

BAB II

TINJAUAN PUSTAKA DAN DASAR TEORI

2.1. Tinjauan Pustaka

Integrasi Firefly Algorithm dengan Improved Particle Swarm Optimization (IPSO) telah diajukan oleh Mohammadi, dkk. (2019) untuk optimasi penjadwalan beban kerja pada sistem komputasi terdistribusi. Data penelitian menunjukkan peningkatan efisiensi pemanfaatan sumber daya serta penurunan rata-rata beban dan waktu respons tugas melalui pendekatan multi-tujuan. Dalam metode tersebut, Firefly Algorithm digunakan untuk menghindari jebakan solusi lokal, sedangkan IPSO dimanfaatkan untuk melakukan eksplorasi ruang solusi secara global. Namun, IPSO memiliki kelemahan berupa sensitivitas terhadap kondisi awal populasi partikel yang dapat memengaruhi konsistensi hasil optimasi (Al-qaness dkk., 2021). Kelemahan ini membuka peluang pengembangan metode optimasi yang lebih stabil dan adaptif, khususnya untuk sistem prediktif berbasis data. Oleh karena itu, penelitian ini menawarkan integrasi ANFIS dengan dua algoritma optimasi secara berlapis, yaitu Particle Swarm Optimization (PSO) untuk mengoptimalkan parameter fungsi keanggotaan fuzzy pada lapisan pertama, dan Firefly Algorithm untuk mengoptimalkan parameter konsekuen pada lapisan keempat. Hasil yang diharapkan adalah model prediksi ANFIS–PSO–Firefly yang lebih adaptif, efisien, dan andal dalam pengolahan data.

Metode hibrida Firefly Algorithm–Particle Swarm Optimization (FAPSO) dikembangkan oleh Xia, dkk. (2018) untuk menggabungkan kelebihan FA dan PSO dalam menjelajahi serta memanfaatkan ruang solusi pada permasalahan optimasi (Xie dkk., 2023). Populasi dibagi menjadi dua subpopulasi yang masing-masing menggunakan mekanisme FA dan PSO, kemudian saling bertukar informasi ketika pencarian solusi mengalami kebuntuan. Ruang pencarian juga dibagi ke dalam beberapa subregion kecil agar pengetahuan historis solusi sebelumnya dapat dimanfaatkan untuk mempercepat deteksi solusi optimal. Hasil eksperimen menunjukkan bahwa

FAPSO memberikan performa lebih baik dibandingkan algoritma tunggal pada sejumlah kasus benchmark. Namun, FAPSO memiliki kelemahan berupa kecenderungan eksplorasi berlebihan pada ruang solusi yang kurang menjanjikan sehingga meningkatkan jumlah evaluasi fungsi kebugaran dan menurunkan efisiensi, khususnya pada masalah berdimensi tinggi dengan permukaan solusi kompleks. Keterbatasan ini membuka peluang pengembangan metode yang lebih efisien dan adaptif. Oleh karena itu, penelitian ini mengusulkan integrasi ANFIS dengan dua algoritma optimasi secara berlapis, yaitu PSO untuk mengoptimalkan parameter fungsi keanggotaan fuzzy pada lapisan pertama dan FA untuk mengoptimalkan parameter konsekuen pada lapisan keempat (Jang dkk., 1997). Dengan pembagian peran yang lebih terstruktur, pendekatan ANFIS-PSO-Firefly diharapkan mampu menekan pemborosan evaluasi *fitness* serta meningkatkan stabilitas dan akurasi prediksi.

Pendekatan gabungan untuk klasifikasi kanker dikemukakan oleh Al-Thanoon, dkk. (2019) dengan mengintegrasikan Particle Swarm Optimization (PSO), Firefly Algorithm (FA), dan Cross Validation (CV). Dalam metode ini, PSO digunakan untuk menyeleksi fitur penting dari data ekspresi gen, FA diimplementasikan untuk mengoptimalkan parameter model klasifikasi, sementara CV dimanfaatkan untuk mengevaluasi kinerja dan mengurangi bias akibat ketidakseimbangan data (Al-Thanoon dkk., 2019). Hasil penelitian menunjukkan bahwa kombinasi ketiga algoritma tersebut mampu meningkatkan akurasi klasifikasi secara signifikan pada empat dataset kimia yang merepresentasikan berbagai jenis kanker. Model juga menunjukkan sensitivitas tinggi dalam pemilihan deskriptor penting, meskipun masih menghadapi keterbatasan berupa kompleksitas komputasi dan potensi *overfitting* akibat pemilihan fitur yang terlalu spesifik pada data pelatihan. Untuk mengatasi hal ini, penelitian ini mengusulkan integrasi Adaptive Neuro-Fuzzy Inference System (ANFIS) dengan dua algoritma swarm yang dioptimalkan secara terpisah. PSO diterapkan pada lapisan pertama ANFIS untuk mengoptimalkan parameter fungsi keanggotaan fuzzy, sedangkan FA diterapkan pada lapisan keempat untuk mengoptimalkan parameter

