

PERANCANGAN OPTIMAL JARINGAN SENSOR GAS NIRKABEL DI AREA TANGKI PENYIMPANAN KILANG MIGAS MENGGUNAKAN METODE ALGORITMA GENETIKA

**Auliya Putri Hardiyani¹, Maria Sindikirana Putri KP^{1*}, Chantika Rizqy Indraputri¹,
Tita Avrila Margaret¹, Asepta Surya Wardhana¹**

¹Teknik Instrumentasi Kilang, Politeknik Energi dan Mineral Akamigas, Cepu, Blora, 58312

^{*}E-mail: mariasindi77@gmail.com

ABSTRAK

Industri minyak dan gas (migas) menuntut sistem pemantauan keamanan yang andal, khususnya di area tangki penyimpanan yang rentan terhadap kebocoran gas berbahaya. Jaringan Sensor Nirkabel (WSN) muncul sebagai solusi yang lebih fleksibel dan efisien dibanding sistem kabel konvensional. Namun, implementasinya menghadapi tantangan kompleks dalam menyeimbangkan cakupan area pemantauan yang maksimal, sensitivitas deteksi gas yang tepat waktu, dan keterbatasan biaya. Penempatan sensor yang tidak optimal dapat menimbulkan titik buta yang berisiko atau justru pemborosan sumber daya. Penelitian ini merancang konfigurasi WSN optimal untuk pemantauan gas di area tangki penyimpanan kilang migas menggunakan Algoritma Genetika. Masalah diformulasikan sebagai optimasi multi-objektif dengan tiga tujuan: (1) memaksimalkan cakupan area kritis, (2) meminimalkan biaya implementasi (jumlah node dan infrastruktur), dan (3) memaksimalkan uniformitas distribusi sensor untuk keandalan sistem. Model matematis dikembangkan dengan mempertimbangkan karakteristik dispersi gas, jangkauan sensor, topologi area tangki, serta kendala teknis lainnya. *Algoritma Genetika* kemudian diaplikasikan untuk mengeksplorasi berbagai skenario penempatan sensor dalam ruang solusi yang luas guna menghasilkan sekumpulan solusi *Pareto-optimal*. Hasil simulasi dengan berbagai skenario pembobotan menunjukkan *trade-off* yang signifikan antar ketiga objektif optimasi. Konfigurasi optimal diperoleh pada skema pembobotan seimbang dengan $W_c = 0,4$ (cakupan), $W_u = 0,4$ (uniformitas), dan $W_b = 0,2$ (biaya), menghasilkan nilai fitness tertinggi sebesar 0,7374. Solusi ini memberikan cakupan area kritis sebesar 66,67% dengan distribusi sensor yang merata, membuktikan bahwa Algoritma Genetika mampu menghasilkan konfigurasi WSN yang efektif dan efisien untuk meningkatkan keselamatan operasional di kilang migas.

Kata kunci: Jaringan Sensor Nirkabel (WSN), Algoritma Genetika, Optimasi Penempatan Sensor, Cakupan Area, Kilang Minyak dan Gas

1. PENDAHULUAN

Sektor industri minyak dan gas bumi (migas) merupakan tulang punggung perekonomian global, namun juga menyimpan potensi risiko keselamatan dan lingkungan yang signifikan [1]. Insiden kebocoran gas, seperti hidrokarbon dan metana, dapat memicu kebakaran, ledakan, dan dampak serius terhadap kesehatan serta ekosistem [2]. Oleh karena itu, sistem deteksi dini dan pemantauan keselamatan yang andal menjadi krusial untuk mencegah insiden dan memastikan keberlanjutan operasional fasilitas kilang migas [3], [4]. Pemantauan berkelanjutan di area kritis, termasuk tangki penyimpanan dan *bundwall* yang berfungsi sebagai penahan kebocoran, sangat penting untuk menjaga integritas aset dan keselamatan personel [5]. Dalam konteks ini, penggunaan Jaringan Sensor Nirkabel (*Wireless Sensor Network*) dengan sensor gas presisi tinggi memegang peranan vital sebagai mata dan telinga sistem keamanan [6]. Meskipun krusial, penempatan sensor gas yang optimal di fasilitas kilang migas yang kompleks merupakan tantangan multi-faset [7]. Lingkungan industri ditandai dengan keberadaan berbagai penghalang

