



Pengembangan Metode Penyelesaian Permasalahan Feature-Based SLAM berbasis Adaptive Extended Kalman Filter, Fuzzy Inference System, dan Particle Swarm Optimization

Hiero Kusuma¹, Heru Suwoyo^{1*}, Julpri Andika¹

¹*Teknik Elektro, Universitas Mercu Buana,
Jl. Meruya Selatan, Jakarta 11650, Indonesia*

*Email Penulis Koresponden: heru.suwoyo@mercubuana.ac.id

Abstrak (TNR 10 Bold Italic):

Objektivitas dari menyelesaikan permasalahan Simultaneous Localization and Mapping pada robot bergerak adalah menaksirkan lintasan robot dan secara simultan memodelkan peta lingkungan. Pada kasus SLAM 2-dimensi berbasis fitur, peta yang dimaksud adalah menaksirkan lokasi semua fitur pada lingkungan dalam bentuk koordinat kartesius. Umumnya penaksiran dilakukan dengan cara memanfaatkan filter berbasis gaussian, seperti Extended Kalman Filter. Pada penerapan konvensional, kebisingan statistik baik pada mean dan kovarian untuk kontrol dan pengukuran, ditentukan diawal untuk tetap selama proses penaksiran. Pada kasus yang mengharuskan ketepatan tinggi, hal ini berdampak pada kinerja filter yang bisa saja menunjukkan divergensi. Atas dasar ini, EKF dikembangkan dengan menambahkan kemampuan rekursif menentukan kovariansi proses Q, dan kovariansi pengukuran R dengan menerapkan Innovation Adaptive Estimation (IAE). Namun tidak jarang ketidaktepatan memetakan kondisi dinamis, membuat performansi dari Adaptif EKF (AEKF) justru mengalami degradasi. Sehingga perlu pendekatan khusus yang relevan mendukung kinerja dari algoritma. Pada penelitian ini, diusulkan Fuzzy Inference System dioptimasi dengan Particle Swarm Optimization untuk menentukan besaran perubah baik untuk Q atau pun R berdasarkan Degree of Matching. Berdasarkan hasil yang dibandingkan, usulan ini memberikan performansi yang lebih baik berdasarkan RMSE saat R tetap dan Q rekursif. Hal ini dibuktikan dengan terdapatnya penurunan RMSE untuk seluruh parameter uji, khususnya pada nilai estimasi koordinat x untuk posisi robot, dengan penurunan sebesar 52.57%.

This is an open access article under the [CC BY-NC](https://creativecommons.org/licenses/by-nc/4.0/) license



Kata Kunci:

*SLAM;
IAE;
FIS-PSO;
RMSE;*

Riwayat Artikel:

Diserahkan 30 September, 2024
Direvisi 29 Nopember, 2024
Diterima 14 Desember, 2024

DOI:

10.22441/incomtech.v14i3.302
77

1. PENDAHULUAN

Selain memiliki kemampuan untuk melakukan pergerakan berbasis perilaku, sebuah robot otonom dipaksa untuk dapat menyelesaikan permasalahan Simultaneous Localization and Mapping [1], [2], [3], [4]. Meskipun berkenaan dengan persepsi dan bukan tentang pengendalian pergerakan, SLAM sangat bermanfaat untuk mengawali tugas-tugas navigasi lainnya seperti perencanaan jalur, dan menelusuri jalur. Tidak hanya karena lingkungan dan keadaan yang dinamis, ketidakakuratan pembacaan sensor, keterbatasan komputasi, fitur-fitur identik yang terdeteksi bersamaan, dan akumulasi error pergerakan dari robot, adalah beberapa tantangan yang memberikan motivasi tersendiri bagi para peneliti navigasi robot. Ketidaktentuan yang tidak dapat dikendalikan inilah, yang membuat penaksiran tidak cukup dengan mengandalkan pembacaan sensor. Taksiran yang tidak akurat, sangat berdampak pada kerja lainnya, seperti perencanaan jalur dan aksi pergerakan. Berdasarkan urgensi ini, filter berbasis gaussian seperti Extended Kalman Filter (EKF) [5], [6] menjadi relevan untuk diterapkan.

Pada dasarnya, pengoperasian EKF dapat secara optimal dilakukan jika model sistem yang akurat tersedia. Model ini mencakup model pergerakan yang mencakup didalamnya penggambaran bagaimana robot bergerak dan bagaimana sensor membaca pergerakan tersebut. Selain itu, model pengukuran yang merepresentasikan bagaimana sensor, seperti LiDAR, beroperasi juga sangat menentukan optimalitas dari EKF pada kasus SLAM. Pemodelan pengukuran yang tidak tepat membuat akurasi dari taksiran menjadi menurun. Faktor lain yang mendukung optimalitas dari kinerja EKF adalah matrik kovariansi proses yang menggambarkan ketidaktentuan pada pergerakan, dan juga matrik kovariansi pengukuran yang menggambarkan ketidaktentuan dari pengukuran sensor yang digunakan. Penentuan kovariansi yang tidak tepat membuat kualitas estimasi menurun. Sedangkan pada penerapan konvensional dua jenis kovariansi ini ditentukan diawal dan berlaku tetap. Singkatnya, dengan kondisi dinamis yang tidak tentu, membuat penentuan besaran kovariansi ini tidak relevan. Sehingga, cara konvensional EKF seperti ini tidak lagi direkomendasikan pada penerapannya menyelesaikan permasalahan SLAM [7], [8], [9], [10], [11].

