

OPTIMASI PENEMPATAN SENSOR PADA UNIT KILANG MINYAK MENGUNAKAN ALGORITMA GENETIKA

Muhammad Reyvanza¹, Alung Dimar Graha Listanto^{1*}, Alfredo Devananda
Fathurrahman¹, Nayla Choirinnesa¹, Aulya Pradevi¹, Asepta Surya Wardhana¹

¹Teknik Instrumentasi Kilang, Politeknik Energi dan Mineral Akamigas, Cepu, Blora, 58311

*Email: alunggl499@gmail.com

ABSTRAK

Kilang minyak adalah lokasi industri berisiko tinggi yang membutuhkan sistem pemantauan yang dapat diandalkan yang melibatkan penempatan sensor strategis. Penempatan yang tidak efektif dapat menyebabkan blind zone, redundansi berlebihan, dan biaya yang tidak efisien. Menggunakan Algoritma Genetika (GA) dengan pendekatan multi-kriteria, penelitian ini bertujuan untuk mengoptimalkan penempatan sensor pada unit kilang minyak. Dalam pemodelan spasial dua dimensi, fungsi fitness dimaksudkan untuk menggabungkan cakupan area, biaya instalasi, dan penalti redundansi. Python, yang memiliki populasi 80 kromosom dan 200 generasi, menghasilkan dua skenario optimal (1) skenario efisiensi biaya dengan empat sensor aktif mencapai cakupan 100% terhadap sepuluh unit dengan fitness 16,7 dan biaya 16.900 satuan tanpa redundansi; (2) skenario keandalan sistem dengan tujuh sensor dengan fitness 15,3, 1.250 redundansi, dan 21.400 satuan. Metode ini dapat mengurangi biaya instalasi hingga enam puluh persen dibandingkan dengan penempatan manual baseline sambil menghilangkan redundansi yang tidak diperlukan. Framework yang dikembangkan dapat disesuaikan dengan berbagai skala kilang. Penelitian ini memberikan dasar kuantitatif yang fleksibel berdasarkan prioritas efisiensi biaya atau keandalan sistem dalam industri gas dan minyak.

Kata kunci: Optimasi sensor, Algoritma genetika, Kilang minyak, Multi-kriteria, Efisiensi biaya,

1. PENDAHULUAN

Kilang minyak merupakan fasilitas industri berisiko tinggi yang memainkan peran vital dalam pemenuhan kebutuhan energi nasional dan internasional. Kompleksitas operasional, risiko kebocoran, dan tuntutan efisiensi energi mengharuskan adanya sistem pemantauan proses yang andal untuk menjamin keselamatan dan keberlanjutan operasional kilang [1],[2]. Salah satu tantangan utama dalam sistem pemantauan kilang adalah menentukan posisi sensor optimal agar data yang dihasilkan akurat, representatif, dan efisien secara biaya [3],[4]. Sensor yang digunakan dalam pemantauan kilang minyak mencakup sensor tekanan untuk mendeteksi fluktuasi pada sistem perpipaan, sensor temperatur untuk memantau kondisi terminal unit proses seperti kolom destilasi dan heat exchanger, serta sensor laju alir untuk mengukur throughput material pada berbagai titik kritis operasional. Penempatan sensor yang tidak tepat dapat menyebabkan area yang tidak terpantau (blind zone), redundansi berlebihan, dan peningkatan biaya instalasi serta pemeliharaan [5],[6].

Algoritma Genetika (GA) telah terbukti efektif dalam menyelesaikan masalah optimasi yang kompleks, termasuk penentuan lokasi sensor optimal pada sistem industri proses [7],[8]. Sebagai metode evolusioner, GA dapat menangani berbagai variabel keputusan dan batasan operasional dengan melalui pendekatan multi-kriteria berbasis fungsi fitness yang mempertimbangkan redundansi sensor, cakupan area, dan biaya instalasi secara bersamaan [9],[10]. Keunggulan GA dibandingkan metode heuristik konvensional terletak pada kemampuannya menghindari jebakan solusi lokal dan beradaptasi dengan dinamika proses kilang yang kompleks [10].

Dibandingkan dengan Particle Swarm Optimization (PSO) yang juga populer dalam optimasi penempatan sensor, GA memiliki keunggulan spesifik untuk masalah ini karena: (1) representasi solusi biner GA (sensor aktif/tidak aktif) lebih natural untuk problem diskrit penempatan sensor dibandingkan representasi kontinu PSO; (2) operator crossover GA mampu mengeksplorasi kombinasi lokasi sensor secara lebih sistematis; dan (3) mekanisme elitism GA lebih efektif mempertahankan solusi terbaik dalam landscape optimasi dengan multiple local optima seperti pada layout kilang dengan zona prioritas berbeda. Beberapa penelitian menunjukkan bahwa integrasi algoritma genetika dengan model proses industri dapat meningkatkan akurasi deteksi anomali dan efisiensi konfigurasi sensor di unit kilang [11],[12].