konsekuen. Strategi ini bertujuan menghindari tumpang tindih optimasi, mempercepat proses komputasi, dan menekan risiko *overfitting*. Pendekatan tersebut sejalan dengan temuan Farouk, dkk. (2021) yang menunjukkan efektivitas kombinasi FA dengan algoritma swarm lain dalam klasifikasi kanker payudara, serta penelitian Iliyasu dan Fatichah (2017) yang membuktikan integrasi Quantum PSO dengan fuzzy k-NN dapat meningkatkan akurasi deteksi kanker serviks. Dengan demikian, integrasi ANFIS–PSO–FA tidak hanya menjadi alternatif dari metode hibrida terdahulu, tetapi juga menawarkan solusi yang lebih konsisten dan fleksibel untuk klasifikasi serta prediksi data medis yang kompleks dan berskala besar (Farouk dkk., 2022; Iliyasu & Fatichah, 2017).

Penelitian yang dilakukan oleh Al-Qaness, dkk. (2020) merancang model prediksi kualitas udara berbasis *Adaptive Neuro-Fuzzy Inference System* (ANFIS) yang dioptimalkan dengan integrasi *Particle Swarm Optimization* (PSO) dan *Slime Mould Algorithm* (SMA), disebut PSOSMA-ANFIS (Al-qaness dkk., 2021). Model ini menggunakan data lingkungan seperti PM_{2.5}, SO₂, CO₂, dan NO₂ yang dikumpulkan sepanjang tahun sebagai masukan prediksi. Evaluasi kinerja dengan metrik MAPE, RMSE, dan MSE menunjukkan bahwa PSOSMA-ANFIS lebih akurat dan konsisten dibandingkan ANFIS tunggal maupun ANFIS–PSO. Kolaborasi PSO dan SMA memungkinkan keseimbangan eksplorasi serta eksploitasi pada pencarian solusi, yang penting untuk permasalahan optimasi nonlinier. Meski demikian, model ini masih sensitif terhadap parameter inisialisasi dan kurang stabil saat menghadapi data yang dinamis. Untuk mengatasi hal tersebut, penelitian ini menawarkan integrasi ANFIS dengan PSO pada lapisan pertama dan Firefly Algorithm (FA) pada lapisan keempat guna meningkatkan stabilitas, efisiensi, dan adaptivitas prediksi pada data lingkungan kompleks.

Studi yang dilakukan oleh Damayanti, dkk. (2016) membahas penggunaan *Adaptive Neuro-Fuzzy Inference System* (ANFIS) yang dioptimalkan dengan *Genetic Algorithm* (GA) untuk deteksi dini penyimpangan perkembangan balita (Damayanti dkk., 2016). Model ini

memanfaatkan data kondisi perkembangan anak untuk memberikan prediksi awal terhadap potensi gangguan pertumbuhan. Proses pelatihan menggunakan pendekatan hibrida yang menggabungkan *Least Squares Estimator* (LSE) pada fase maju dan GA pada fase mundur guna mengoptimalkan parameter ANFIS. Hasil penelitian menunjukkan model mampu mencapai error pelatihan yang sangat kecil (0,002899), menandakan kinerja prediksi yang baik pada data latihan. Namun, kinerja sistem masih sangat bergantung pada kualitas dan keragaman data pelatihan, sehingga generalisasi dapat menurun saat diuji pada data baru yang lebih heterogen. Untuk mengatasi keterbatasan tersebut, penelitian ini menawarkan integrasi ANFIS dengan *Particle Swarm Optimization* (PSO) pada lapisan pertama dan *Firefly Algorithm* (FA) pada lapisan keempat untuk meningkatkan efisiensi, stabilitas, serta adaptivitas prediksi dalam konteks data kesehatan anak yang kompleks.

Studi oleh Mottahedi, dkk. (2018) mengembangkan model prediksi *Adaptive Neuro-Fuzzy Inference System* (ANFIS) yang dioptimalkan dengan *Particle Swarm Optimization* (PSO), dikenal sebagai ANFIS-PSO (Adel dkk., 2018). Penelitian ini memanfaatkan 270 dataset numerik untuk regresi berganda dalam prediksi kualitas udara, dengan PSO yang digunakan untuk mengoptimalkan parameter fungsi keanggotaan fuzzy agar akurasi prediksi meningkat dan konvergensi lebih cepat. Evaluasi menggunakan MAPE, RMSE, dan MSE menunjukkan bahwa ANFIS-PSO secara konsisten lebih unggul dibandingkan ANFIS konvensional, baik dalam menurunkan kesalahan prediksi maupun meningkatkan kestabilan model. Meski demikian, PSO memiliki keterbatasan pada eksploitasi lokal ketika menghadapi ruang solusi yang kompleks serta sensitivitas terhadap parameter inisialisasi partikel. Untuk mengatasi hal tersebut, penelitian ini mengusulkan integrasi ANFIS dengan dua algoritma swarm, yaitu PSO pada lapisan pertama untuk mengoptimalkan fungsi keanggotaan fuzzy, dan *Firefly Algorithm* (FA) pada lapisan keempat untuk menyempurnakan parameter konsekuensi. Dengan pembagian peran yang lebih terstruktur, ANFIS-PSO-FA diharapkan mampu menghasilkan prediksi kualitas udara yang lebih akurat, stabil, dan

tangguh terhadap dinamika serta kompleksitas data lingkungan.