Dengan mengacu pada beberapa tantangan inilah, EKF pada penerapan SLAM terus berkembang. Dengan menganggap bahwa rata-rata dan kovariansi kebisingan harus secara berkala diperbarui, Maximum Likelihood Estimation (MLE) diterapkan [12], [13], [14]. Penerapan ini bertujuan untuk menaksirkan kebisingan statistik dengan memaksimalkan likelihood pada residual. Selain tertuju pada taksiran untuk kovariansi, juga digunakan untuk memaksimalkan ketepatan rata-rata akibat adanya potensi bias yang terjadi pada proses maupun pengukuran. Selain MLE, Maximum A Posterior (MAP) [13], [15], [16] juga dikenalkan untuk membuat EKF menjadi adaptif. Melanjutkan MLE, MAP menaksirkan kebisingan statistik dengan memperhitungkan informasi prior untuk memaksimalkan perhitungan estimasi. Selain itu, juga terdapat metode yang memanfaatkan beberapa kovariansi yang berbeda dan memilih satu diantara metode terbaik berdasarkan kemampuan menaksirkan, metode ini dinamai dengan Multiple Model Adaptive Estimation (MMAE) [17], [18], [19]. Selanjutnya, bentuk adaptif dari

EKF juga dapat ditentukan dengan penerapan Innovation Adaptive Estimation, yang bekerja berdasarkan residual dalam menentukan besaran rekursif dari kovariansi proses Q atau kovariansi pengukuran R.

Meskipun dianggap memberikan kemudahan dalam penerapan, Innovation Adaptive Estimation tidak lepas dari tantangan seperti stabilitas filter yang terganggu ketika terdapat perbedaan signifikan pada pengukuran, atau karakteristik dari proses maupun pengukuran yang dinamis yang membuat level keakuratan estimasi terganggu. Sehingga, tidak jarang untuk mengantisipasi degradasi dan divergensi pada kinerja filter, IAE didukung dengan pendekatan tertentu. NeuroFuzzy dimanfaatkan untuk menjamin kestabilan dari IAE dengan mengacu pada penyimpangan yang terjadi pada kovariansi pengukuran perhitungan dan nyata [20]. Meskipun telah memberikan pengaruh yang baik berupa penurunan pada RMSE taksiran, penggunaan neural network untuk mendukung fuzzy logic tidak lepas dari kebutuhan data latih dan model yang kompleks yang membuat proses taksiran menjadi lambat. Berdasarkan kekurangan ini, penelitian ini mengusulkan metode serupa yaitu Fuzzy-Particle Swarm Optimization [21], [22], [23], yang digunakan untuk menentukan besaran perubah Adj berdasarkan besar penyimpangan antara kovariansi pengukuran nyata dan teoris, yaitu Degree of Matching. Selain memiliki keunggulan berupa kesederhanaan implementasi, PSO juga menawarkan fleksibilitas dan kecepatan konvergensi. Hal ini sejalan dengan fokus dari tugas estimasi pada lokasi robot dan peta lingkungan secara simultan.

Pada penerapan ini, PSO bertugas untuk menentukan pengaturan yang tepat baik pada input, DoM, Delta DoM, dan Adj. Fuzzy Inference System (FIS) yang digunakan adalah Mamdani. Fungsi keanggotaan menggunakan model segitiga, menerapkan aturan min-max, dan defuzzifikasi centroid. Setiap terdapat DoM baru pada iterasi saat ini, Delta DoM dapat ditentukan. Besaran keduanya merupakan input yang kemudian dengan fuzzy ini, Adj ditentukan. Mengingat pengaturan fungsi keanggotaan yang rumit dan berpengaruh pada kinerja fuzzy, PSO diterapkan. Pada penerapannya, solusi kandidat titik puncak fungsi keanggotaan ditetapkan berdasarkan rentang yang didapatkan saat secara trial. Ukuran populasi ditentukan sebesar 50 dengan jumlah generasi 50. Setiap proses optimasi berlangsung, PSO memanfaatkan fungsi kebugaran yang merupakan performansi dari FIS-EKF pada penyelesaian SLAM, yang dinyatakan dalam Root Mean Square Error. Optimasi berulang jika nilai RMSE yang didapatkan tidak lebih baik dari generasi sebelumnya. Selain menjadi acuan terminasi, penentuan seperti ini untuk memastikan bahwa hasil akhir yang didapatkan adalah yang terbaik. Dengan penerapan seperti ini, kualitas solusi yang diberikan oleh metode usulan menunjukkan nilai yang lebih baik mengacu pada taksiran jalur maupun taksiran fitur pada lingkungan. Pengujian dilakukan pada dua lingkungan yang sintesis yang berbeda untuk memperkuat hasil analisa perbandingannya.

2. PSO-FIS-BASED IAE-EKF SLAM ALGORITHM

Dengan menganggap bahwa model dinamis dari sistem nonlinear adalah

$$\begin{cases} x_k = f(x_{k-1}, u_k) + \omega_{k-1} \\ z_k = h(x_k) + v_k \end{cases} \quad (1)$$

dengan karakteristik dari kebisingan statistik sebagai

$$\begin{cases} E[\omega_k] = 0, Cov[\omega_k, \omega_j] = Q_k \delta_{kj} \\ E[v_k] = 0, Cov[v_k, v_j] = R_k \delta_{kj} \\ E[\omega_k, v_k] \end{cases} \quad (2)$$

formulasi adaptif EKF yang ditetapkan berdasarkan Innovation Adaptive Estimation (IAE) dapat dipaparkan sebagai berikut. Ketika sistem adalah Gaussian, maka pada tahap prediksi berlaku (3) dan (4)

$$\hat{x}_{k|k-1} = f(\hat{x}_{k-1|k-1}, u_k) + q_{k-1} \quad (3)$$

$$P_{k|k-1} = F P_{k-1|k-1} F^T + Q_{k-1} \quad (4)$$

dimana $f(\cdot)$ adalah fungsi transisi yang menerapkan model pergerakan, dan F adalah hasil turunan parsial dari fungsi transisi terhadap state, yang biasa disebut dengan matrik jacob. Selanjutnya dengan mengetahui pengukuran actual, z_k , error residual atau inovasi dapat ditentukan. Penentuan ini diawali dengan memperhitungkan nilai pengukuran terprediksi, $\hat{z}_{k|k-1}$, untuk selanjutnya dianggap sebagai pembanding dari z_k . Kedua perhitungan ini dapat dilihat pada (5) dan (6) secara berurutan.

