal emitted from the ESP32.

The research will use the trilateration method which requires three sink nodes to receive signal strength, then a machine learning algorithm, namely Support Vector Machine (SVM), to classify rooms in three different scenarios, namely when the target is stationary, moving between rooms, and is on the edge room adjacent to another room.

The results of the test show that the three scenarios provide different levels of accuracy. The accuracy of the system on the target scenario while still in the room reaches 100%, on the target moving room scenario reaches 86.15%, and on the target scenario that is at the edge of the room adjacent to another room reaches 80%.

Keywords—Indoor positioning system, trilateration, SVM, Wi-Fi

1. PENDAHULUAN

Perkembangan internet di kehidupan masyarakat berdampak pada pengembangan produk cerdas yang mampu terhubung ke jaringan dan melakukan pertukaran informasi dengan perangkat lain semakin umum dan menjadi memungkinkan [1]. Salah satu pemanfaatan *Internet of Things* adalah di dalam rumah untuk memberikan layanan kepada penghuni rumah melalui sebuah sistem yang dapat berinteraksi satu sama lain untuk memperoleh informasi dan menentukan aksi berdasarkan informasi yang diperoleh tersebut. Contohnya adalah memperoleh informasi ruangan mana yang ditempati seseorang sehingga sistem dapat menentukan keputusan untuk mengeksekusi sebuah aksi atau tidak. Sistem tersebut merupakan *Indoor Positioning System* atau IPS [2].

Namun, kekuatan sinyal yang diterima oleh sistem *human tracking* menjadi semakin tersebar apabila target yang membawa *tag* sedang berjalan dibandingkan dalam keadaan diam sehingga menyebabkan kesalahan klasifikasi pada saat target berjalan menuju ruangan lain karena jumlah sinyal yang diterima tidak sesuai dengan lokasi target [3]. Selain itu, akibat dari pantulan logam, interferensi dari derau, dan terhalang oleh dinding, informasi kekuatan sinyal yang diterima menjadi tidak akurat. Keadaan tersebut menyebabkan informasi kekuatan sinyal bisa saja tidak tertangkap dengan sempurna [4].

Oleh karena penentuan lokasi menggunakan indoor positioning dapat tergolong sebagai permasalahan klasifikasi, maka salah satu metode machine learning yang dapat digunakan adalah Support Vector Machine atau SVM karena dapat menyelesaikan permasalahan linier dan nonlinier menggunakan *kernel* [5]. Metode lain seperti Decision Tree tidak dipilih karena memberikan efisiensi yang lebih rendah, sedangkan Naïve Bayes memberikan akurasi yang rendah [6]. Ada pula algoritma K-means yang terbukti mengurangi waktu yang dibutuhkan untuk melakukan komputasi, namun memiliki akurasi yang kurang baik [7].

2. METODE PENELITIAN

2.1 Analisis Sistem

Sistem yang dirancang pada penelitian ini berfungsi untuk meningkatkan akurasi tracking manusia pada lingkup smart home menggunakan pembelajaran mesin SVM. Agar sistem tersebut dapat terwujud, diperlukan beberapa komponen fisik yang ditunjukkan pada Tabel 1.

Tabel 1 Perangkat keras

No.	Nama	Fungsi
1	Raspberry Pi 4	Komputasi jarak berdasarkan RSSI, pelatihan data menggunakan SVM, dan validasi
2	ESP32	<i>Beacon</i> dan <i>tag</i> pada target yang bergerak
3	Catu daya	Memberi daya untuk ESP32 dan Raspberry Pi

Raspberry Pi sebagai Single Board Computer atau SBC yang mendukung berbagai antarmuka dan memiliki modul Wi-Fi di dalamnya [8]. ESP32 merupakan modul yang memiliki keping tunggal Wi-Fi dan Bluetooth, dua buah core processor, dan perangkat perifer yang cukup banyak. ESP32 dapat digunakan untuk akuisisi data dan kendali berbagai perangkat melalui jaringan nirkabel dan memiliki kinerja yang lebih baik dari pendahulunya, yaitu ESP8266 [9]. Untuk mendukung perangkat keras, diperlukan perangkat lunak yang tertera pada Tabel 2.