Penelitian oleh Ike, dkk. (2022) membandingkan tiga pendekatan prediktif, yaitu Response Surface Methodology (RSM), Artificial Neural Network (ANN), dan Adaptive Neuro-Fuzzy Inference System (ANFIS) untuk memprediksi efisiensi penghilangan minyak menggunakan adsorben (Ike dkk., 2022). Hasil penelitian menunjukkan bahwa ANN memberikan performa terbaik dengan koefisien korelasi di atas 0,97, diikuti oleh ANFIS dan RSM yang juga dinilai mampu menghasilkan prediksi efisien, ekonomis, dan berkelanjutan. Namun, dalam konteks prediksi kualitas udara, tantangan utama terletak pada ketidakpastian data lingkungan serta dinamika konsentrasi polutan yang dipengaruhi musim, aktivitas manusia, dan kondisi cuaca. ANFIS menjadi metode populer karena menggabungkan keunggulan logika fuzzy dalam menangani ketidakpastian dengan kemampuan jaringan saraf dalam pembelajaran nonlinear, meski kinerjanya masih terbatas. Untuk itu, penelitian ini mengusulkan integrasi ANFIS dengan dua algoritma swarm secara berlapis, yaitu PSO pada lapisan pertama untuk mengoptimalkan fungsi keanggotaan fuzzy dan FA pada lapisan keempat untuk menyempurnakan parameter konsekuen. Pendekatan ANFIS–PSO–FA ini diharapkan mampu meningkatkan akurasi, stabilitas, serta kemampuan adaptasi model dalam menghadapi dinamika kualitas udara yang kompleks.

Penelitian oleh Dirik (2022) mengembangkan model ANFIS dengan pendekatan *fuzzy c-means* sebagai sistem fuzzy awal, kemudian mengoptimalkan parameter model melalui Genetic Algorithm (GA) (Dirik, 2022). Evaluasi kinerja dilakukan menggunakan metrik korelasi, MSE, EM, RMSE, STD, dan MAPE, dan hasilnya menunjukkan bahwa ANFIS–GA mampu menekan kesalahan prediksi sekaligus meningkatkan akurasi dibandingkan ANFIS konvensional. Selain GA, Particle Swarm Optimization (PSO) juga banyak digunakan karena bekerja berdasarkan perilaku sosial kawanan untuk menemukan parameter optimal secara cepat dan efisien. Sejumlah penelitian membuktikan bahwa ANFIS–PSO menghasilkan prediksi kualitas udara yang akurat, dengan keunggulan pada kecepatan konvergensi dan kemudahan implementasi, meskipun perbandingan langsung

ANFIS–GA dan ANFIS–PSO pada dataset kualitas udara kompleks masih jarang dilakukan. Celah penelitian ini juga tampak pada terbatasnya studi ANFIS–PSO yang mengeksplorasi prediksi kualitas udara jangka pendek dan panjang dengan memperhitungkan variasi musiman serta geografis. Untuk menjawab keterbatasan tersebut, penelitian ini mengusulkan pengembangan ANFIS–PSO–Firefly Algorithm (FA), dengan PSO mengoptimalkan fungsi keanggotaan fuzzy pada lapisan pertama dan FA menyempurnakan parameter konsekuen pada lapisan keempat guna meningkatkan akurasi, stabilitas, serta kemampuan adaptasi model prediksi kualitas udara.

Penelitian yang dilakukan oleh Abdu, dkk. (2023) mengevaluasi pemanfaatan Artificial Neural Network (ANN) dan Adaptive Neuro-Fuzzy Inference System (ANFIS) dalam memprediksi indikator evaluasi kompos seperti konduktivitas listrik (EC), pH, rasio karbon-nitrogen (C/N), serta indeks pertumbuhan tanaman (GI) (Abdi dkk., 2023). Hasil penelitian menunjukkan bahwa ANFIS memberikan akurasi prediksi lebih tinggi dibandingkan ANN karena kemampuannya menggabungkan pembelajaran data dengan representasi linguistik melalui sistem fuzzy. Evaluasi menggunakan MAPE, RMSE, dan MSE semakin menegaskan potensi ANFIS sebagai pendekatan yang andal dalam pemodelan sistem kompleks dan dinamis. Namun, model ANFIS yang digunakan masih bergantung pada optimasi global tanpa membedakan karakteristik tiap lapisan, sehingga akurasinya berpotensi terbatas. Kesenjangan penelitian ini membuka peluang untuk strategi optimasi terpisah antara lapisan fungsi keanggotaan fuzzy dan lapisan konsekuen. Untuk itu, penelitian ini mengusulkan pendekatan hibrida ANFIS–PSO–FA, dengan PSO untuk mengoptimalkan parameter fungsi keanggotaan pada lapisan pertama dan FA untuk menyempurnakan parameter konsekuen pada lapisan keempat, sehingga model prediksi lebih efisien, akurat, dan stabil.