$$\hat{z}_{k|k-1} = h(\hat{x}_{k|k-1}) + r_k \quad (5)$$

$$e_{k|k-1} = z_k - \hat{z}_{k|k-1} \quad (6)$$

Error residual (6) ini memiliki korespondensi kovariansi, S_k , yang ditetapkan dengan menerapkan perhitungan pada (7).

$$S_k = H P_{k|k-1} H^T + R_k \quad (7)$$

di mana H adalah matriks jacob pengukuran yang dihitung dengan menentukan turunan parsial $h(\cdot)$ terhadap state yang terprediksi (3). Dengan didapatkannya seluruh perhitungan dari (1) – (7), gain dari EKF dapat selanjutnya ditentukan. Perhitungan ini diwakili oleh (8).

$$K_k = P_{k|k-1} H^T S^{-1} \quad (8)$$

Gain ini yang kemudian digunakan untuk pembaruan state terprediksi $\hat{x}_{k|k-1}$ dan $P_{k|k-1}$ dengan perhitungan yang terdapat pada (9) dan (10).

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k e_{k|k-1} \quad (9)$$

$$P_{k|k} = P_{k|k-1} (I - K_k H) \quad (10)$$

Pada kasus penyelesaian SLAM, filter bertugas untuk melakukan estimasi terhadap posisi dan juga fitur-fitur lingkungan berdasarkan data sensor terbaca. Sehingga data yang disediakan oleh odometer, IMU, dan LiDAR dipadukan dengan data teoritis atau modelnya oleh filter. Pada penyelesaian SLAM semua model diformulasikan kembali dalam bentuk waktu diskrit. Adapun untuk model pergerakan, yang dihitung dengan mendekati analisa kinematik pada robot dengan penggerak roda sebelah kanan dan kiri secara differensial, dijabarkan sebagai berikut (lihat (11) dan (12)).

$$\begin{bmatrix} x_{r,k} \\ y_{r,k} \\ \theta_{r,k} \end{bmatrix} = \begin{bmatrix} x_{r,k-1} \\ y_{r,k-1} \\ \theta_{r,k-1} \end{bmatrix} + \begin{bmatrix} \left(R + \frac{W}{2}\right) (\sin(\theta_{r,k-1} + \alpha) - \sin(\theta_{r,k-1})) \\ \left(R + \frac{W}{2}\right) (-\cos(\theta_{r,k-1} + \alpha) + \cos(\theta_{r,k-1})) \\ \alpha \end{bmatrix} \quad (11)$$

$$\begin{bmatrix} x_{r,k} \\ y_{r,k} \\ \theta_{r,k} \end{bmatrix} = \begin{bmatrix} x_{r,k-1} \\ y_{r,k-1} \\ \theta_{r,k-1} \end{bmatrix} + u_l \begin{bmatrix} \cos(\theta_{r,k-1}) \\ \sin(\theta_{r,k-1}) \\ 0 \end{bmatrix} \quad (12)$$

di mana (11) adalah model pergerakan dari robot ketika kondisi input, $u = [u_l, u_r]^T$ adalah berbeda. Sedangkan pada (12), menunjukkan kondisi yang berbeda yaitu ketika kedua besaran kendali kiri dan kanan adalah sama. Model pergerakan ini yang selanjutnya diperankan sebagai fungsi transisi $f(.)$ yang terdapat pada proses prediksi filter pada (3). Tidak hanya model pergerakan, model pengukuran juga ditetapkan dengan asumsi bahwa robot menggunakan laser yang ditempatkan pada posisi yang berjarak sebesar d_{ls} di depan tepat titik *Centre of Mass*. Sehingga dengan mengetahui, posisi spatial robot $[x_r, y_r]$ maka posisi dari sensor pada kerangka global dapat ditentukan sebagai (13)

$$\begin{bmatrix} x_{ls} \\ y_{ls} \end{bmatrix} = \begin{bmatrix} x_r \\ y_r \end{bmatrix} + d_{ls} \begin{bmatrix} \cos(\theta_r) \\ \sin(\theta_r) \end{bmatrix} \tag{13}$$

Dengan demikian model pengukuran dalam bentuk waktu diskrit yang menggambarkan kerja dari sebuah LiDAR dapat dihitung dengan (15).

$$\begin{bmatrix} \delta_L^i \\ \beta_L^i \end{bmatrix} = \begin{bmatrix} \sqrt{(x_{L,x}^i - x_{ls})^2 + (x_{L,y}^i - y_{ls})^2} \\ \arctan\left(\frac{x_{L,y}^i - y_{ls}}{x_{L,x}^i - x_{ls}}\right) - \theta_r \end{bmatrix} \tag{14}$$

$$z_i = \begin{bmatrix} \delta_L^i \\ \beta_L^i \end{bmatrix} + \begin{bmatrix} r_\delta \\ \delta_\beta \end{bmatrix} \tag{15}$$

di mana posisi fitur ke- i direpresentasikan dengan $(x_{L,x}^i, x_{L,y}^i)$ dan setiap pengukuran, z_i , LiDAR memberikan dua jenis informasi, berupa jarak δ_L^i dan β_L^i . Pada praktiknya, model pengukuran ini digunakan untuk mendapat nilai prediksi pengukuran yang dinyatakan sebagai $h(.)$ pada (5). Untuk membuat penerapan fuzzy logic menjadi relevan pada EKF-SLAM terlebih dahulu IAE diterapkan sehingga EKF-SLAM berlaku adaptif. Penerapan ini pada dasarnya adalah untuk membuat nilai sebenarnya dari kovariansi urutan inovasi (7) sesuai dengan nilai aktualnya, C_{inn_k} . Di mana C_{inn_k} diperkirakan berdasarkan perhitungan sampel kovariansi dengan mencari rata-rata di dalam moving window dengan ukuran N sebagai berikut (lihat (16)).