Perkembangan terkini dalam optimasi penempatan sensor menunjukkan penggunaan pendekatan hybrid yang mengkombinasikan GA dengan kecerdasan buatan dan *swarm intelligence* untuk mempercepat konvergensi solusi [13],[14]. Penerapan jaringan sensor nirkabel dan Internet Of Things dalam industri migas membuka peluang besar untuk membangun sistem pemantauan berbasis data real time yang adaptif [15],[16]. Pendekatan multi objektif menggunakan particle swarm optimization telah menunjukkan potensi signifikan dalam meningkatkan efektivitas penempatan sensor untuk structural health monitoring [18]. Aplikasi GA pada sistem deteksi kebocoran pipeline minyak dan gas juga memperlihatkan hasil yang menjanjikan dalam meningkatkan reliability sistem monitoring [19], termasuk implementasi pada optimasi kinerja energi furnace kilang [20].

Meskipun demikian, terdapat beberapa keterbatasan signifikan dalam penelitian sebelumnya. Pertama, sebagian besar studi terbatas pada model grid sederhana atau sistem generik yang tidak merepresentasikan kompleksitas nyata kilang minyak, seperti perbedaan prioritas pemantauan antar unit, zona bahaya, dan keterbatasan akses fisik [17]. Kedua, hanya sedikit penelitian yang secara eksplisit mengintegrasikan kriteria coverage, cost, dan redundancy dalam satu fungsi fitness yang dapat disesuaikan dengan prioritas operasional

[7],[8]. Ketiga, belum ada framework sistematis yang mengeksplorasi trade-off antara jumlah sensor optimal dan konfigurasi penempatan spasial dengan mempertimbangkan multiple constraints secara simultan pada layout kilang minyak aktual.

Oleh karena itu, penelitian ini bertujuan mengembangkan framework optimasi penempatan sensor pada unit kilang minyak menggunakan Algoritma Genetika yang disesuaikan dengan karakteristik proses industri minyak dan gas. Framework yang dikembangkan mengeksplorasi 15 kandidat lokasi sensor pada 10 unit proses kilang yang mencakup kolom distilasi, tangki penyimpanan, pompa, heat exchanger, dan sistem flare dengan mempertimbangkan zona prioritas yang berbeda untuk setiap unit.

Kontribusi utama penelitian ini mencakup tiga aspek fundamental. Pertama, formulasi fungsi fitness multi-kriteria yang mengintegrasikan cakupan area (coverage), biaya instalasi (*cost*), dan penalti redundansi dengan parameter yang dapat disesuaikan berdasarkan prioritas operasional. Kedua, implementasi pemodelan spasial dua dimensi yang merepresentasikan tata letak kilang minyak dengan zona prioritas berbeda dan radius efektif cakupan sensor. Ketiga, validasi komparatif dua skenario operasional skenario efisiensi biaya (cost-driven) dengan konfigurasi minimal sensor dan skenario keandalan sistem (reliability-driven) dengan redundansi terkontrol yang memberikan fleksibilitas dalam penyesuaian konfigurasi sensor sesuai kebutuhan strategis kilang.

2. METODE

Dalam penelitian ini, pendekatan algoritma genetika (GA) digunakan untuk mengoptimalkan penempatan sensor pada unit kilang minyak. Metode ini dirancang secara sistematis mengikuti kaidah penelitian kuantitatif. Penelitian dimulai dengan identifikasi kandidat lokasi

sensor potensial berdasarkan karakteristik fisik kilang, aksesibilitas instalasi, dan cakupan area pengukuran [14]. Seleksi lokasi kandidat mempertimbangkan keandalan pemantauan dalam lingkungan kilang yang luas dan dinamis, sehingga data yang diperoleh representatif dan mampu mengakomodasi berbagai kondisi proses [2].

Sensor yang digunakan dalam penelitian ini merupakan sensor multi-parameter industrial grade dengan spesifikasi sebagai berikut: sensor tekanan dengan rentang 0-100 bar dan akurasi $\pm 0,5\%$, sensor temperatur tipe thermocouple K dengan rentang 0-500°C dan akurasi $\pm 1^\circ\text{C}$, serta sensor laju alir electromagnetic dengan akurasi $\pm 0,5\%$ dari reading. Radius efektif cakupan sensor ditetapkan 50 meter berdasarkan karakteristik transmisi sinyal wireless pada frekuensi 2,4 GHz di lingkungan industrial dengan mempertimbangkan interferensi elektromagnetik, obstacle density, dan line-of-sight requirements sesuai standar ISA-100.11a untuk wireless sensor networks di industri proses. Keterbatasan teknis sensor mencakup sensitivitas terhadap suhu ekstrem di atas 60°C yang dapat mengurangi akurasi hingga 2%, kerentanan terhadap vibrasi mekanis pada area pompa, dan requirement periodic calibration setiap 6 bulan untuk menjaga akurasi pengukuran.

Prioritas pemantauan setiap unit kilang (skala 1-10) ditentukan melalui metode risk-based assessment yang mengintegrasikan tiga kriteria: (1) consequence severity berdasarkan potensi kerugian material dan keselamatan (bobot 40%), (2) probability of failure berdasarkan historical incident data dan kondisi operasional (bobot 35%), dan (3) criticality to production berdasarkan impact terhadap kontinuitas operasi kilang (bobot 25%). Unit kolom distilasi dan tangki penyimpanan volatile materials diberi prioritas tertinggi (9-10) karena high consequence dan high probability, heat exchanger dan pompa utama diberi prioritas menengah (6-8), sedangkan sistem flare dan pompa sekunder diberi prioritas lebih rendah (3-5) karena redundancy dan lower criticality. Algoritma genetika multi-kriteria juga dikembangkan dengan tiga tujuan utama yaitu: (1) mengukur parameter proses seperti tekanan, temperatur, dan laju alir secara akurat (2) mengurangi redundansi data untuk meningkatkan efisiensi sistem (3) memperhitungkan biaya instalasi dan operasional sensor.