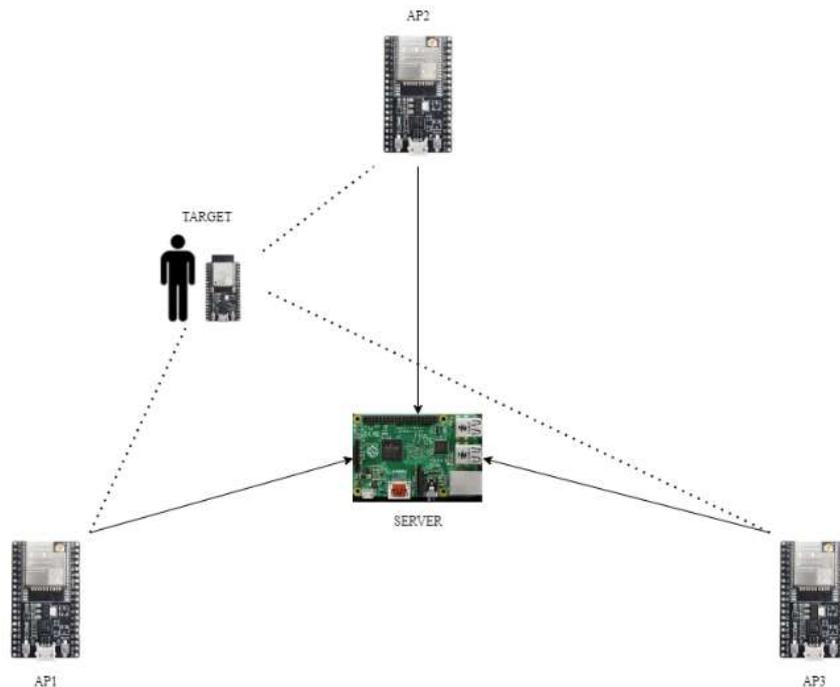
Tabel 2 Perangkat lunak

No.	Nama	Fungsi
1	VNC	Sarana mengakses layar Raspberry Pi menggunakan laptop
2	Python	Bahasa pemrograman untuk Raspberry Pi
3	Jupyter Notebook	IDE untuk menjalankan program Python

VNC sebagai aplikasi untuk mengakses layar dan mengoperasikan Raspberry Pi menggunakan laptop sehingga tidak perlu *monitor*, *keyboard*, dan *mouse* tambahan. Python merupakan bahasa yang digunakan untuk menyusun kode program melalui Raspberry Pi dengan dukungan perangkat lunak Jupyter Notebook sebagai *Integrated Development Environment* atau IDE yang terpasang pada Raspberry Pi.

2.2 Rancangan perangkat keras

Sistem yang akan dirancang pada penelitian ini membutuhkan perangkat keras sebagai perangkat untuk menjalankan perangkat lunak yang berisi program, perangkat keras yang akan digunakan pada penelitian ini berupa Raspberry Pi, ESP32, dan catu daya. Interkoneksi perangkat keras pada penelitian ini disajikan pada Gambar 1.



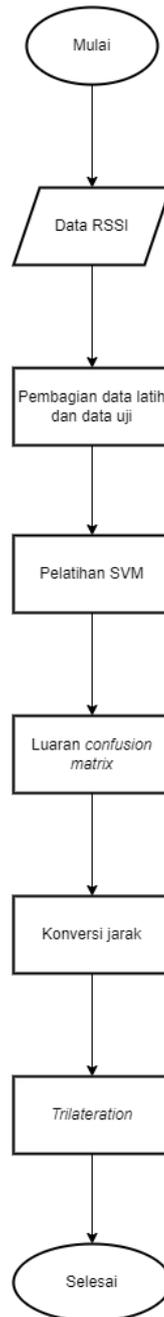
Gambar 1 Interkoneksi perangkat keras

Perangkat ESP32 berperan sebagai *sink node* yang akan memindai nilai RSSI dari Wi-Fi yang dipancarkan oleh ESP32 yang dibawa target. Raspberry Pi berperan sebagai server yang akan menerima data RSSI, melakukan komputasi, dan pelatihan menggunakan SVM.