$$C_{inn_k} = \frac{1}{N} \sum_{i=k-N+1}^k inn_k inn_k^T \tag{16}$$

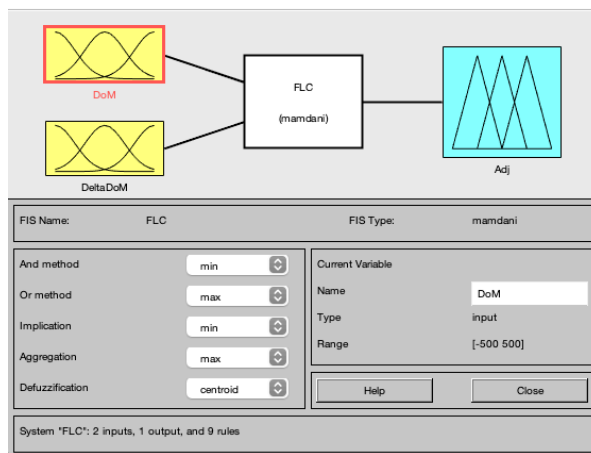
Jika C_{inn_k} memiliki ketidaktentuan berdasarkan S_k maka pengaturan dilakukan untuk melakukan koreksi penyimpangan. Besaran penyimpangan ini disebut dengan Degree of Matching (DoM) yang didefinisikan (16)

$$DoM_k = S_k - C_{inn_k} \tag{17}$$


Mengacu pada (7) peningkatan yang terjadi pada R berdampak langsung pada S_k yang membuat DoM meningkat. Dengan demikian, didapatkan konsep kerja dari fuzzy logic yaitu memastikan terdapat pengaturan R atau Q selanjutnya, berdasarkan nilai DoM. Sederhananya jika DoM mendekati 0 maka tidak diperlukan perbaikan elemen yang terdapat pada R , jika DoM tinggi maka elemen R diturunkan, dan sebaliknya jika DoM rendah maka R ditingkatkan. Selain merujuk pada nilai DoM, pada penelitian ini adaptif Q dan R juga dihitung berdasarkan Delta DoM yang didefinisikan sebagai berikut (16)

$$Delta DoM_k = DoM_k - DoM_{k-1} \tag{15}$$


di mana pada pengoperasian awal elemen pada DoM_{k-1} diasumsikan 0.




Gambar 1 Pengaturan Fuzzy pada IAE EKF-SLAM Dengan menggunakan representasi segitiga, fungsi keanggotaan pada fuzzy awalnya ditentukan pada Gambar 2 dan hasilnya dipaparkan pada bagian hasil.



(a)



(b)



(c)

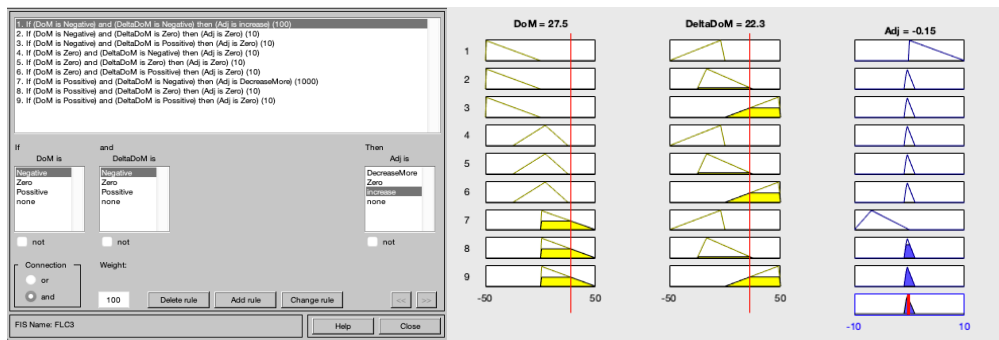
Gambar 2 Pengaturan Input (a) DoM, (b) Delta DoM, dan output (c) Adj Membership Function

Terlihat pada Gambar 2, terdapat output Adj yang merupakan variabel pengatur yang berperan pada pengaturan Q, saat R dianggap tetap atau R saat Q dianggap tetap. Pengaturan ini dapat dilihat persamaan berikut (14) dan (15)

$$Q_{k+1} = Q_k Adj Q_k^T \tag{14}$$


$$R_{k+1} = R_k + Adj R_k \tag{15}$$

Adapun rule yang mengatur penentuan Adj dipaparkan sebagai berikut



Gambar 3 Rule pada Fuzzy IAE EKF SLAM

Seperti yang terlihat pada Gambar 3, terdapat 9 rules yang mengatur fuzzy inference dalam menentukan besaran Adj berdasarkan nilai DoM dan Delta DoM. Dengan cara trial setting dilakukan pada fungsi keanggotaan. Namun hasil yang didapatkan tidak lebih baik bahkan dibandingkan dengan EKF. Hal ini memperkuat bahwa penerapan fuzzy tidak direkomendasikan tanpa adanya pendekatan khusus. Pada penelitian ini, pendekatan yang dimaksud adalah mengadopsi metode optimasi heuristic yaitu Particle Swarm Optimization