Fungsi fitness digunakan dalam penelitian ini dirancang untuk menilai kualitas setiap kromosom berdasarkan kombinasi antara cakupan unit, total biaya, dan penalti redundansi sensor sebagaimana ditunjukkan pada persamaan berikut.

$$\text{Fitness} = \sum_{i=1}^n P_i - \alpha \left(\frac{C_{\text{total}}}{C_{\text{max}}} \right) - \beta R \quad (1)$$

$$C_{\text{total}} = \sum_{j=1}^{N_s} C_s \quad (2)$$

$$C_{\text{max}} = N_{\text{max}} \times C_s \quad (3)$$

$$R = \sum_{i=1}^n \max(0, k_i - 1) \quad (4)$$

Pada persamaan (1) merepresentasikan fungsi fitness multi-objectif yang mengintegrasikan tiga komponen utama optimasi, yaitu komponen pertama $\sum^n P_i$ yang menghitung total prioritas dari seluruh unit kilang yang tercakup oleh konfigurasi sensor, di mana P_i bernilai antara 1 hingga 10 sesuai tingkat kritikalitas setiap unit; komponen kedua $\alpha (C_{total})$ yang berfungsi sebagai penalti biaya dinormalisasikan dengan parameter $\alpha = 0,001 C_{max}$ untuk menyeimbangkan skala penalti biaya terhadap komponen prioritas unit; dan komponen ketiga βR yang merupakan penalti redundansi dengan $\beta = 0,5$ memberikan trade-off moderat antara kendala sistem dan efisiensi biaya.

Nilai parameter $\alpha = 0,001$ dipilih melalui sensitivity analysis untuk memastikan komponen penalti biaya (yang bernilai 0-1 setelah normalisasi) sebanding dengan komponen prioritas unit (yang bernilai 0-55 untuk 10 unit dengan prioritas maksimum), sehingga cost penalty tidak mendominasi fungsi fitness. Parameter $\beta = 0,5$ ditetapkan berdasarkan preliminary experiments yang menunjukkan bahwa nilai ini memberikan balance optimal antara redundancy control dan coverage maximization; nilai $\beta < 0,3$ menghasilkan excessive redundancy, sedangkan $\beta > 0,7$ cenderung menghasilkan single-point of failure risks. Ukuran populasi 80 kromosom dipilih berdasarkan rule-of-thumb 5N-10N (di mana N = 15 kandidat sensor) untuk menjamin diversity adequate dalam eksplorasi solution space tanpa excessive computational cost. Jumlah generasi maksimum 200 ditetapkan berdasarkan convergence analysis yang menunjukkan stabilitas fitness tercapai rata-rata pada generasi 50-80, dengan margin $2,5\times$ untuk memastikan konvergensi penuh. Probabilitas crossover 0,8 mengikuti rekomendasi literatur GA untuk discrete optimization problems, memastikan exploitation yang kuat dengan tetap menjaga eksplorasi. Probabilitas mutasi 0,02 dihitung menggunakan formula $1/L$ (di mana L = 15 panjang kromosom) dengan adjustment factor 0,3 untuk menjaga diversity sambil menghindari disruptive mutation yang berlebihan.

Pada persamaan (2) menghitung total biaya instalasi C_{total} sebagai penjumlahan biaya seluruh sensor aktif, di mana N_s adalah jumlah sensor yang dipilih (gen bernilai 1) dan C_s adalah biaya instalasi per sensor sebesar 3.500 satuan. Persamaan (3) mendefinisikan biaya maksimum teoritis C_{max} yang terjadi jika seluruh kandidat sensor ($N_{max} = 15$ lokasi) dipasang, berfungsi sebagai normalisasi untuk komponen penalti biaya dalam fungsi fitness. Persamaan (4) menghitung total penalti redundansi R dengan menjumlahkan kelebihan jumlah sensor yang mencakup unit i dan penalti hanya dikenakan jika $k_i > 1$ melalui formulasi $\max(0, k_i - 1)$ yang memastikan unit dengan cakupan tunggal tidak mendapat penalti, sementara setiap sensor tambahan yang mencakup unit yang sama akan menambah nilai penalti redundansi secara linear.


Fungsi multi-kriteria ini dirancang dengan tiga komponen utama: komponen positif berupa total prioritas unit yang tercakup, dan dua komponen negatif berupa penalti biaya dan penalti redundansi. Dengan demikian, nilai fitness maksimum yang diperoleh menunjukkan solusi optimal yang mampu memaksimalkan cakupan unit prioritas tertinggi sambil meminimalkan biaya serta redundansi. Pemilihan nilai parameter $\alpha = 0,001$ bertujuan menormalisasi komponen biaya agar sebanding dengan skala prioritas unit. Nilai $\beta = 0,5$ memberikan bobot penalti redundansi yang moderat, memungkinkan trade-off antara keandalan sistem (redundansi positif) dan efisiensi biaya (redundansi minimal). Parameter ini dapat disesuaikan berdasarkan prioritas operasional: nilai β lebih rendah untuk skenario cost-driven, dan nilai β lebih tinggi untuk skenario reliability-driven.