2.3 Rancangan perangkat lunak

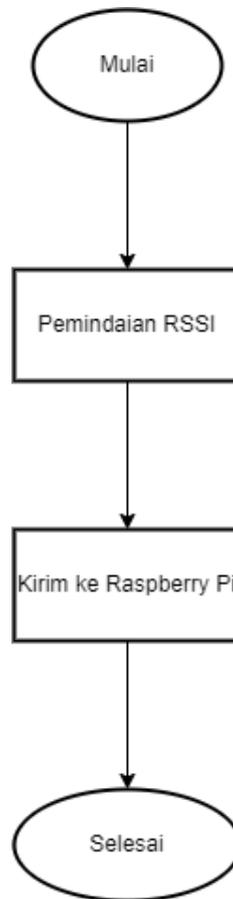
Perangkat lunak pada penelitian ini akan digunakan untuk mendukung proses pengambilan himpunan data, pengiriman data, pelatihan data menggunakan pembelajaran mesin

SVM, pengujian sistem, dan analisis luaran sistem. SVM adalah salah satu algoritma pembelajaran mesin yang terbaik. SVM umumnya digunakan di tiga bidang utama, yaitu kategorisasi teks, pengenalan citra, dan bioinformatika. Data-data dipisahkan ke dua atau lebih kelompok. Data satu dimensi dipisahkan menggunakan titik, data dua dimensi dipisahkan menggunakan garis, sedangkan data tiga dimensi dipisahkan menggunakan bidang buatan. Untuk data lebih dari tiga dimensi bisa dipisahkan menggunakan *hyperplane* [10]. Tahapan perangkat lunak pada Raspberry Pi berfungsi untuk melatih model menggunakan pembelajaran mesin dengan metode SVM. Tahapan perangkat lunak pada Raspberry Pi berfungsi untuk melatih model menggunakan pembelajaran mesin dengan metode SVM. Tahapan perangkat lunak pada Raspberry Pi terdapat pada Gambar 2.



Gambar 2 Tahapan perangkat lunak Raspberry Pi

Tahapan perangkat lunak pada ESP32 untuk mendapatkan posisi dari target menggunakan pemindaian RSSI, kemudian data akan dikirimkan ke Raspberry Pi yang berperan sebagai server. Tahapan perangkat lunak pada ESP32 terdapat pada Gambar 3.



Gambar 3 Tahapan perangkat lunak ESP32

Data RSSI yang diperoleh dari ESP32 dibagi menjadi data latih dan data uji dengan perbandingan 70% banding 30% agar tidak terjadi *underfitting* maupun *overfitting* pada saat proses pengujian. Data yang telah dibagi akan digunakan pada tahap pelatihan menggunakan teknik SVM. Hasil pelatihan yang berupa RSSI tersebut dievaluasi berdasarkan akurasi dan *confusion matrix*. Kemudian, data-data RSSI tersebut dikonversikan ke dalam jarak yang kemudian digunakan untuk perhitungan metode *trilateration*. Pengujian akan dilakukan menggunakan model yang telah dilatih menggunakan metode pembelajaran SVM untuk menentukan ruangan tempat objek berada berdasarkan data RSSI yang telah diproses menjadi koordinat.

3. HASIL DAN PEMBAHASAN

3.1 Hubungan RSSI terhadap Jarak

Agar dapat melakukan konversi dari kekuatan sinyal menjadi satuan jarak, maka perlu diketahui hubungan dari RSSI terhadap perubahan jarak. Pengukuran ini dilakukan dalam kondisi tidak ada halangan dan jarak yang diukur adalah *line of sight*. Gambar 4 menunjukkan bahwa semakin jauh jaraknya, maka kekuatan sinyal yang diterima akan semakin lemah, walaupun hasilnya tidak linier apabila dilihat dari titik awal hingga titik akhir pengukuran.



Gambar 4 Grafik hubungan RSSI terhadap perubahan jarak

Data diukur mulai dari jarak 25 cm hingga 550 cm dengan interval 25 cm setiap pengukuran. RSSI pada kolom ketiga diperoleh dari dua puluh RSSI yang kemudian dirata-rata untuk masing-masing titiknya. Terlihat perubahan RSSI terhadap jarak yang signifikan saat jarak bernilai kurang dari atau sama dengan 100 cm. Namun, perubahan RSSI yang terjadi tidak terlalu signifikan setelah jarak melebihi 100 cm. Bahkan, pada rentang jarak 450 cm hingga 500 cm, nilai RSSI yang diperoleh nilainya hampir sama.

3.2 Pengaruh Arah Hadap

Setelah didapatkan hubungan antara jarak dengan RSSI, perlu dilakukan pengujian untuk mengetahui pengaruh arah hadap ESP32 terhadap kekuatan sinyal yang diterima agar mendapatkan hasil dengan kesalahan paling minimum pada saat menentukan posisi menggunakan metode trilaterasi. Pengujian dilakukan untuk seluruh lima ruangan dengan mengubah arah hadap ESP32 dengan variasi 8 arah mata angin, yaitu utara, timur laut, timur, tenggara, selatan, barat daya, barat, dan barat laut. Cuplikan data pengujian arah hadap untuk ruangan koridor dapat dilihat pada Tabel 3.