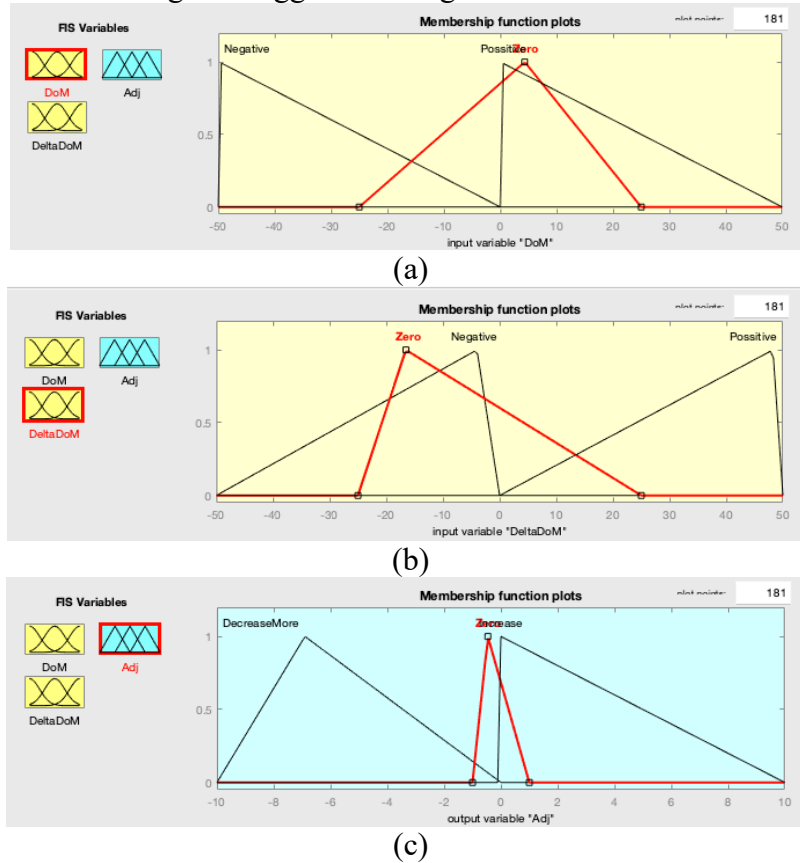
Gambar 4 Penentuan Jumlah Solusi Kandidat

Pada penerapan Particle Swarm Optimization (PSO), secara iteratif solusi kandidat dioptimalkan. Pada penelitian ini terdapat 9 kandidat yang masing-masingnya ada mbf1, mbf2, mbf3, yang dianggap adalah puncak-puncak fungsi keanggotaan yang terdapat pada DoM. Berikutnya kandidat mbf4, mbf5, dan mbf6 yang merupakan puncak-puncak segitiga pada input Delta DoM. Sedangkan mbf7, mbf8, dan mbf9 adalah yang terdapat pada Adj. Sembilan posisi inilah yang optimalkan dengan PSO secara bersamaan. Optimalitas dari penentuan nilainya diwakili oleh nilai RMSE FIS-IAE EKF SLAM, atau yang biasa disebut dengan fitness. Pada parameterisasi PSO, masing-masing mbf memiliki rentang yang berbeda-beda seperti yang terlihat pada Tabel 1.

Tabel 1 Daftar Rentang masing-masing kandidat solution

Solusi Kandidat	Rentang
mbf1	[-50,0]
mbf2	[-25,25]
mbf3	[0, 50]
mbf4	[-50,0]
mbf5	[-25,25]
mbf6	[0,50]
mbf7	[-10,0]
mbf8	[-5,5]
mbf9	[0,10]

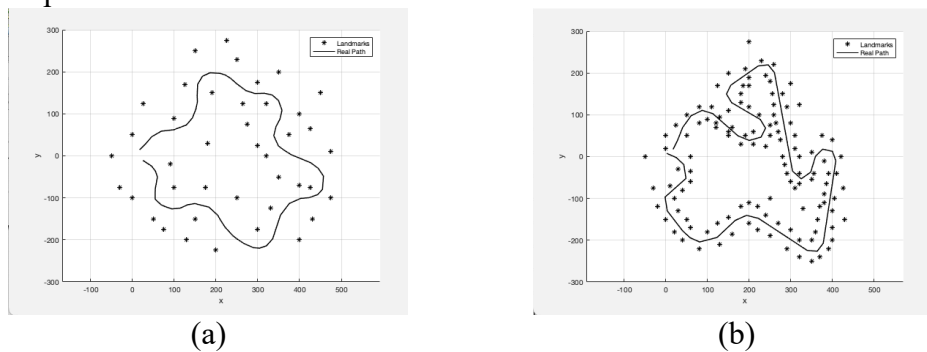
Pada penelitian ini beberapa parameter yang digunakan pada PSO antara lain adalah iterasi maximum adalah 50, jumlah populasi adalah 100, weight adalah 1, c1 adalah 1.775, dan c2 adalah 2.8. Mengacu pada pengaturan ini dan mengikuti konsep PSO didapatkan bentuk fungsi keanggotaan sebagai berikut



Gambar 5 Fungsi Keanggotaan DoM, Delta DoM, dan Adj setelah dioptimasi dengan PSO

3. HASIL DAN PEMBAHASAN

Pada pengujian metode yang diusulkan terdapat dua jenis lingkungan uji yang digunakan. Adapun bentuk dari lingkungan uji yang sekigus dijadikan referensi terlihat pada Gambar 4.



Gambar 4. Referensi Jalur dan Lokasi Fitur pada Lingkungan

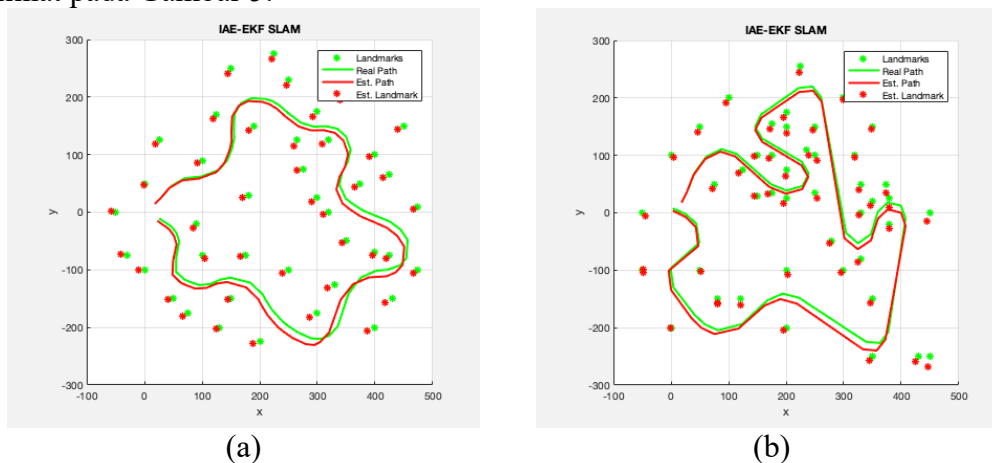
Pada pengujian ini, besaran kebisingan statistik baik untuk proses maupun pengukuran ditetapkan. Adapun untuk lingkungan penetapannya adalah sebagai berikut

$$\begin{aligned} q_0 &= [0.1, 0.2] \\ Q_0 &= \text{diag}(q_0) \\ r_0 &= [0.2, 1\pi/180] \\ R_0 &= \text{diag}(r_0) \end{aligned}$$