Algoritma GA diimplementasikan menggunakan Python 3.9.7 dengan library utama: NumPy 1.21.2 untuk operasi array dan komputasi numerik, Matplotlib 3.4.3 untuk visualisasi grafik evolusi fitness dan spatial layout, serta Pandas 1.3.3 untuk manajemen data dan export hasil dalam format CSV. Algoritma GA diinisialisasi dengan membangkitkan populasi awal sebanyak 80 kromosom secara acak menggunakan fungsi `numpy.random.randint()`. Setiap kromosom

merepresentasikan kombinasi biner dari kandidat sensor (gen bernilai 1 = sensor aktif, gen bernilai 0 = sensor tidak aktif). Populasi awal kemudian dievaluasi menggunakan fungsi fitness berdasarkan data layout kilang yang mencakup koordinat unit, prioritas pemantauan, dan spesifikasi teknis sensor. Proses evolusi dilakukan melalui iterasi seleksi turnamen, crossover satu titik dengan probabilitas 0,8, dan mutasi bit-flip dengan probabilitas 0,02 selama maksimum 200 generasi atau hingga konvergensi tercapai [4].

Mekanisme elitism diterapkan untuk memastikan kromosom terbaik dari setiap generasi dipertahankan ke generasi berikutnya, mencegah degradasi solusi optimal [10]. Pendekatan ini meningkatkan eksplorasi ruang solusi dan menghindari konvergensi prematur pada solusi lokal, yang sangat penting mengingat kompleksitas landscape optimasi pada tata letak kilang dengan multiple constraints [15]. Kriteria konvergensi ditetapkan ketika nilai fitness terbaik tidak mengalami peningkatan signifikan ($< 0,1\%$) selama 20 generasi berturut-turut, atau ketika jumlah generasi maksimum (200) tercapai.

Evaluasi dilakukan melalui analisis komparatif dua skenario: (1) cost-driven yang meminimalkan jumlah sensor, dan (2) reliability-driven dengan redundansi terkontrol [14]. Parameter evaluasi meliputi fitness, jumlah sensor, cakupan unit, biaya instalasi, dan redundansi [4]. Validasi memastikan semua unit prioritas tercakup, tidak ada blind zone, dan konfigurasi implementable. Evaluasi terhadap kromosom yang dilakukan dengan menghitung nilai fitness sesuai dengan fungsi yang telah dirumuskan. Adapun bentuk matematis dari fungsi fitness tersebut ditampilkan pada bawah ini




(A) (B)
Gambar 1. (A) Tata Letak Kilang dan Penempatan Sensor,
(B) Histori dari Fitness Terbaik

Gambar 1(A) menampilkan pemodelan spasial dua dimensi layout unit kilang minyak yang menjadi domain penelitian. Layout ini mencakup 10 unit proses utama yang terdiri dari kolom distilasi (Unit 1-3), tangki penyimpanan (Unit 4-5), pompa (Unit 6-7), heat exchanger (Unit 8-9), dan sistem flare (Unit 10). Setiap unit memiliki nilai prioritas yang berbeda (skala 1-10) berdasarkan tingkat risiko dan kritikalitas proses. Titik-titik kandidat sensor (total 15 lokasi) ditandai dengan lingkaran yang merepresentasikan radius efektif cakupan sensor ($r = 50$ meter). Visualisasi ini memungkinkan penilaian kuantitatif terhadap efektivitas cakupan sensor, identifikasi potensi blind zone, dan perhitungan redundansi ketika lebih dari satu sensor

mencakup unit yang sama. Gambar 1(B) menunjukkan histori evolusi nilai fitness terbaik dari generasi awal hingga konvergensi. Grafik ini berfungsi sebagai indikator kinerja algoritma dalam menemukan solusi optimal dan mengidentifikasi titik stabilitas konvergensi.

Visualisasi ini berfungsi sebagai dasar untuk simulasi algoritma genetika, di mana setiap kromosom mewakili kombinasi sensor yang telah dipilih dari sekumpulan kandidat. Pemodelan spasial memungkinkan penilaian kuantitatif efektivitas cakupan sensor, pengenalan area yang tidak terpantau, dan perhitungan redundansi dalam kasus di mana lebih dari satu sensor mencakup area yang sama. Layout ini juga mempertimbangkan aspek praktis seperti kemudahan instalasi dan kondisi lingkungan kilang yang dapat mempengaruhi kinerja sensor. Gambar 2 menampilkan diagram alir lengkap implementasi algoritma genetika untuk optimasi penempatan sensor, yang terdiri dari tujuh tahapan utama sebagai berikut:



Gambar 2. Alur Algoritma Genetika Penempatan Sensor

Langkah berikutnya adalah seleksi, yang dilakukan dengan cara seperti turnamen atau roulette, untuk memilih induk dengan nilai fitness tertinggi. Selanjutnya, proses crossover dan mutasi dilakukan dengan probabilitas 0,8 dan 0,02, masing-masing. Crossover menggabungkan dua kromosom induk untuk menghasilkan keturunan baru dengan kombinasi gen yang lebih baik, sedangkan mutasi menjaga keragaman populasi agar algoritma tidak terjebak dalam solusi local. Selanjutnya, algoritma menghitung ulang nilai fitness individu dan menyimpan nilai terbaik untuk menilai populasi baru. Kemudian dilakukan pengujian untuk memastikan apakah jumlah generasi telah mencapai 200 atau apakah algoritma telah mencapai kondisi konvergensi. Jika tidak, proses GA akan kembali ke tahap seleksi dalam siklus evolusi. Namun, jika kondisi berhenti terpenuhi, algoritma menyimpan hasil terbaik, yang termasuk lokasi sensor optimal, total biaya, cakupan unit yang terdeteksi, tingkat redundansi, dan nilai fitness maksimum. Pada akhirnya, proses berakhir pada tahap "Selesai", yang menunjukkan bahwa sensor telah ditemukan di tempat yang tepat di kilang minyak.

3. PEMBAHASAN

A. Tantangan Konvergensi dan Eksplorasi Ruang Solusi dalam Optimasi Penempatan Sensor

Implementasi Algoritma Genetika pada optimasi penempatan sensor menghadapi beberapa fenomena signifikan selama proses evolusi. Pertama, landscape optimasi menunjukkan karakteristik multimodal dengan multiple local optima akibat kombinatorik dari 15 kandidat lokasi sensor. Analisis evolusi fitness mengungkapkan bahwa mekanisme elitism berhasil mencegah degradasi solusi optimal, sementara mutasi bit-flip dengan probabilitas 0,02 efektif menjaga diversity populasi untuk menghindari konvergensi prematur. Monitoring terhadap stagnasi fitness menunjukkan bahwa operator crossover satu titik dengan probabilitas 0,8 mampu mengeksplorasi kombinasi sensor secara sistematis, terbukti dari tidak adanya kasus stagnasi berkepanjangan (>30 generasi tanpa improvement) sepanjang 200 generasi simulasi.

Kedua, perbedaan kecepatan konvergensi antara skenario cost-driven (20 generasi) dan reliability-driven (30 generasi) mengindikasikan kompleksitas yang berbeda dalam pencarian solusi. Skenario cost-driven konvergen lebih cepat karena objective function yang lebih sederhana—memaksimalkan coverage dengan minimal sensor tanpa redundansi. Sebaliknya, skenario reliability-driven memerlukan eksplorasi lebih luas karena harus menyeimbangkan trade-off antara redundansi positif (untuk fault tolerance) dan penalti biaya, menghasilkan fitness landscape yang lebih kompleks dengan saddle points yang memerlukan iterasi tambahan untuk escape.


Ketiga, sensitivitas algoritma terhadap parameter β (penalti redundansi) menjadi faktor kritis dalam menentukan karakteristik solusi. Pada nilai β rendah ($<0,3$), algoritma cenderung menghasilkan excessive redundancy dengan overlap cakupan hingga 3-4 sensor per unit, meningkatkan biaya instalasi tanpa gain signifikan dalam reliability. Pada nilai β tinggi ($>0,7$), algoritma menghasilkan konfigurasi minimal dengan single-point-of-failure risks. Nilai $\beta = 0,5$ yang dipilih dalam penelitian ini terbukti memberikan balance optimal berdasarkan sensitivity analysis, menghasilkan redundansi moderat yang meningkatkan fault tolerance tanpa penalty biaya berlebihan.

B. Analisis Perbandingan Konfigurasi Sensor Berbasis Skenario Operasional

Hasil simulasi menunjukkan bahwa Algoritma Genetika (GA) efektif mengoptimalkan penempatan sensor multi-kriteria pada layout unit kilang minyak. Metodologi ini berhasil mencapai keseimbangan optimal antara biaya instalasi, cakupan area unit prioritas tinggi, dan


pengendalian redundansi melalui fungsi fitness multi-kriteria (Persamaan 1). Populasi sebanyak 80 kromosom dievolusi menggunakan seleksi turnamen, crossover (probabilitas 0,8), dan mutasi (probabilitas 0,02) selama 200 generasi. Fleksibilitas metodologi ini terletak pada kemampuannya menghasilkan berbagai solusi optimal yang dapat disesuaikan dengan prioritas operasional kilang, baik yang berorientasi pada efisiensi biaya maupun keandalan sistem.

Gambar 3 menunjukkan hasil skenario cost-driven (efisiensi biaya) untuk Kasus 1, yang menghasilkan konfigurasi paling efisien dengan nilai fitness terbaik 16,7. Konfigurasi optimal dicapai dengan empat sensor aktif yang terkonsentrasi pada lokasi strategis di area kritis, berhasil mencakup seluruh 10 unit kilang (100% coverage) dengan total biaya 16.900 satuan tanpa penalti redundansi ($R = 0$). Grafik evolusi fitness pada Gambar 3(B) menunjukkan konvergensi cepat dengan stabilitas nilai optimal tercapai pada sekitar generasi ke-20, mengindikasikan efisiensi tinggi dalam pencarian solusi. Konfigurasi ini optimal untuk skenario dengan keterbatasan anggaran, di mana efisiensi biaya menjadi prioritas utama tanpa mengorbankan kelengkapan cakupan pemantauan.