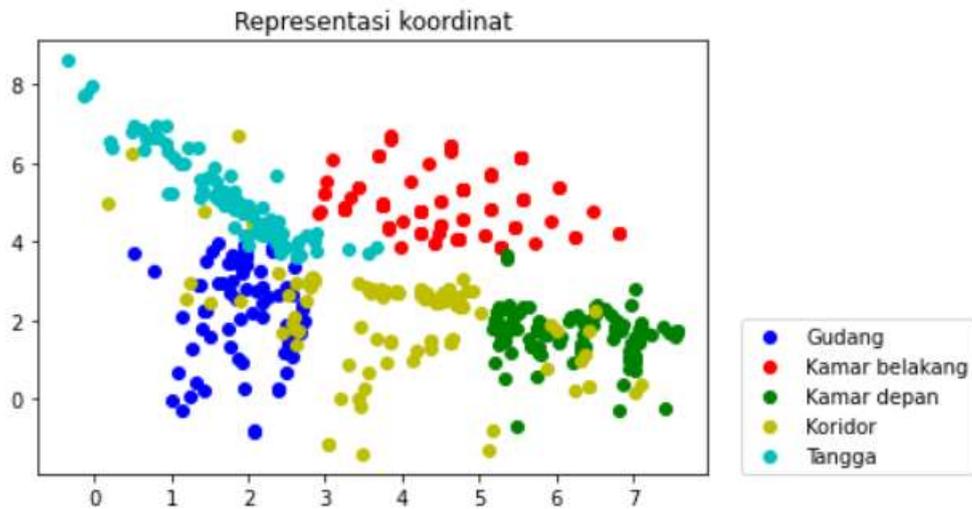
Tabel 3 Pengaruh arah hadap ESP32 terhadap trilaterasi

No.	Arah	Rerata eror (meter)
1	Utara	1.63
2	Timur laut	2.98
3	Timur	1.77
4	Tenggara	0.98
5	Selatan	0.20
6	Barat daya	0.26
7	Barat	1.08
8	Barat laut	3.67

Dapat dilihat bahwa pada Tabel 3, terdapat 8 arah yang berbeda dengan rerata eror yang berbeda juga. Mulai dari arah utara yang memiliki nilai rerata eror 1.63 meter, kemudian timur laut dengan 2.98 meter, arah timur dengan 1.77 meter, arah tenggara dengan 0.98 meter, arah selatan dengan 0.20 meter, arah barat daya dengan 0.26 meter, arah barat dengan 1.08 meter, dan arah barat laut dengan nilai rerata eror 3.67 meter. Dari 8 arah tersebut. Diperoleh nilai rerata eror minimum pada saat ESP32 target mengarah ke selatan, sedangkan nilai rerata eror maksimum didapat ketika ESP32 target mengarah ke barat laut. Perbedaan nilai eror tersebut diakibatkan oleh terhalangnya dinding dan juga sudut yang terbentuk dari arah hadap ESP32 target dengan *sink node*.

3.3 Akurasi SVM berdasarkan RSSI

Hasil akuisisi data RSSI menggunakan metode trilaterasi ditunjukkan seperti pada Gambar 5 yang diklasifikasikan menggunakan algoritma SVM. Terdapat lima ruangan yang berperan sebagai kelas untuk SVM, yaitu gudang, kamar belakang, kamar depan, koridor, dan tangga yang masing-masing memiliki warna yang berbeda untuk membedakan satu sama lain. Sumbu X pada Gambar 5 menunjukkan koordinat X, sedangkan sumbu Y menunjukkan koordinat Y.



Gambar 5 Visualisasi data RSSI

Pengujian kemudian divariasikan dengan menggunakan tiga jenis *kernel*, yaitu linier, polinomial, dan *radian basis function*. Masing-masing variasi *kernel* diuji dengan rentang nilai C dari 10 hingga 100. Jenis *kernel* dan perolehan akurasi tertinggi dapat dilihat pada Tabel 4.