Sedangkan untuk kasus penyelesaian kedua dijabarkan sebagai berikut

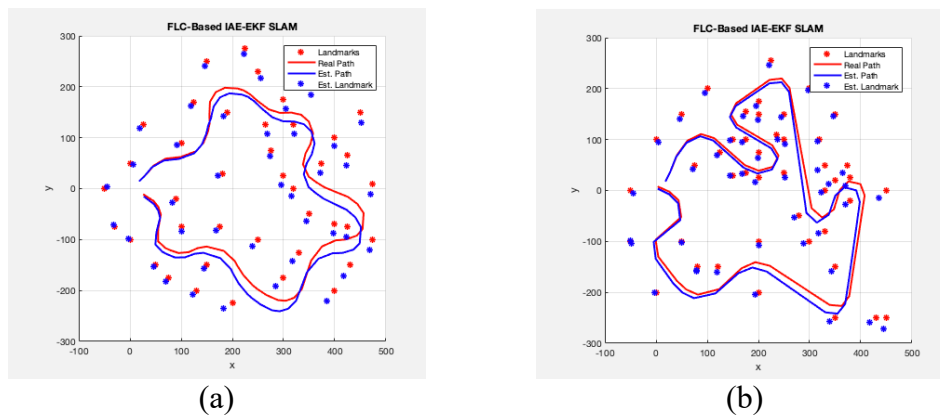
$$\begin{aligned} q_0 &= [0.1, .4] \\ Q &= \text{diag}(q_0) \\ r_o &= [0.34; 0.1 * \pi/180] \\ R &= \text{diag}(r_o) \end{aligned}$$

Pengujian dengan menggunakan MATLAB 2017a pada computer dengan spesifikasi berikut: Processor: 3.6 GHz Quad-Core Intel Core i3; Graphics: intel UHD Graphic 630 1563, dengan memori: 8 GB 2667 MHz DDR4. Awalnya pengujian dilakukan dengan mempertahankan nilai kovarians Q dan R selama proses penyelesaian permasalahan SLAM. Adapun hasil yang didapatkan dapat dilihat pada Gambar 5.



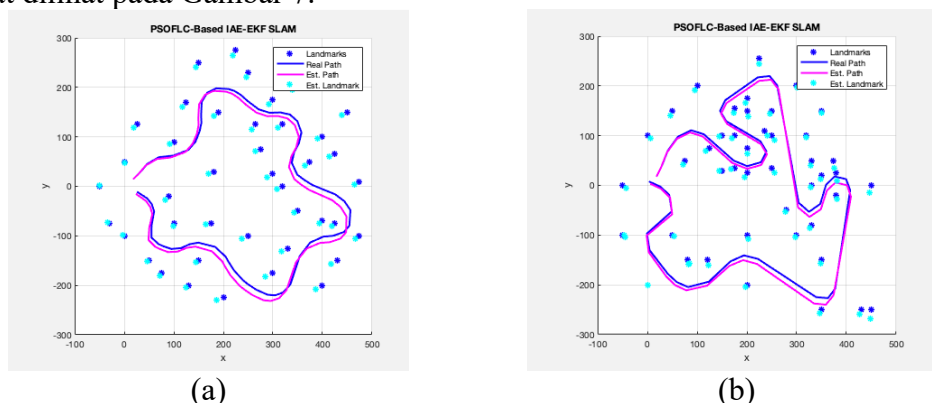
Gambar 5. Performansi EKF-SLAM pada (a) kasus pertama (b) pada kasus kedua

Sekilas, terlihat pada Gambar 5 EKF-SLAM mampu menyelesaikan permasalahan SLAM dengan baik secara visual. Namun jika diperhatikan dengan seksama terjadi penyimpangan taksiran jalur yang cukup besar yang ditunjukkan EKF-SLAM pada saat menyelesaikan kasus pertama. Hal ini semakin terlihat ketika penyelesaian permasalahan kedua, yaitu pada saat menaksirkan jalur setelah melewati tungkungan ke tujuh. Meskipun wajar karena ketidakpastian kovariansi yang meningkat saat level dinamis proses meningkat, namun permasalahan ini dapat diminimalisir. Pada percobaan kedua IAE-EKF-SLAM didukung dengan penerapan FLC pengaturan $mbf1 = -25$, $mbf2 = 0$, $mbf3 = 25$, $mbf4 = -25$, $mbf5 = 0$, $mbf6 = 25$, $mbf7 = -5$, $mbf8 = 0$, dan $mbf9 = 5$ pada pengaturan fungsi keanggotaan DoM, Delta DoM, dan Adj. Kemudian dengan menganggap bahwa pengendalian hanya berpengaruh pada Q karena R tetap, hasil dari percobaan ini dapat dipaparkan pada Gambar 6.