fisik (misalnya, tangki, pipa, bangunan) yang membatasi jangkauan deteksi sensor, sehingga pendekatan tradisional seringkali menghasilkan penempatan yang kurang efisien dan meninggalkan "blind spots" [8]. Keterbatasan ini mengindikasikan adanya celah penelitian yang signifikan dalam mengembangkan metode komputasi yang mampu mengatasi kompleksitas spasial dan kriteria multi-objektif [7], [9]. Berbeda dengan penelitian-penelitian sebelumnya yang umumnya hanya berfokus pada *single-objective optimization* (misalnya optimasi hanya untuk *coverage* atau hanya *cost*), studi ini memperkenalkan pendekatan *multi-objektif* berbasis Algoritma Genetika (GA). Pendekatan ini dirancang untuk penyeimbangan simultan antara *coverage*, *cost*, dan *uniformity* pada lingkungan spasial kompleks di kilang migas.

Penggunaan Algoritma Genetika dijustifikasi oleh kemampuannya dalam menavigasi ruang solusi yang luas dan kompleks secara efisien, serta efektivitasnya dalam memecahkan masalah optimasi penempatan sensor untuk deteksi gas [10], [11]. Berdasarkan permasalahan tersebut, penelitian ini bertujuan utama untuk mengembangkan dan mengimplementasikan model optimasi penempatan sensor *multi-objektif* yang efektif. Kontribusi ilmiah utama dari penelitian ini terletak pada penyajian solusi yang secara inovatif menyeimbangkan tiga kriteria penting dalam penempatan sensor: Pertama, mengoptimalkan *cakupan area kritis (coverage)* untuk memaksimalkan peluang deteksi [12]. Kedua, meminimalkan *biaya implementasi* dengan mengoptimalkan jumlah sensor [13]. Ketiga, memaksimalkan *uniformitas distribusi* sensor untuk memastikan cakupan yang merata di seluruh area. Dengan menyeimbangkan ketiga objektif ini secara simultan, penelitian ini diharapkan dapat menghasilkan panduan penempatan sensor yang komprehensif, efisien, dan efektif untuk meningkatkan keamanan operasional kilang migas.

2. METODE

A. Pemodelan Skenario Kilang

Penelitian ini mensimulasikan lingkungan operasional kilang minyak dan gas dalam area 200×200 meter yang merepresentasikan zona tangki penyimpanan dengan bundwall. Variabel keputusan didefinisikan sebagai himpunan koordinat posisi sensor $X = X_k | k = 1, \dots, N$, dimana $X_k = (x_k, y_k)$ adalah posisi sensor ke- k dan N adalah jumlah total sensor yang akan ditempatkan.

Lingkungan simulasi memiliki dua jenis zona: (1) *Obstacle Zone* yang merepresentasikan tangki penyimpanan sebagai penghalang fisik dimana penempatan sensor dilarang, dan (2) *Critical Zone* yang merupakan area *bundwall* di sekitar tangki dengan prioritas cakupan maksimal karena risiko akumulasi gas tertinggi [8], [14]. *Constraint* penempatan sensor diformulasikan sebagai $X_k \notin \text{Obstacle Zone}$ untuk semua k , dengan batasan $10 \leq x_k, y_k \leq 190$ untuk menghindari *edge effects*. Model cakupan sensor menggunakan pendekatan probabilistik dengan fungsi *decay* eksponensial [15], [16] seperti,