Tabel 4 *Kernel* dan akurasi tertingginya

No.	Jenis <i>kernel</i>	Akurasi tertinggi (%)
1	Linier	91.33
2	Polinomial	93.06
3	rbf	93.64

Berdasarkan pengujian yang dilakukan, diperoleh *confusion matrix* SVM *multiclass* dengan *kernel* rbf yang menggunakan nilai C seperti pada Gambar 6. *Confusion matrix* berukuran 5 x 5 karena SVM memiliki lima kelas.

$$\begin{bmatrix} 18 & 0 & 0 & 0 & 1 \\ 0 & 27 & 0 & 0 & 0 \\ 0 & 0 & 46 & 0 & 0 \\ 2 & 0 & 6 & 38 & 1 \\ 0 & 1 & 0 & 0 & 33 \end{bmatrix}$$

Akurasi: 93.64
Data uji: 173

Gambar 6 *Confusion matrix kernel* rbf

3.4 Klasifikasi Ruang ketika Target Diam

Pada bagian ini, pengujian dilakukan dengan membawa ESP32 target dalam keadaan tetap di dalam satu ruangan. Pengujian ini bermaksud untuk mengetahui performa SVM untuk

melakukan klasifikasi ketika koordinat X dan Y dari hasil trilaterasi menjadi masukan SVM dalam kondisi stabil. Pengujian ini akan dilakukan pada tiap ruangan untuk memeriksa akurasi SVM pada masing-masing ruangan. Data hasil pengujian di ruangan gudang dapat dilihat pada Tabel 5. Dari 10 data X dan Y yang diperoleh, didapatkan akurasi 100% untuk klasifikasi di ruangan gudang. Hasil ini menunjukkan bahwa SVM bekerja dengan baik pada saat kondisi ESP32 target berada di ruangan tersebut.

Tabel 5 Pengujian klasifikasi dalam keadaan diam

No.	X	Y	SVM
1	2.26	1.77	Gudang
2	2.41	2.62	Gudang
3	2.2	2.2	Gudang
4	2.21	1.84	Gudang
5	2.21	1.84	Gudang
6	2.21	1.84	Gudang
7	2.21	1.84	Gudang
8	2.26	2.11	Gudang
9	2.26	2.11	Gudang
10	2.25	2.12	Gudang

3.5 Klasifikasi Ruangan ketika Target Berpindah Ruangan

Pada bagian ini, pengujian dilakukan dengan cara ESP32 target dibawa bergerak dari satu ruangan ke ruangan yang lain. Setiap sinyal yang dipancarkan oleh target akan dideteksi oleh *sink node*, kemudian dilakukan perhitungan trilaterasi sehingga diperoleh prediksi koordinat X dan Y dari target. Hasil prediksi koordinat tersebut kemudian dijadikan sebagai masukan klasifikasi ruangan bagi SVM. Pengujian ini bertujuan untuk mengetahui pengaruh pemancar sinyal yang bergerak terhadap kekuatan sinyal yang akan diterima oleh tiga *sink node*. Pada bagian ini dilakukan 10 kali pengujian untuk perpindahan dari gudang ke tangga. Cuplikan percobaan perpindahan ruangan dari gudang ke tangga dapat diamati pada Tabel 6 yang menunjukkan koordinat X dan Y, lokasi asli, prediksi SVM, dan hasil yang membandingkan prediksi SVM dengan lokasi asli target.

Tabel 6 Cuplikan data perpindahan ruangan

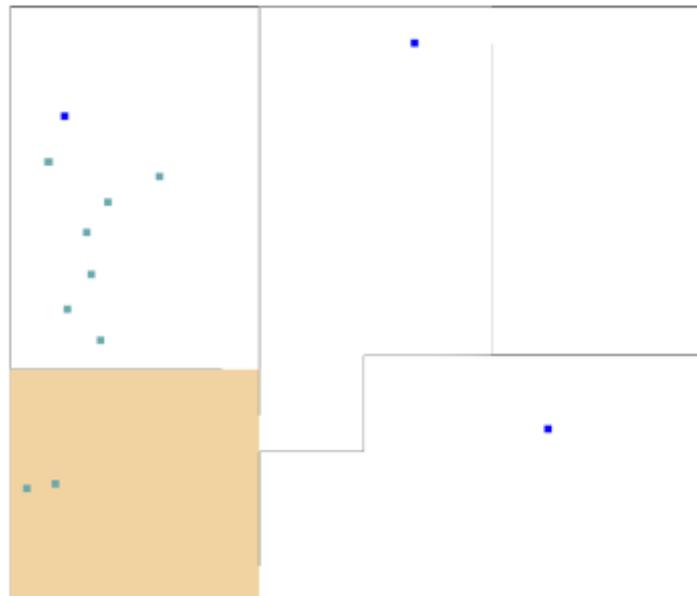
No.	X	Y	Lokasi asli	Prediksi SVM	Hasil
1	0.41	1.69	Gudang	Gudang	Benar
2	0.98	3.64	Gudang	Tangga	Salah
3	1.62	1.85	Gudang	Gudang	Benar
4	0.88	2.92	Gudang	Gudang	Benar
5	0.83	2.46	Gudang	Gudang	Benar
6	1.06	2.13	Gudang	Gudang	Benar
7	0.62	3.3	Gudang	Gudang	Benar
8	0.42	1.69	Gudang	Gudang	Benar
9	0.49	5.21	Tangga	Tangga	Benar
10	-0.15	6.67	Tangga	Koridor	Salah
11	0.18	5.26	Tangga	Tangga	Benar
12	0.35	6.75	Tangga	Tangga	Benar
13	0.35	6.78	Tangga	Tangga	Benar
14	0.35	6.75	Tangga	Tangga	Benar