Gambar 6. Performansi FLC-Based IAE-EKF SLAM pada (a) kasus pertama (b) pada kasus kedua

Dengan secara taktis membandingkan Gambar 5 dan Gambar 6, didapatkan dasar bahwa pengaturan yang tidak tepat justru berpengaruh buruk pada performansi EKF-SLAM. Hal ini ditunjukkan pada Gambar 6(a) ketika terdapat kovariansi rekursif Q yang ditentukan berdasarkan DoM dan Delta DoM melalui fuzzy logic. Alih-alih didapatkan performansi yang baik, dengan tidak memperhatikan pengaturan fungsi keanggotaan baik input maupun output, penyimpangan taksiran menjadi lebih besar. Tidak hanya terdapat pada kasus penyelesaian pertama, penyimpangan taksiran pada jalur dan peta juga terjadi ketika Fuzzy Logic diterapkan pada penyelesaian kasus kedua. Meskipun hanya menguji Q dengan R tetap, pernyataan ini sudah sangat cukup menunjukkan urgensi perlunya pengaturan fungsi keanggotaan secara akurat. Atas dasar inilah, pada penelitian ini diusulkan penerapan PSO dalam upaya mengoptimasi lokasi puncak fungsi keanggotaan input dan output. Hasil pengaturan yang dihasilkan cukup ekstrim (lihat Gambar 2 dan 5), yang menunjukkan bahwa pengaturan sebelumnya sangatlah tidak disarankan. Melanjutkan pengujian berikutnya, PSO dilibatkan untuk mendukung perhitungan Fuzzy Logic untuk Q saat R tetap pada bentuk adaptif dari EKF-SLAM. Dengan mengacu pada rentang yang telah ditentukan (Tabel 1), PSO dioperasikan dengan fitness RMSE pada FLC-Based IAE-EKF SLAM. Adapun hasil dari percobaan ini dapat dilihat pada Gambar 7.



Gambar 7 Performansi PSO-FLC-Based IAE-EKF SLAM pada (a) kasus pertama (b) pada kasus kedua

Tidak hanya meningkat dari capaian yang ditunjukkan oleh FLC-Based IAE-EKF SLAM, dengan optimasi ini peningkatan taksiran juga melampaui dari yang

dihasilkan tanpa FLC. Hasil seperti ini menunjukkan bahwa, permasalahan akan pengaturan yang tepat pada FLC-Based IAE-EKF SLAM dapat teratasi dengan baik. Meskipun sulit untuk membandingkan metode yang lebih baik dari hasil taksiran jalur yang ditunjukkan oleh Gambar 5 dan Gambar 7, rekatnya taksiran dengan data aktual untuk semua lokasi fitur yang tersedia pada lingkungan, cukup untuk menunjukkan bahwa PSO telah berperan dengan sangat baik. Untuk menguatkan analisa dan pernyataan ini Tabel 2 disajikan.

Tabel 2 Perbandingan RMSE EKF-SLAM, FIS-Based IAE-EKF, PSO-FIS-Based IAE-EKF SLAM (kasus 1)

Metode	RMSE x-Path	RMSE y-Path	RMSE theta-Path	RMSE x-Coord Map	RMSE y-Coord Map
EKF-SLAM	48.1511	61.7797	0.000386	8.74634	5.75274
FIS-Based IAE-EKF	41.5655	275.1766	0.002679	7.07575	13.79661
PSO-FIS-Based IAE-EKF	37.0288	71.022	0.000189	8.11478	5.08374

Sedangkan untuk perbandingan RMSE pada kasus kedua dapat dilihat pada Tabel 3. Meskipun pada kasus pertama baru dapat menurunkan nilai RMSE, tetapi PSO-FIS-Based IAE-EKF SLAM telah berhasil menunjukkan penurunan hampir diseluruh ukuran (perhatikan Tabel 3).

Tabel 3 Perbandingan RMSE EKF-SLAM, FIS-Based IAE-EKF, PSO-FIS-Based IAE-EKF SLAM (kasus 2)

Metode	RMSE x-Path	RMSE y-Path	RMSE theta-Path	RMSE x-Coord Map	RMSE y-Coord Map
EKF-SLAM	8.73192	67.9778	0.000469	3.62181	8.17731
FIS-Based IAE-EKF	31.9941	72.9941	0.000609	6.75811	8.32166
PSO-FIS-Based IAE-EKF	4.5903	66.5293	0.000467	3.61892	8.10063

4. KESIMPULAN

Pada penelitian ini PSO digunakan untuk mendukung peningkatan kinerja dari adaptif EKF. Peningkatan yang dimaksud adalah memperbaiki akurasi algoritma dalam menaksirkan jalur dan lokasi dari seluruh fitur yang tersedia di lingkungan, atau yang biasa disebut dengan penyelesaian permasalahan Simultaneous Localization and Mapping. Berbeda seperti penerapan konvensional, pada penelitian ini peran PSO menjamin bahwa besaran kebisingan statistik, dapat ditaksirkan secara rekursif sesuai dengan perubahan proses dan pengukuran yang terjadi. Dengan memanfaatkan kovariansi residual dan prinsip , ketidakcocokkan dapat menggambarkan penyimpangan yang terjadi oleh kovariansi teoritikal merujuk pada sample kovariansi aktual, yang ditaksirkan berdasarkan rata-rata rata-rata di dalam moving window. Mengacu pada besaran inilah, PSO bekerja menentukan pengatur, Adj, yang berperan untuk secara langsung membuat Q atau

R rekursif. Dengan metode ini, didapatkan performansi yang lebih baik pada metode usulan dibandingkan dengan metode pendahulunya mengacu pada RMSE jalur dan lokasi semua fitur, dengan penurunan sebesar 53.57% nilai estimasi koordinat x robot.

PENGAKUAN

Penelitian ini dibiayai oleh Direktorat Riset, Teknologi, dan Pengabdian Masyarakat (DRTPM), melalui hibah penelitian skema Penelitian Tesis Megister (PTM), tahun anggaran 2024 dan didukung oleh Universitas Mercu Buana, Jakarta.