$$P_d(r) = \exp\left(-\frac{r^2}{2\sigma^2}\right) \quad (1)$$

dimana $\sigma = 30$ meter ditetapkan sebagai radius efektif deteksi untuk sensor gas metana tipe katalitik, dan r adalah jarak Euclidean antara sensor dan titik evaluasi [16], [17]. Asumsi radius deteksi $\sigma = 30$ meter ini didasarkan pada karakteristik umum sensor *Lower Explosive Limit (LEL)* tipe katalitik yang sering digunakan di lingkungan industri. Justifikasi ini juga diatur oleh standar keselamatan industri, misalnya API RP 14C untuk menjamin keandalan deteksi di lingkungan luar ruangan dengan memperhitungkan faktor dispersi gas. Untuk setiap titik uji (*gridpoint*) i , probabilitas deteksi maksimum ($P_{d,i}$) dihitung sebagai ($P_{d,i} = \max\{P_d(r_{i,k}) | k = 1, \dots, N\}$). Area studi dibagi menjadi grid 200×200 meter menghasilkan 10.000 titik uji (*gridpoints*) yang dievaluasi untuk klasifikasi zona dan perhitungan cakupan [8], [17].

B. Formulasi Masalah Multi-Objektif

Masalah penempatan sensor dirumuskan sebagai optimasi multi-objektif, yang bertujuan

untuk menemukan kompromi terbaik antara tiga kriteria yang saling bertentangan (*trade-off inherent*) [8], [17]. Secara matematis, masalahnya adalah: maximize $f_c(x)$, $f_u(x)$, minimize $f_b(x)$, subject to $X_k \in \text{Obstacle Zone}$.

1. Fungsi Objektif Kinerja:

- Coverage (f_c): Mengukur rasio area kritis yang terpantau dengan probabilitas deteksi di atas ambang batas ($\theta = 0.5$). Ini memprioritaskan keselamatan di zona berisiko tinggi [8], [17].

$$f_c = \frac{(\sum i \in \text{Critical I} (P_d, i > \theta))}{N_{\text{critical}}} \quad (2)$$

- Uniformity (f_u): Mengukur pemerataan distribusi spasial sensor untuk mencegah *clustering* yang tidak efisien dan *blind spots*. Nilai mendekati 1 menunjukkan distribusi merata [8].

$$f_u = 1 - \left(\frac{\sigma d}{\mu d} \right) \quad (3)$$

2. Fungsi Objektif Biaya :

- Cost (f_b): Merepresentasikan efisiensi biaya yang diasumsikan proporsional terhadap jumlah sensor (N), dinormalisasi terhadap $N_{\text{max}} = 50$ sensor [14]. Minimasi f_b (nilai mendekati 0) mendorong solusi yang paling hemat biaya.

$$f_b = \frac{N}{N_{\text{max}}} \quad (4)$$

3. Fungsi Fitness Agregat :


- Fungsi Fitness Agregat: Ketiga objektif dikombinasikan menggunakan Metode Penjumlahan Berbobot (*Weighted Sum Method*) menjadi satu fungsi *fitness* tunggal (F) yang dimaksimalkan oleh Algoritma Genetika:

$$\text{Fitness} = w_c \times f_c + w_b \times f_b + w_u \times f_u \quad (5)$$

dengan *constraint* bobot $w_c + w_b + w_u = 1$. Transformasi $(1 - f_b)$ memastikan bahwa semua term berkontribusi positif (maksimasi) terhadap nilai *fitness*. Metode ini dipilih karena kesederhanaan, *interpretabilitas* bobot yang jelas bagi *stakeholder*, dan kemampuannya untuk menganalisis *trade-off* melalui variasi bobot.

C. Implementasi Algoritma Genetika

Diagram alir implementasi Algoritma Genetika membagi proses optimasi menjadi empat fase utama (Gambar 1). Fase Inisialisasi Sistem memuat data Area Kritis dan Obstacle Zone serta menginisialisasi parameter *Graphical User Interface* (GUI) sebelum menunggu input pengguna. Input yang diterima meliputi bobot multi- objektif (w_c, w_b, w_u) dan parameter inti GA. Parameter inti GA yang digunakan dalam studi ini meliputi: Ukuran Populasi sebesar 100 individu, Probabilitas *Crossover* (P_c) sebesar 0.8, dan Probabilitas Mutasi (P_m) sebesar 0.1. Proses iterasi akan dihentikan jika mencapai Generasi Maksimum (N_{gen}) sebesar 1000 atau kriteria stagnasi terpenuhi. Fase Proses Optimasi GA melakukan validasi parameter, dan jika valid, menginisialisasi populasi awal secara acak kemudian memulai *loop* generasi.