Penelitian yang dilakukan oleh Zeinalnezhad, dkk. (2020) menyoroti keterbatasan metode peramalan deret waktu tradisional yang cenderung mengasumsikan hubungan linier antarvariabel, padahal dalam kasus pencemaran udara hubungan tersebut bersifat nonlinier dan kompleks

(Zeinalnezhad dkk., 2020a) Studi ini menggunakan data polutan udara berupa CO, SO₂, O₃, dan NO₂ dari satu titik pemantauan di Tehran. Hasil evaluasi menunjukkan bahwa ANFIS memiliki akurasi prediksi lebih tinggi dibandingkan regresi linier karena mampu menangkap pola nonlinier melalui integrasi logika fuzzy dan pembelajaran adaptif. Temuan ini menegaskan peran ANFIS sebagai model prediktif yang relevan dalam mendukung kebijakan lingkungan demi kesehatan manusia, kelestarian ekosistem, dan pembangunan berkelanjutan. Namun, sebagian besar penelitian sebelumnya masih mengoptimasi ANFIS secara global tanpa strategi yang memperhatikan karakteristik spesifik tiap lapisan. Untuk mengatasi hal tersebut, penelitian ini mengusulkan pendekatan hibrida ANFIS–PSO–FA, dengan PSO untuk mengoptimasi fungsi keanggotaan pada lapisan pertama dan FA untuk menyempurnakan parameter konsekuen pada lapisan keempat, sehingga diharapkan menghasilkan prediksi yang lebih akurat, stabil, dan adaptif terhadap kompleksitas data pencemaran udara.

2.2. Dasar Teori

2.2.1. Adaptive Neuro Fuzzy Inference System (ANFIS)

Adaptive Neuro Fuzzy Inference System (ANFIS) merupakan model hibrida yang menggabungkan kelebihan logika fuzzy dan jaringan saraf tiruan. Untuk penyederhanaan, pada Gambar 2.1 diasumsikan sistem inferensi fuzzy memiliki dua variabel input yaitu x dan y serta satu variabel output yaitu z (Zeinalnezhad dkk., 2020b).



Gambar 2. 1 Struktur ANFIS

Pada Gambar 2.1, model yang digunakan adalah *fuzzy* Sugeno orde pertama dengan seperangkat aturan *fuzzy* :

Rule 1 : jika x adalah A_1 dan y adalah B_1 , maka $f_1 = p_1x + q_1y + r_1$

Rule 2 : jika x adalah A_2 dan y adalah B_2 , maka $f_2 = p_2x + q_2y + r_2$

(2.1)

Dengan :

A_i, B_j = himpunan *fuzzy* untuk input x dan y

p, q, r = parameter konsekuen yang ditentukan melalui pembelajaran

Output akhir z diperoleh melalui proses *fuzzyfikasi* perhitungan bobot aturan, normalisasi, *defuzzifikasi* hingga *agregasi* semua aturan. Struktur ANFIS terdiri atas 5 lapisan (Jang dkk., 1997):

1. Lapisan 1 *fuzzyfikasi*

Pada lapisan ini, setiap node menghitung derajat keanggotaan input terhadap himpunan *fuzzy* tertentu :

$$O_{1,i} = \mu_{A_i}(x) \text{ untuk } i = 1,2, \text{ atau}$$

$$O_{1,i} = \mu_{B_{i-2}}(y) \text{ untuk } i = 3,4$$

(2.2)

Fungsi keanggotaan yang digunakan adalah *bell-shaped function* :

$$\mu_A(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b_i}} \quad (2.3)$$

Dengan :

a_i = lebar fungsi keanggotaan (*premise* parameter)

b_i = *gradien* fungsi (umumnya $b_i = 1$)

c_i = pusat fungsi keanggotaan

2. Lapisan 2 produk (Rule Firing Strength)

Lapisan ini menghitung kekuatan aktivasi aturan *fuzzy* menggunakan operator perkalian yaitu :

$$O_{2,i} = w_i = \mu_{A_i}(x) \cdot \mu_{B_i}(y) \quad i = 1,2$$

(2.4)

Sebagai contoh untuk dua aturan :

$$w_1 = \frac{1}{1 + \left| \frac{x - c_{11}}{a_{11}} \right|^2} \times \frac{1}{1 + \left| \frac{y - c_{21}}{a_{21}} \right|^2}, \text{ dengan } b_i = 1$$

$$\begin{aligned} w_2 &= \mu_{A_2}(x) \cdot \mu_{B_2}(y) \\ &= \frac{1}{1 + \left| \frac{x - c_{12}}{a_{12}} \right|^2} \times \frac{1}{1 + \left| \frac{y - c_{22}}{a_{22}} \right|^2} \end{aligned}$$