Pada Tabel 6, terdapat total 14 data koordinat yang diperoleh. Di antaranya terdapat 2 data yang salah, yaitu pada nomor 2 dan 10. Pada nomor 2, saat ESP32 target masih berada di gudang, hasil prediksi SVM berdasarkan trilaterasi menunjuk ke tangga. Pada kenyataannya, target masih berada di ruangan gudang. Kemudian, pada nomor 10, saat ESP32 target sudah berjalan dan berada di tangga, SVM justru menghasilkan prediksi yang menunjuk ke koridor. Dari 2 kesalahan tersebut, pada percobaan ini diperoleh akurasi klasifikasi sebesar 85.71%. Akurasi dan jumlah data pada untuk 10 kali percobaan perpindahan ruangan dari kamar belakang ke tangga dapat diamati pada Tabel 7.

Tabel 7 Data perpindahan ruangan

No.	Jumlah data	Akurasi (%)
1	20	90
2	22	86.36
3	19	89.47
4	14	85.71
5	21	100
6	15	73.33
7	20	90
8	18	94.44
9	18	72.22
10	25	80

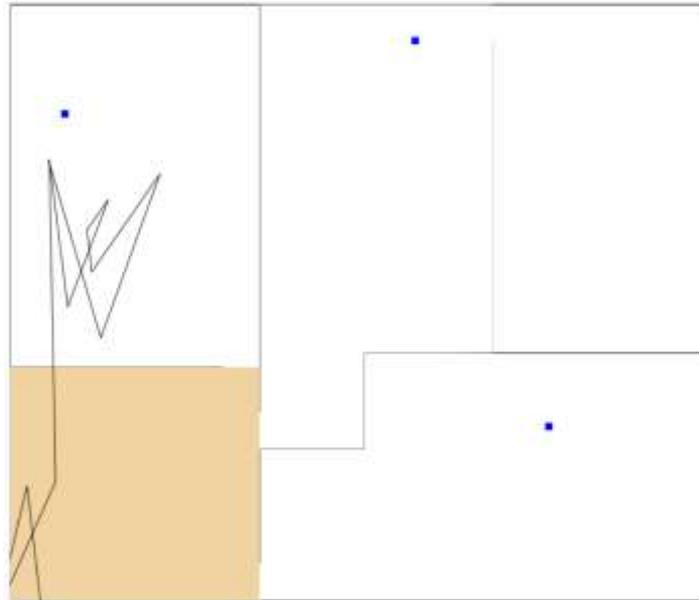
Dapat diamati pada Tabel 7 bahwa terdapat total 192 data yang diperoleh dari 10 kali percobaan dengan rerata akurasi 86.15%. Perbedaan jumlah data tiap percobaan disebabkan oleh kecepatan saat berpindah ruangan karena apabila perpindahannya terlalu cepat, kecepatan pengiriman data dari *sink node* tidak dapat mengimbangi sehingga data yang ditampilkan tidak sesuai dengan apa yang terjadi dengan kenyataan. Sebaran data untuk Tabel 7 dapat diamati pada Gambar 7 yang menunjukkan bahwa terdapat titik-titik berwarna hijau.