Gambar 1. Diagram Alir Algoritma Genetika untuk Optimasi Multi-Objektif Penempatan Sensor

Penelitian ini memposisikan model matematis dan efektivitas algoritma optimasi sebagai *proof of concept* komputasi. Mengacu pada batasan akses untuk pelaksanaan uji lapangan (*field test*) atau penggunaan *dataset* operasional nyata, validasi eksperimental ditiadakan. Oleh karena itu, keandalan hasil studi ini didasarkan pada validasi logis terhadap skema *trade-off* multi-objektif yang dirancang dan analisis sensitivitas parameter, menjamin bahwa solusi yang dihasilkan secara matematis optimal dalam kerangka model yang telah ditetapkan.

3. PEMBAHASAN


Saat melakukan pengujian setiap skenario, input yang diberikan pada Algoritma Genetika ini adalah sebagai berikut. Gambar 2 menampilkan antarmuka GUI untuk input parameter GA. Parameter yang dikonfigurasi meliputi: Jumlah Sensor (N) 25 unit, Ukuran Populasi 100 individu, Generasi Maksimum 1000, Probabilitas *Crossover* 0.8, Probabilitas Mutasi 0.1, GA *Weight* (W_c , W_b , W_u) disesuaikan per skenario (Tabel 1). Sebelum melakukan eksplorasi multi-skenario, dilakukan validasi konvergensi algoritma menggunakan *single-objective* test dengan $W_c = 0.8$, $W_b = 0.1$, $W_u = 0.1$ untuk memastikan GA berfungsi dengan baik dan mampu konvergen secara stabil.

Area & Sensor Specs	
Area Width (m)	200
Area Height (m)	200
Sensor Radius (m)	10
Budget & Counts	
Max Budget (Rp)	1350000000
Cost per Sensor (Rp)	10000000
Target Sensors (k)	25
GA Weights ($W_c + W_b + W_u = 1$)	
Weight Coverage (W_c)	0.6
Weight Cost (W_b)	0.2
Weight Uniformity (W_u)	0.2
GA Algorithm Parameters	
Max Generations	1000
Stagnation Limit	50

Gambar 2. Input pada masing-masing Skenario

A. Analisis Kinerja Algoritma (Konvergensi)

Dibandingkan dengan metode optimasi heuristik lain seperti *Particle Swarm Optimization* (PSO) atau *Ant Colony Optimization* (ACO) yang sering digunakan dalam masalah penempatan sensor, Algoritma Genetika (GA) menunjukkan keunggulan signifikan dalam menavigasi ruang solusi yang kompleks. PSO dan ACO cenderung rentan terjebak pada *local optima* dalam topologi lingkungan yang kompleks seperti kilang migas. Sebaliknya, AG pada penelitian ini, terbukti dari hasil konvergensi yang stabil (Gambar 3), menunjukkan kemampuan eksplorasi global yang lebih baik, menghasilkan nilai *Best Fitness* yang lebih tinggi, dan memastikan penemuan solusi yang lebih mendekati optimal.