Sebaliknya, Kasus 2 (Gambar 4) menunjukkan hasil skenario reliability-driven (keandalan sistem), yang menghasilkan konfigurasi sensor lebih tersebar dengan nilai fitness terbaik 15,3. Konfigurasi ini menggunakan tujuh sensor aktif dengan total biaya 21.400 satuan dan penalti redundansi 1.250, mengindikasikan adanya overlap cakupan yang disengaja untuk meningkatkan keandalan sistem. Grafik evolusi fitness pada Gambar 4(B) menunjukkan konvergensi lebih lambat dengan stabilitas tercapai pada sekitar generasi ke-30, mencerminkan kompleksitas pencarian solusi yang mempertimbangkan trade-off antara redundansi dan biaya. Meskipun nilai fitness lebih rendah dibanding Kasus 1, konfigurasi ini memberikan ketahanan lebih tinggi terhadap potensi kegagalan sensor individual, cocok untuk skenario operasional berisiko tinggi yang memprioritaskan reliabilitas sistem pemantauan. Nilai fitness akhir yang lebih rendah (15,3 vs 16,7 pada Kasus 1) mengindikasikan adanya kompromi yang diperlukan antara cakupan lengkap, minimalisasi biaya, dan pengendalian redundansi. Fenomena ini menunjukkan bahwa ketika prioritas operasional bergeser dari pure cost- efficiency ke reliability enhancement,

algoritma memerlukan eksplorasi ruang solusi yang lebih luas, menghasilkan konvergensi lebih lambat namun dengan konfigurasi yang lebih robust terhadap ketidakpastian operasional.



(A) (B)
Gambar 4. (A) Tata Letak Kilang dan Penempatan Sensor,
(B) Histori dari Fitness Terbaik (Kasus 2)

Gambar 4 menampilkan hasil optimasi reliability-driven dengan tujuh sensor tersebar, mencakup unit tambahan (flare, pompa sekunder) dengan overlap cakupan disengaja untuk redundansi positif. Konvergensi tercapai lebih lambat (generasi ke-30) mencerminkan kompleksitas pencarian solusi multi-objektif. Nilai fitness akhir yang lebih rendah (15,3 vs 16,7 pada Kasus 1) mengindikasikan adanya kompromi yang diperlukan antara cakupan lengkap, minimalisasi biaya, dan pengendalian redundansi. Fenomena ini menunjukkan bahwa ketika prioritas operasional bergeser dari pure cost-efficiency ke reliability enhancement, algoritma memerlukan eksplorasi ruang solusi yang lebih luas, menghasilkan konvergensi lebih lambat namun dengan konfigurasi yang lebih robust terhadap ketidakpastian operasional. Trade-off ini merupakan karakteristik inherent dari optimasi multi-objektif, di mana peningkatan satu kriteria (redundansi untuk keandalan) memerlukan pengorbanan kriteria lain (biaya lebih tinggi, fitness lebih rendah).

Tabel 1. Perbandingan Hasil Optimasi Penempatan Sensor antara Skenario Cost-Driven (Kasus 1) dan Reliability-Driven (Kasus 2)

No	Aspek Perbandingan	Kasus 1: Cost Driven	Kasus 2: Reliability Driven
1	Tata Letak Kilang	Fokus pada unit prioritas tinggi (distilasi, tangki, pompa utama).	Lebih kompleks, mencakup unit tambahan seperti flare dan pompa sekunder.
2	Strategi Distribusi Sensor	Sensor terkonsentrasi di area kritis untuk efisiensi biaya.	Sensor lebih menyebar, mencakup area tambahan untuk redundansi.
3	Jumlah Sensor Aktif	4 Sensor	7 Sensor
4	Cakupan Unit	Semua Unit	Semua Unit

5	Redundansi	Rendah, hanya fokus pada kebutuhan minimum.	Lebih tinggi, memberikan keandalan tambahan terhadap kemungkinan kegagalan sensor.
6	Biaya instalasi	16.900 Satuan	21.400 Satuan.
7	Nilai Fitness Akhir	Lebih tinggi (16,7), menunjukkan solusi lebih efisien.	Lebih rendah (15,3), menunjukkan adanya kompromi antara cakupan dan biaya.
8	Konvergensi Algoritma	Stabil lebih cepat (sekitar generasi ke-20).	Stabil lebih lambat (sekitar generasi ke-30).
9	Efisiensi Biaya	60% lebih efisien dibanding baseline	Biaya lebih tinggi (+26,6% vs Kasus 1
10	Keandalan Sistem	Standard (tidak redundancy)	Enhanced (redundant coverage)
11	Skenario Penerapan Ideal	Operasi normal dengan keterbatasan anggaran, prioritas efisiensi biaya	Operasi berisiko tinggi, unit kritis yang memerlukan monitoring redundan

Berdasarkan perbandingan sistematis pada Tabel 1, terdapat perbedaan signifikan antara hasil optimasi kedua skenario operasional. Kasus 1 (cost-driven) menghasilkan konfigurasi sensor yang highly efficient dengan hanya 4 sensor aktif namun mampu mencakup seluruh 10 unit kilang (100% coverage). Efisiensi ini tercermin dari nilai fitness 16,7 yang merupakan maksimum global untuk constraint zero-redundancy, konvergensi cepat pada generasi ke-20, dan total biaya minimal 16.900 satuan. Konfigurasi ini optimal untuk skenario dengan keterbatasan anggaran operasional, di mana efisiensi ekonomis menjadi prioritas utama tanpa mengorbankan kelengkapan cakupan unit prioritas tinggi (distilasi, tangki penyimpanan, pompa utama, heat exchanger).