(2.5)

3. Lapisan 3 normalisasi

Pada lapisan ini, bobot aturan dinormalisasikan agar memiliki kontribusi relatif :

$$O_{3,i} = \bar{w}_i = \frac{w_i}{\sum_{i=1}^2 w_i}, i = 1, 2,$$

(2.6)

Dengan :

$\bar{w}_i$ = bobot ternormalisasi

4. Lapisan 4 defuzzifikasi

Lapisan ini, node menghasilkan keluaran linier berdasarkan parameter konsekuen :

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (P_i x + q_i y + r_i)$$

(2.7)

dengan :

$\bar{w}_i$: bobot ternormalisasi

$\{ P_i, q_i, r_i \}$: parameter konsekuen adaptif yang diperoleh melalui pembelajaran

5. Lapisan 5 output (Agregasi)

Lapisan terakhir terdiri dari satu node tunggal yang menjumlahkan seluruh sinyal yang diterima dari lapisan keempat untuk menghasilkan output akhir :

$$\text{Overall output} = O_{5,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$$

Untuk dua aturan :

$$= \bar{w}_1 (p_1 x + q_1 y + r_1) + \bar{w}_2 (p_2 x + q_2 y + r_2)$$

(2.8)

2.2.2. Particle Swarm Optimization (PSO)

Particle Swarm Optimization (PSO) adalah algoritma optimasi berbasis kecerdasan kolektif (*swarm intelligence*) yang diperkenalkan oleh Kennedy dan Eberhart (1995). PSO meniru perilaku sosial hewan yang bergerak dalam kelompok, seperti kawanan burung atau ikan, di mana setiap individu menyesuaikan posisi berdasarkan pengalaman terbaiknya dan informasi dari kelompok untuk mencapai tujuan secara efisien dan adaptif. Dalam implementasi komputasi, populasi diwakili oleh sejumlah partikel sebagai kandidat solusi. Setiap partikel memiliki posisi dan kecepatan yang diperbarui secara iteratif untuk menemukan posisi dengan nilai fungsi objektif (*fitness*) terbaik (Febri Istighfarin dkk., 2020).

1. Prinsip dasar PSO

PSO memanfaatkan dua informasi utama yaitu :

- *Pbest* adalah posisi terbaik yang pernah dicapai partikel
- *Gbest* adalah posisi terbaik yang ditemukan seluruh populasi

Pergerakan partikel dipandu oleh dua mekanisme yaitu :

- Eksplorasi yaitu menjelajah ruang pencarian agar tidak terjebak pada solusi lokal
- Eksploitasi yaitu memusatkan pencarian di area potensial (dekat *gbest*) untuk mempercepat konvergensi.

Keseimbangan antara eksplorasi dan eksploitasi menjadi kunci keberhasilan PSO dalam menemukan solusi *global* optimum.

2. Parameter Utama PSO

Beberapa parameter yang memengaruhi kinerja PSO meliputi :

- a. Jumlah partikel (N) yaitu untuk menentukan ukuran populasi.
- b. Bobot inersia (ω) yaitu mengatur pengaruh kecepatan sebelumnya pada kecepatan saat ini berperan dalam keseimbangan eksplorasi dan eksploitasi.
- c. Faktor pembelajaran individu (c_1) dan sosial (c_2) yaitu mengatur pengaruh *pbest* dan *gbest* pada pembaruan kecepatan.
- d. Bilangan acak (R_1, R_2) yaitu bernilai antara 0 – 1, menambah unsur stokastik pada arah pencarian.

- e. Kecepatan maksimum (V_{max}) yaitu mencegah pergerakan partikel yang terlalu besar sehingga tetap stabil.
 - f. Kriteria penghentian (*stopping condition*) yaitu berupa jumlah iterasi maksimum atau tercapainya nilai *fitness* tertentu.
3. Langkah – langkah algoritma PSO

Menurut Kennedy dan Eberhart (1995) yang diperjelas oleh Mansur dkk.(2014), prosedur PSO dapat dijelaskan sebagai berikut (Bahiraei dkk., 2021) :

a. Inisialisasi

Menentukan parameter awal seperti jumlah partikel, bobot inersia (ω), faktor pembelajaran (c_1, c_2), jumlah iterasi maksimum, dan fungsi objektif. Posisi setiap partikel X_j diinisialisasi secara acak dalam ruang pencarian dengan kecepatan awal $V_j = 0$.

b. Evaluasi *Fitness*

Menghitung nilai *fitness* tiap partikel berdasarkan fungsi objektif yang ditetapkan.

c. Tentukan *pbest* dan *gbest*

Menyimpan posisi terbaik yang pernah dicapai setiap partikel sebagai *pbest* dan memilih posisi terbaik di antara seluruh partikel sebagai *gbest*.