REFERENSI

- [1] D. Rodriguez-Losada, P. San Segundo, F. Matia, R. Galan, A. Jiménez, and L. Pedraza, "Dual of the factored solution to the simultaneous localization and mapping problem," *IFAC Proceedings Volumes (IFAC-PapersOnline)*, vol. 6, no. PART 1, pp. 542–547, 2007.
- [2] R. G. Reid, "Large-scale simultaneous localization and mapping for teams of mobile robots," no. July, 2016, [Online]. Available: <https://research-repository.uwa.edu.au/en/publications/large-scale-simultaneous-localization-and-mapping-for-teams-of-mo>
- [3] C. G. Prince, *Book Review: Computational Principles of Mobile Robotics*, vol. 14, no. 3. 2004. doi: 10.1023/b:mind.0000035501.55990.99.
- [4] R. Kuemmerle, "State Estimation and Optimization for Mobile Robot Navigation," pp. 1–191, 2013.
- [5] Z. Li, W. Yang, and D. Ding, "Time-Varying Noise Statistic Estimator Based Adaptive Simplex Cubature Kalman Filter," *Math Probl Eng*, vol. 2017, 2017, doi: 10.1155/2017/5349879.
- [6] Y. Tian, H. Suwoyo, W. Wang, and L. Li, "An ASVSF-SLAM Algorithm with Time-Varying Noise Statistics Based on MAP Creation and Weighted Exponent," *Math Probl Eng*, vol. 2019, pp. 28–34, 2019, doi: 10.1155/2019/2765731.
- [7] C.-H. Tseng, S.-F. Lin, and D.-J. Jwo, "Fuzzy adaptive cubature Kalman filter for integrated navigation systems," *Sensors*, vol. 16, no. 8, p. 1167, 2016.
- [8] Z. QIU, H. QIAN, and G. WANG, "Adaptive robust cubature Kalman filtering for satellite attitude estimation," *Chinese Journal of Aeronautics*, vol. 31, no. 4, pp. 806–819, 2018, doi: 10.1016/j.cja.2018.01.023.
- [9] Z. Gao, D. Mu, Y. Zhong, C. Gu, and C. Ren, "Adaptively random weighted cubature kalman filter for nonlinear systems," *Math Probl Eng*, vol. 2019, 2019, doi: 10.1155/2019/4160847.
- [10] A. H. Mohamed and K. P. Schwarz, "Adaptive Kalman filtering for INS/GPS," *J Geod*, vol. 73, no. 4, pp. 193–203, 1999, doi: 10.1007/s001900050236.
- [11] A. P. Sage and G. W. Husa, "Adaptive filtering with unknown prior statistics," in *Joint Automatic Control Conference*, 1969, pp. 760–769.
- [12] B. Gao, S. Gao, G. Hu, Y. Zhong, and C. Gu, "Maximum likelihood principle and moving horizon estimation based adaptive unscented Kalman filter," *Aerosp Sci Technol*, 2018, doi: 10.1016/j.ast.2017.12.007.
- [13] X.-X. WANG, M. SUN, C. YAN, J.-C. DING, and L. ZHAO, "Adaptive UKF Filtering Algorithm Based on Maximum a Posterior Estimation and Exponential Weighting," *Acta Automatica Sinica*, vol. 36, no. 7, pp. 1007–1019, 2010, doi: 10.3724/sp.j.1004.2010.01007.
- [14] H. Suwoyo *et al.*, "Maximum likelihood estimation-assisted ASVSF through state covariance-based 2D SLAM algorithm," *Telkonnika (Telecommunication Computing Electronics and Control)*, vol. 19, no. 1, pp. 327–338, 2020, doi: 10.12928/TELKOMNIKA.V19I1.16223.
- [15] Z. L. W. X.-X. SUN and M. D. J.-C. Y. A. N. Chao, "Adaptive UKF Filtering Algorithm Based on Maximum a Posterior Estimation and Exponential Weighting," *Acta Automatica Sinica*, vol. 7, 2010.

- [16] E. Levitan and G. T. Herman, "A Maximum A Posteriori Probability Expectation Maximization Algorithm for Image Reconstruction in Emission Tomography," *IEEE Trans Med Imaging*, vol. 6, no. 3, pp. 185–192, 1987, doi: 10.1109/TMI.1987.4307826.
- [17] A. H. Mohamed and K. P. Schwarz, "Adaptive Kalman filtering for INS/GPS," *J Geod*, vol. 73, no. 4, pp. 193–203, 1999, doi: 10.1007/s001900050236.
- [18] C. Hide, T. Moore, and M. Smith, "Adaptive Kalman filtering for low-cost INS/GPS," *Journal of Navigation*, vol. 56, no. 1, pp. 143–152, 2003, doi: 10.1017/S0373463302002151.
- [19] Z. QIU, H. QIAN, and G. WANG, "Adaptive robust cubature Kalman filtering for satellite attitude estimation," *Chinese Journal of Aeronautics*, vol. 31, no. 4, pp. 806–819, 2018, doi: 10.1016/j.cja.2018.01.023.
- [20] R. Havangi, M. Ali Nekoui, and M. Teshnehlab, "Adaptive Neuro-Fuzzy extended Kalman filtering for robot localization," *Proceedings of EPE-PEMC 2010 - 14th International Power Electronics and Motion Control Conference*, vol. 7, no. 2, pp. 15–23, 2010, doi: 10.1109/EPEPEMC.2010.5606833.
- [21] M. Collotta, G. Pau, and V. Maniscalco, "A Fuzzy Logic Approach by Using Particle Swarm Optimization for Effective Energy Management in IWSNs," *IEEE Transactions on Industrial Electronics*, vol. 64, no. 12, pp. 9496–9506, 2017, doi: 10.1109/TIE.2017.2711548.
- [22] S. Agrawal and V. Shrivastava, "Particle swarm optimization of BLDC motor with fuzzy logic controller for speed improvement," *8th International Conference on Computing, Communications and Networking Technologies, ICCCNT 2017*, 2017, doi: 10.1109/ICCCNT.2017.8204006.
- [23] A. Adriansyah, H. Suwoyo, and Y. Tian, "Jurnal Teknologi IMPROVING ROBOT," vol. 3, pp. 119–126, 2019.