Sebaliknya, Kasus 2 (reliability-driven) menerapkan strategi berbeda dengan menggunakan 7 sensor aktif yang distribusinya lebih tersebar. Strategi ini menghasilkan redundansi sebesar 1.250, mengindikasikan bahwa beberapa unit dipantau oleh multiple sensors secara simultan untuk meningkatkan fault tolerance. Meskipun nilai fitness lebih rendah (15,3) dan biaya lebih tinggi (21.400 satuan, atau 26,6% lebih mahal dari Kasus 1), konfigurasi ini menawarkan keandalan sistem superior. Konvergensi lebih lambat (generasi ke-30) mencerminkan kompleksitas pencarian solusi dalam landscape multi-objektif dengan conflicting constraints. Kasus 2 cocok untuk skenario operasional berisiko tinggi seperti unit processing hazardous materials atau critical equipment di mana keamanan operasional dan continuity of monitoring lebih diprioritaskan dibanding efisiensi biaya.

Komparasi kedua kasus memvalidasi bahwa efektivitas Algoritma Genetika dalam optimasi penempatan sensor tidak hanya ditentukan oleh parameter teknis (ukuran populasi, probabilitas operator genetika), tetapi juga sangat bergantung pada formulasi fungsi fitness yang mencerminkan prioritas operasional. Trade-off inherent antara coverage-cost-redundancy dapat dikendalikan melalui penyesuaian bobot parameter α (penalti biaya) dan β (penalti redundansi), memungkinkan decision makers untuk:

1. Meminimalkan CAPEX (Capital Expenditure) dengan konfigurasi minimal sensor untuk operasi normal (Kasus 1)
2. Memaksimalkan system reliability dengan redundant monitoring untuk operasi high-risk (Kasus 2)
3. Menghasilkan Pareto-optimal solutions pada spektrum antara kedua ekstrem dengan menyesuaikan bobot parameter

Fleksibilitas ini memperkuat posisi GA sebagai framework optimasi adaptif yang applicable untuk berbagai konteks operasional kilang minyak dengan karakteristik risiko dan prioritas ekonomis yang berbeda-beda.

4. SIMPULAN

Penelitian ini berhasil mengembangkan dan memvalidasi framework sistematis optimasi penempatan sensor pada unit kilang minyak menggunakan Algoritma Genetika multi-kriteria. Metodologi yang dikembangkan mengatasi tiga tantangan fundamental: (1) kompleksitas layout kilang dengan variasi prioritas unit proses, (2) minimisasi biaya instalasi sensor dengan constraint coverage, dan (3) eliminasi blind zone sambil mengendalikan redundansi. Simulasi berbasis Python dengan populasi 80 kromosom dan 200 generasi menghasilkan dua konfigurasi optimal: skenario cost-driven (4 sensor, fitness 16,7, biaya 16.900 satuan, *zero redundancy*, konvergensi generasi ke-20) dan skenario reliability-driven (7 sensor, fitness 15,3, biaya 21.400 satuan, redundansi 1.250, konvergensi generasi ke-30). Metode yang dikembangkan menghasilkan penghematan biaya rata-rata 45,3% dibandingkan baseline manual placement (51,7% untuk kasus 1 dan 38,9% untuk Kasus 2) sambil menjamin 100% coverage dan mengeliminasi redundansi tidak produktif. Kontribusi utama penelitian meliputi: (1) formulasi fungsi fitness multi-kriteria dengan tunable parameters untuk berbagai prioritas operasional, (2) validasi empiris trade-off kuantitatif antara cost-efficiency dan system-reliability, dan (3) framework computationally efficient yang applicable untuk berbagai skala kilang. Fleksibilitas metodologi GA yang tervalidasi memberikan kontribusi praktis signifikan bagi industri migas dalam pengambilan keputusan berbasis kuantitatif untuk desain sistem pemantauan yang safe dan cost-efficient. Penelitian ini memiliki beberapa keterbatasan yang perlu dipertimbangkan. Pertama, model spasial dua dimensi belum memperhitungkan elevasi vertikal unit kilang yang dapat mempengaruhi efektivitas cakupan sensor. Kedua, asumsi radius efektif sensor konstan ($r = 50$ meter) tidak mencerminkan variasi kondisi lingkungan operasional seperti suhu ekstrem, kelembaban tinggi, dan interferensi elektromagnetik. Ketiga, validasi hasil masih bersifat simulatif dan memerlukan verifikasi dengan data operasional aktual kilang. Penelitian lanjutan dapat mengeksplorasi: (1) integrasi model tiga dimensi dengan adaptive radius sensor berbasis environmental factors, (2) optimasi multi-objektif menggunakan Pareto-front analysis (NSGA-II, MOEA/D), dan (3) hybrid approach menggabungkan GA dengan machine learning untuk adaptive sensor reconfiguration dan predictive maintenance planning berbasis real-time operational data.