d. Pembaruan kecepatan

Kecepatan partikel diperbarui menggunakan persamaan :

$$V_{k+1} = \omega \cdot V_k + c_1 \cdot R_1 \cdot (Pbest_k - X_k) + c_2 \cdot R_2 (Gbest_k - X_k) \quad (2.9)$$

Dengan keterangan :

ω : bobot inersia

c_1, c_2 : faktor pembelajaran individu dan sosial (umumnya 2)

R_1, R_2 : bilangan acak (0 – 1)

V_k : kecepatan saat ini

X_k : posisi saat ini

e. Pembaruan posisi

Posisi partikel diperbarui dengan :

$$X_{j(i)} = X_{j(i-1)} + V_{j(i)}$$

(2.10)

Dengan keterangan :

$X_{j(i)}$: posisi baru partikel ke-j pada iterasi ke-i

$V_{j(i)}$: kecepatan baru pada iterasi ke-i

f. Cek kondisi penghentian

Jika jumlah iterasi maksimum tercapai atau solusi optimal ditemukan, algoritma berhenti. Jika belum, kembali ke langkah kedua.

4. Kelebihan PSO

Beberapa kelebihan PSO antara lain :

- a. Sederhana dan mudah diimplementasikan karena tidak memerlukan turunan fungsi objektif.
- b. Memiliki konvergensi cepat pada berbagai masalah optimasi nonlinier.
- c. Efektif menjaga keseimbangan eksplorasi dan eksploitasi melalui pengaturan parameter.

2.2.3. Firefly Algorithm

Firefly Algoritma (FA) merupakan metode optimasi metaheuristik yang dikembangkan oleh Xin- She Yang dari Universitas Cambridge pada tahun 2007. Algoritma ini terinspirasi dari perilaku biologis kunang-kunang (*firefly*), khususnya mekanisme cahaya berkedip yang digunakan untuk menarik perhatian kunang-kunang lain. Dalam FA intensitas cahaya yang dipancarkan kunang-kunang dianalogikan sebagai kualitas solusi : semakin terang cahaya, semakin baik kualitas solusi di posisi tersebut. Kunang – kunang dengan cahaya redup akan bergerak menuju kunang-kunang yang lebih terang untuk memperoleh posisi dengan nilai fungsi tujuan (*objective function*) yang lebih baik.

1. Prinsip dasar *firefly algorithm*

Prinsip utama FA didasarkan pada tiga asumsi biologis berikut :

- *Unisex* semua kunang – kunang dianggap memiliki jenis

kelamin yang sama, sehingga setiap individu dapat tertari satu sama lain.

- Tingkat kecerahan daya tarik antar kunang-kunang sebanding dengan intensitas cahaya yang dipancarkan.
- Pengaruh jarak intensitas cahaya yang dirasakan akan berkurang seiring bertambahnya jarak dan dipengaruhi oleh koefisien penyerapan cahaya (γ) serta faktor lingkungan.

Dalam konteks optimasi, cahaya diartikan sebagai nilai fungsi tujuan: semakin baik nilai fungsi tujuan, semakin terang cahaya kunang-kunang.

2. Tahapan algoritma FA

Langkah-langkah umum algoritma *firefly* dapat dijelaskan sebagai berikut :

a. Inisialisasi populasi

- a) Tentukan jumlah kunang-kunang (n)
- b) Inisialisasi posisi awal setiap kunang-kunang x_i secara acak dalam ruang pencarian berdimensi d .
- c) Tetapkan parameter algoritma :
 - β_0 adalah daya tarik maksimum
 - γ adalah koefisien penyerapan cahaya
 - α adalah parameter langkah acak

d) Evaluasi fungsi tujuan

- a) Hitung nilai fungsi tujuan $f(x_i)$ pada setiap posisi kunang-kunang.
- b) Konversikan nilai fungsi tujuan menjadi intensitas cahaya I_i (untuk masalah maksimisasi, semakin besar nilai $f(x_i)$ semakin terang kunang-kunang)

e) Hitung jarak antar kunang-kunang

Untuk setiap pasangan kunang-kunang (i, j) hitung jarak Euclidean:

$$r_{i,j} = \sqrt{\sum_{k=1}^d (X_{i,k} - X_{j,k})^2}$$

(2.11)

f) Hitung daya tarik

Tentukan daya tarik kunang-kunang j terhadap i dengan persamaan :

$$\beta = \beta_0 e^{-\gamma r^2}$$

(2.12)

g) Update posisi kunang-kunang

Jika kunang-kunang j lebih terang dari i, maka kunang-kunang i bergerak menuju j dengan persamaan :

$$x_i = x_i + \beta_0 e^{-\gamma r_{i,j}^2} (x_j - x_i) + \alpha \epsilon_i$$

(2.13)

Dengan ϵ_i adalah vektor acak

h) Evaluasi ulang fungsi tujuan

Hitung kembali nilai fungsi tujuan pada posisi baru

i) Pemeriksaan kondisi berhenti

Ulangi langkah 3-6 hingga kondisi berhenti terpenuhi, misalnya :

- a) Jumlah iterasi maksimum tercapai
- b) Nilai fungsi tujuan sudah konvergen

j) Output solusi terbaik

Pilih kunang-kunang dengan nilai fungsi tujuan terbaik sebagai solusi optimal.