Gambar 7 Sebaran data perpindahan ruangan

Visualisasi perjalanan dari gudang ke tangga secara lebih jelasnya ditunjukkan pada Gambar 8 yang dapat menunjukkan di mana posisi awal dan akhir pada saat pengujian ini

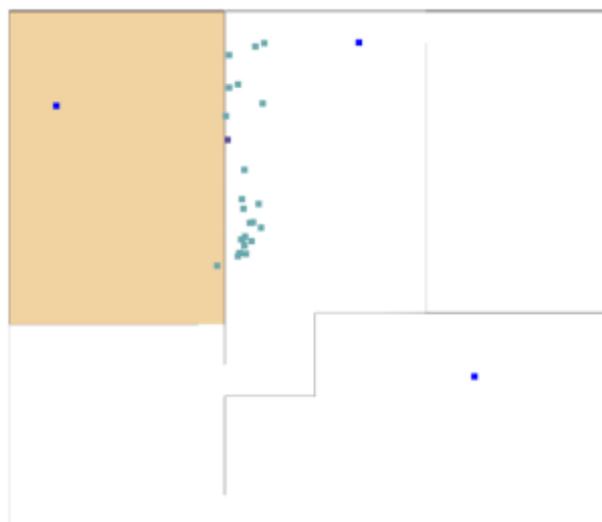
dilakukan. Selain itu, visualisasi pada Gambar 8 juga menunjukkan urutan perubahan lokasi dengan menghubungkan satu titik koordinat dengan koordinat lain menggunakan garis hitam.



Gambar 8 Perjalanan perpindahan ruangan

3.6 Klasifikasi Ruang ketika Target Berada di Tepi Ruang

Pada pengujian ini, ESP32 target akan diposisikan di tepi ruangan pada lima ruangan yang berbatasan dengan ruangan lain untuk memeriksa apakah SVM mampu melakukan klasifikasi dengan baik apabila koordinat yang diperoleh berdekatan dengan ruangan lain. Ruang yang dilakukan untuk pengujian pada Gambar 9 adalah koridor dengan ESP32 ditempatkan di sebelah kiri ruangan yang berbatasan dengan ruangan gudang. Terdapat 5 buah titik hasil triliterasi yang letaknya sangat berdekatan dengan ruangan gudang, bahkan ada sebuah titik yang loncat ke ruangan gudang.



Gambar 9 Visualisasi pengujian di tepi ruangan

Rincian data untuk pengujian di tepi ruangan disajikan dalam bentuk tabel pada Tabel 8 yang memuat koordinat X, koordinat Y, dan hasil klasifikasi oleh SVM.

Tabel 8 Data hasil pengujian tepi ruangan

No.	X	Y	Lokasi asli	SVM
1	2.87	3.09	Koridor	Koridor
2	2.97	3.06	Koridor	Koridor
3	2.95	2.96	Koridor	Koridor
4	2.91	2.88	Koridor	Koridor
5	3.06	2.66	Koridor	Koridor
6	3.16	2.73	Koridor	Koridor
7	2.96	2.84	Koridor	Koridor
8	2.93	2.88	Koridor	Koridor
9	2.89	3.05	Koridor	Koridor
10	2.61	3.21	Koridor	Gudang
11	3.03	2.67	Koridor	Koridor
12	3.02	2.67	Koridor	Koridor
13	3.04	2.9	Koridor	Koridor
14	2.92	2.37	Koridor	Koridor
15	2.94	2.49	Koridor	Koridor
16	3.13	2.43	Koridor	Koridor
17	2.95	2	Koridor	Koridor
18	2.76	0.55	Koridor	Gudang
19	2.87	0.92	Koridor	Koridor
20	2.72	1.32	Koridor	Gudang
21	2.76	0.96	Koridor	Gudang
22	3.2	0.4	Koridor	Koridor
23	3.09	0.44	Koridor	Koridor
24	3.18	1.16	Koridor	Koridor
25	2.74	1.62	Koridor	Gudang

4. KESIMPULAN

Berdasarkan pengujian dan hasil yang diperoleh, sinyal Wi-Fi yang dipancarkan oleh ESP32 memiliki respon perubahan kekuatan sinyal terhadap perubahan jarak sehingga dapat digunakan sebagai landasan untuk melakukan implementasi *indoor positioning system* yang ditingkatkan menggunakan SVM untuk klasifikasi. Sistem dapat melakukan klasifikasi ruangan pada tiga skenario, yaitu dalam keadaan diam, target berpindah ruangan, dan target berada di tepi ruangan yang berbatasan dengan ruangan lain. Akurasi hasil klasifikasi pada saat target dalam kondisi statis mencapai 100% karena sinyal yang diterima lebih stabil. Performa indoor positioning system ketika target bergerak dari ruangan satu ke ruangan yang lain memiliki akurasi sebesar 86.15%. Akurasi klasifikasi untuk membedakan target yang berada di tepi ruangan yang berbatasan langsung dengan ruangan lain mencapai 80%. Selain jarak antara target dengan sink node, kekuatan sinyal yang diterima oleh sink node juga dipengaruhi oleh arah hadap dari ESP32.