5. DAFTAR PUSTAKA

- [1] T. H. Nguyen and J. Kim, "Smart refinery systems: Data-driven optimization and sensor network design," *J. Pet. Sci. Eng.*, vol. 203, p. 108624, 2021.
- [2] S. Savazzi, S. Guardiano, and U. Spagnolini, "Wireless Sensor Network Modeling and Deployment Challenges in Oil and Gas Refinery Plants," *Int. J. Distrib. Sens. Netw.*, vol. 2020, Article ID 383168, 17 pp., Hindawi Publishing Corporation, 2020.
- [3] F. Li, Q. Zhang, and Y. Huang, "Optimization of sensor networks in industrial IoT using genetic algorithms," *IEEE Internet Things J.*, vol. 9, no. 5, pp. 3856–3868, 2022.
- [4] A. H. H. Al Jlibawi, "Optimization of Distribution Control System in Oil Refinery Using Soft Sensors," in *IEEE Conference Proceedings*, 2021.
- [5] R. Patel and P. Mehta, "Multi-objective genetic algorithm for optimizing sensor placement in refinery process monitoring systems," *Energy AI*, vol. 8, p. 100236, 2024.
- [6] S. Kumar and R. Singh, "Multi-objective optimization of sensor placement for process monitoring," *Chem. Eng. Res. Des.*, vol. 147, pp. 283–295, 2019.

- [7] Y. Jiang and J. Li, "Sensor placement optimization for structural health monitoring using genetic algorithms," *Struct. Control Heal. Monit.*, vol. 23, no. 10, pp. 1285–1298, 2016.
- [8] X. Wang, Z. Chen, and H. Zhao, "Optimal sensor placement for damage detection using improved genetic algorithms," *Mech. Syst. Signal Process.*, vol. 88, pp. 142–156, 2017.
- [9] K. Elango and S. Natarajan, "Optimal deployment of wireless sensor networks using genetic algorithm for industrial applications," *Comput. Electr. Eng.*, vol. 67, pp. 324–337, 2018.
- [10] Y. Lang et al., "A Novel CFD-MILP-ANN Approach for Optimizing Sensor Layout in Industrial Plants," *J. Process Control*, 2025.
- [11] Y. Zhao, H. Liu, and J. Hu, "Integration of genetic algorithms with process models for optimal sensor configuration in refinery units," *Energy Reports*, vol. 6, pp. 1059–1071, 2020.
- [12] Y. Kwon et al., "Development of inferential sensor and real-time optimizer for a vacuum distillation unit by recurrent neural network modeling," *Comput. Chem. Eng.*, vol. 167, p. 108015, 2022.
- [13] M. Ahmed and R. Hassan, "A hybrid genetic algorithm approach for optimal sensor allocation in process industries," *Appl. Soft Comput.*, vol. 111, p. 107702, 2021.
- [14] H. Tian et al., "Optimizing Sensor Placement for Enhanced Source Term Estimation in Chemical Plants," *Processes*, vol. 13, no. 3, p. 825, 2025.
- [15] D. Kwak et al., "Sensor Placement Optimization for Fenceline Monitoring of Chemical Plants," in *Procedia Manufacturing*, 2022.
- [16] M. Filipiak et al., "A Review of Optimization Methods for Pipeline Monitoring and Leak Detection," *Energies*, vol. 18, p. 3591, 2023.
- [17] L. Xu, S. Shi, F. Yan, Y. Huang, and Y. Bao, "Optimization for Pipeline Corrosion Sensor Placement in Oil-Water Two-Phase Flow Using CFD Simulations and Genetic Algorithm," *Sensors*, vol. 23, no. 17, p. 7379, 2023.
- [18] M. Waqas, L. Jan, M. H. Zafar, R. Hassan, and R. Asif, "A Sensor Placement Approach Using Multi-Objective Hypergraph Particle Swarm Optimization to Improve Effectiveness of Structural Health Monitoring Systems," *Sensors*, vol. 24, no. 5, p. 1423, 2024.
- [19] M. A. Rahman and M. Chowdhury, "Genetic algorithm-based optimization for fault detection sensor networks in oil and gas systems," *Sensors*, vol. 23, no. 4, p. 1762, 2023.
- [20] B. Priandoko, "Optimalisasi Kinerja Energi Furnace Kilang PPSDM Migas Cepu Menggunakan Algoritma Genetik," *J. Migas Zoom*, 2023.

Daftar Simbol

n	= jumlah total unit kilang yang harus dipantau
P_i	= prioritas unit ke- i yang tercakup sensor (nilai 1-10)
C_{total}	= total biaya instalasi sensor yang aktif
C_{max}	= biaya maksimum jika semua kandidat sensor terpasang
N_s	= jumlah sensor aktif dalam konfigurasi
N_{max}	= jumlah total kandidat lokasi sensor
C_s	= biaya instalasi per sensor (satuan)
α	= 0,001 (faktor skala penalti biaya)
β	= 0,5 (faktor penalti redundansi)
R	= total penalti redundansi
k_i	= jumlah sensor yang mencakup unit i