3. Karakteristik FA

FA dikenal efektif untuk masalah optimasi nonlinier karena :

- a) Memiliki mekanisme eksplorasi *global* melalui langkah acak
- b) Eksploitasi lokal diarahkan oleh daya tarik cahaya untuk mempercepat konvergensi
- c) Tidak memerlukan turunan fungsi tujuan (*derivative-free*).

2.2.5. Kualitas Udara

Udara merupakan salah satu elemen penting bagi keberlangsungan kehidupan di bumi. Udara merupakan campuran gas yang mengelilingi bumi,

terdiri dari berbagai macam gas diantaranya yaitu nitrogen 78%, oksigen 20%, argon 0,93% dan karbon monoksida 0,30% lalu sisanya keluarkan gas-gas lain. Sedangkan untuk uap air yang terdapat di udara merupakan hasil dari penguapan air laut, sungai dan lain-lainnya. Pada peraturan Menteri Lingkungan Hidup dan Kehutanan Republik Indonesia Nomor P.14/MENLHK/SETJEN/KUM.1/7/2020 tentang indeks pencemaran udara terbagi menjadi 5 kategori nilai yaitu (Sang dkk., 2021) :

Tabel 2. 1 ISPU Udara

Kategori	Status Warna	Angka Rentan
Baik	Hijau	0 – 50
Sedang	Biru	51 – 100
Tidak Sehat	Kuning	101 – 200
Sangat Tidak Sehat	Merah	201 – 300
Berbahaya	Hitam	≥ 301

2.2.6. Polusi Udara

Pencemaran udara adalah isu penting yang dapat memberikan efek buruk bagi kesehatan manusia. Jika tidak ditangani, polusi udara dapat mengakibatkan berbagai masalah kesehatan mulai dari gangguan pernapasan, iritasi pada mata, hingga alergi kulit. Dengan demikian, pengembangan sistem peringatan dini untuk memprediksi kualitas udara menjadi sangat krusial. Pada konsentrasi tertentu, polusi udara dapat segera berdampak pada kesehatan, sehingga sensor kualitas udara yang terjangkau dan portabel bisa digunakan secara luas untuk memantau paparan polutan secara individu (Abidin dkk., 2019). Pencemaran udara terjadi saat substansi, energi, atau elemen lain memasuki udara akibat tindakan manusia, melebihi standar kualitas yang telah ditentukan. Sumber pencemaran dapat diklasifikasikan menjadi tiga kategori yaitu sumber dari perkotaan dan industri, sumber dari pedesaan/pertanian, serta sumber yang bersifat alami. Sumber urban dan industri berasal dari perkembangan teknologi yang menciptakan banyak pabrik, pembangkit listrik, dan kendaraan bermotor. Sumber pedesaan/pertanian meliputi penerapan pestisida dan senyawa kimia lainnya

guna melindungi tanaman. Sumber alami terdiri dari abu dari gunung berapi, gas vulkanik, debu yang tertiuap angin, dan aroma tidak sedap akibat pembusukan limbah organik (Dyana dkk., 2025).

Dalam konteks ini, polutan udara seperti Nitrogen Dioksida (NO_2), Sulfur Dioksida (SO_2), Karbon Monoksida (CO), dan Ozon (O_3) memiliki pengaruh besar terhadap kesehatan dan lingkungan. NO_2 yang berasal dari pembakaran bahan bakar pada kendaraan dan industri berperan dalam pembentukan ozon troposferik serta berdampak buruk pada kesehatan pernapasan. Pengawasan emisi NO_2 sangat krusial untuk mempertahankan kualitas udara (Rofia Nurfadillah dkk., 2023). SO_2 yang dihasilkan dari pembakaran bahan bakar fosil dapat mengiritasi saluran pernapasan dan berkontribusi pada terjadinya hujan asam, sehingga penting untuk mengendalikan emisinya (Rejeki Takuloe dkk., 2023). CO yang dihasilkan dari proses pembakaran yang tidak sempurna, dapat berbahaya bagi kesehatan, terutama bagi orang-orang yang memiliki masalah jantung atau paru-paru (Suhardono dkk., 2025). O_3 walaupun melindungi dari radiasi UV di stratosfer dapat menimbulkan masalah kesehatan di troposfer. Dengan demikian pengawasan dan pengendalian emisi dari semua zat pencemar ini sangat penting untuk memelihara kualitas udara dan kesehatan masyarakat, serta untuk merumuskan kebijakan yang lebih efisien (Pettersson dkk., 2022).