5. SARAN

Berdasarkan penelitian yang telah dilakukan, terdapat beberapa aspek yang perlu diperbaiki dan dikembangkan, yaitu perbandingan performa antara penggunaan frekuensi 2.4

GHz dengan 5.8 GHz untuk *indoor positioning system* dan penggunaan ESP32 dengan tambahan antena eksternal untuk meminimalisasi intervensi oleh dinding dan meningkatkan kestabilan kekuatan sinyal.

DAFTAR PUSTAKA

- [1] G. M. B. Oliveira *et al.*, “Comparison between MQTT and WebSocket Protocols for IoT Applications Using ESP8266,” in *2018 Workshop on Metrology for Industry 4.0 and IoT, MetroInd 4.0 and IoT 2018 - Proceedings*, Aug. 2018, pp. 236–241. doi: 10.1109/METROI4.2018.8428348.
- [2] K. Mekki, E. Bajic, and Meyer Fernand, “Indoor Positioning System for IoT Device based on BLE Technology and MQTT Protocol,” in *2019 IEEE 5th World Forum on Internet of Things (WF-IoT)*, 2019, pp. 787–792. doi: 10.1109/WF-IoT.2019.8767287.
- [3] A. Sashida, Di. P. Moussa, M. Nakamura, and H. Kinjo, “A Machine Learning Approach to Indoor Positioning for Mobile Targets using BLE Signals,” *34th International Technical Conference on Circuits/Systems, Computers and Communications, ITC-CSCC 2019*, Jun. 2019, doi: 10.1109/ITC-CSCC.2019.8793423.
- [4] P. Sthapit, H.-S. Gang, and J.-Y. Pyun, “Bluetooth Based Indoor Positioning Using Machine Learning Algorithms,” in *2018 IEEE International Conference on Consumer Electronics - Asia (ICCE-Asia)*, 2018, pp. 206–212. doi: 10.1109/ICCE-ASIA.2018.8552138.
- [5] H. A. Al-Jamimi and A. Al-Roubaiey, “Hybrid Modelling Based on SVM and GA for Intelligent Wi-Fi-based Indoor Localization System,” in *2019 11th International Conference on Electronics, Computers and Artificial Intelligence (ECAI)*, 2019, pp. 1–6. doi: 10.1109/ECAI46879.2019.9042102.
- [6] H. A. Abbas, N. W. Boskany, K. Z. Ghafoor, and D. B. Rawat, “Wi-Fi Based Accurate Indoor Localization System using SVM and LSTM Algorithms,” in *Proceedings - 2021 IEEE 22nd International Conference on Information Reuse and Integration for Data Science, IRI 2021*, 2021, pp. 416–422. doi: 10.1109/IRI51335.2021.00065.
- [7] Shuai Zhang, Jiming Guo, Wei Wang, and Jiyuan Hu, “Indoor 2.5D Positioning of WiFi Based on SVM,” in *2018 Ubiquitous Positioning, Indoor Navigation and Location-Based Services (UPINLBS)*, 2018, pp. 1–7. doi: 10.1109/UPINLBS.2018.8559903.
- [8] D. Eridani and E. D. Widiyanto, “Performance of Sensors Monitoring System using Raspberry Pi through MQTT Protocol,” in *2018 International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, 2018, pp. 587–590. doi: 10.1109/ISRITI.2018.8864473.
- [9] O. Barybin, E. Zaitseva, and V. Brazhnyi, “Testing the Security ESP32 Internet of Things Devices,” *2019 IEEE International Scientific-Practical Conference: Problems of Infocommunications Science and Technology, PIC S and T 2019 - Proceedings*, pp. 143–146, Oct. 2019, doi: 10.1109/PICST47496.2019.9061269.
- [10] A. Kowalczyk, *Support Vector Machines Succinctly*. Morrisville, North Carolina: Syncfusion, 2017. Accessed: Apr. 13, 2022. [Online]. Available: <https://www.syncfusion.com/succinctly-free-ebooks/support-vector-machines-succinctly>