2.2.7. Model Performance Evaluation

Evaluasi kinerja model diperlukan untuk mengukur sejauh mana kemampuan model dalam menghasilkan prediksi yang mendekati nilai aktual. Penggunaan teknik evaluasi yang tepat dapat membantu menilai keandalan model sekaligus menjadi dasar perbaikan pada tahap berikutnya. Menurut Hyndman dan Athanasopoulos (2018), ukuran kesalahan (*error metrics*) merupakan salah satu pendekatan yang paling umum digunakan untuk mengevaluasi performa model peramalan (Rob J Hyndman, 2018).

Beberapa metrik yang digunakan pada penelitian ini adalah *Mean Square Error* (MSE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE).

1. *Mean Square Error* (MSE)

MSE mengukur rata-rata kesalahan kuadrat antara nilai aktual dengan nilai prediksi. Semakin kecil nilai MSE (mendekati nol), semakin baik model karena hasil prediksi mendekati nilai aktual (Rob J Hyndman, 2018). Persamaan MSE dituliskan sebagai berikut :

$$MSE = \frac{1}{n} \sum_{i=1}^n (P_{yi} - Y_i)^2 \quad (2.19)$$

dengan :

P_{yi} : nilai prediksi pada periode ke-i

Y_i : nilai sejati pada periode ke – i

n : jumlah data

MSE menitik beratkan pada penalti yang lebih besar terhadap *error* yang ekstrem karena kesalahan dipangkatkan dua. MSE digunakan karena mampu menunjukkan besarnya kesalahan prediksi secara keseluruhan dengan memberikan penalti yang lebih besar terhadap kesalahan yang ekstrem. Hal ini penting dalam penelitian prediksi kualitas udara karena kesalahan yang sangat besar pada beberapa periode dapat mempengaruhi interpretasi terhadap kondisi lingkungan yang sebenarnya. MSE dapat mengidentifikasi apakah model memiliki kecenderungan menghasilkan error yang besar pada data tertentu.

2. Root Mean Square Error (RMSE)

RMSE merupakan akar kuadrat dari MSE. Metrik ini memiliki satuan yang sama dengan data aslinya sehingga lebih mudah diinterpretasikan dalam konteks data yang dianalisis (Estrada dkk., 2020). Persamaan RMSE dapat dituliskan sebagai berikut:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (P_{yi} - Y_i)^2}{n}} \quad (2.20)$$

dengan :

P_{yi} : nilai prediksi pada periode ke-i

Y_i : nilai sejati pada periode ke – i

n : jumlah data

Semakin kecil nilai RMSE, semakin baik kualitas prediksi yang dihasilkan oleh model. RMSE digunakan karena memiliki satuan yang sama dengan data aslinya sehingga lebih mudah diinterpretasikan dalam konteks nilai yang

diprediksi. RMSE juga sering digunakan dalam penelitian peramalan karena mampu menggambarkan seberapa jauh rata-rata deviasi antara nilai prediksi dan nilai aktual. Oleh karena itu, RMSE memberikan gambaran yang lebih intuitif mengenai tingkat kesalahan model dalam satuan yang sama dengan data kualitas udara yang dianalisis.

3. *Mean Percentage Absolute Error (MAPE)*

MAPE digunakan untuk mengukur rata-rata presentase kesalahan mutlak (*absolute*) antara nilai aktual dan prediksi. Nilai MAPE dinyatakan dalam persen sehingga memudahkan interpretasi dalam berbagai skala data (Lewis, 1982). Persamaan MAPE adalah sebagai berikut :

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{(Y_i - P_{yi})}{Y_i} \times 100\% \quad (2.21)$$

dengan :

P_{yi} : nilai prediksi pada periode ke-i

Y_i : nilai sejati pada periode ke – i

n : jumlah data

MAPE menurut Lewis (1982) dalam bukunya *Industrial and Business Forecasting Methods : A Practical Guide to Exponential Smoothing and Curve Fitting*, kriteria penilaian tingkat akurasi berdasarkan nilai MAPE dapat dilihat pada Tabel 2.2 :

Tabel 2. 2 Penilaian MAPE

Nilai MAPE	Keterangan
$MAPE \leq 10\%$	Prediksi yang sangat akurat
$10\% < MAPE \leq 20\%$	Prediksi yang akurat
$20\% < MAPE \leq 50\%$	Prediksi yang cukup akurat
$MAPE > 50\%$	Prediksi yang tidak akurat

Nilai MAPE digunakan karena mampu menunjukkan tingkat kesalahan model dalam bentuk presentase sehingga memudahkan perbandingan tingkat akurasi model meskipun data memiliki skala yang berbeda. Selain itu, nilai MAPE telah banyak digunakan dalam penelitian peramalan karena kriteria penilaian yang jelas seperti yang dikemukakan oleh Lewis (1982) sehingga memudahkan dalam menentukan apakah model yang

dihasilkan termasuk sangat akurat, akurat, cukup akurat, atau tidak akurat. Metrik ketiganya digunakan secara bersamaan, evaluasi performa model dapat dilakukan secara lebih komprehensif baik dari sisi besarnya kesalahan absolute maupun kesalahan relatif terhadap nilai aktual.



SEKOLAH PASCASARJANA