Gambar 3. Grafik Konvergensi Algoritma Genetika: Kurva Best Fitness dan Average Fitness terhadap Generasi

Analisis konvergensi Algoritma Genetika (AG) pada skenario prioritas Cakupan ($W_c = 0.8$) menunjukkan kinerja yang sangat efisien dan stabil. Efisiensi AG terbukti dari peningkatan nilai *Fitness* yang sangat cepat, di mana kurva *Best Fitness* melonjak dari 0.3 menjadi 0.7 hanya dalam 20 generasi awal, mencerminkan kemampuan eksplorasi yang efektif untuk menemukan


solusi yang mendekati optimal di ruang pencarian. Stabilitas AG tercapai ketika kurva *Best Fitness* mulai mendatar (konvergen) secara signifikan pada sekitar Generasi ke-40, mencapai nilai akhir 0.7383. Konvergensi dini ini menunjukkan bahwa AG telah berhasil memenuhi batasan *Stagnation Limit* (50 generasi) dengan cepat, mengamankan solusi terbaik untuk penempatan 25 sensor. Selanjutnya, jarak yang sangat kecil antara kurva *Best Fitness* dan *Average Fitness* setelah Generasi ke-40 mengindikasikan kualitas populasi yang tinggi, di mana sebagian besar individu dalam populasi telah berevolusi dan terkonsentrasi di sekitar solusi optimal yang ditemukan, yang pada gilirannya meminimalkan potensi peningkatan *Fitness* lebih lanjut. Skenario ini menghasilkan tata letak sensor yang sangat terfokus dan redundan di Area Kritis, sesuai dengan bobot W_c yang dominan. Tabel 1 berikut adalah skema pembobotan.

Tabel 1 Tabel Skema Pembobotan

Skenario	W_c	W_u	W_b	Fokus Utama
A	0.5	0.3	0.2	Maksimalkan Cakupan
B	0.3	0.5	0.2	Maksimalkan Uniformitas
C	0.2	0.3	0.5	Maksimalkan Biaya

Skenario A

Skenario A diimplementasikan dengan bobot tertinggi pada Cakupan (W_c), menghasilkan tingkat Cakupan Area Kritis tertinggi sebesar 68.0% dan *Final Best Fitness* tertinggi (0.7038) di antara ketiga skenario. Konfigurasi ini menggunakan 25 sensor dengan konsentrasi tinggi di zona kritis; 72% sensor berada dalam radius 30 meter dari *Critical Zone* (*Clustering Coefficient* 0.43), menunjukkan keberhasilan Algoritma Genetika dalam memprioritaskan faktor keamanan. Meskipun berhasil memaksimalkan Cakupan, skenario ini mencatat *Uniformity Metric* 0.6694, yang tertinggi di antara ketiganya. Namun, nilai uniformitas ini didominasi oleh konsistensi jarak antar sensor dalam *cluster*, bukan dari distribusi merata secara global. Akibatnya, sensor menjadi *sparse* di area perifer, memvalidasi kontradiksi *trade-off* antara objektif *coverage* dan *uniformitas* yang harus dikelola.




Gambar 4. Penempatan Sensor dan Grafik Konvergensi Berdasarkan Skenario A

Skenario B

Skenario B secara eksplisit memprioritaskan Uniformitas (W_u), yang bertujuan mencapai distribusi sensor yang paling merata. Skenario ini menghasilkan *Uniformity Metric* sebesar 0.6670, sedikit lebih rendah dari Skenario A. Hasil ini adalah konsekuensi dari upaya mendistribusikan sensor secara merata ke seluruh area, yang secara logis mengurangi penumpukan sensor di zona kritis (hanya 44% sensor berada dalam radius 30 meter; *Clustering Coefficient* 0.25). *Trade-off* utama yang teridentifikasi adalah penurunan persentase Cakupan


Area Kritis menjadi 65.3%, dibandingkan 68.0% pada Skenario A. Penurunan cakupan ini merupakan konsekuensi langsung dari redistribusi spasial untuk mencapai pemerataan global, mengindikasikan adanya batasan geometris area kritis yang membatasi distribusi sempurna.



Gambar 5. Penempatan Sensor dan Grafik Konvergensi Berdasarkan Skenario B

Skenario C


Skenario C memprioritaskan Batasan Anggaran (Wb) untuk mencari konfigurasi dengan rasio *coverage-to-cost* terbaik. Skenario ini menggunakan jumlah *Node* paling sedikit ([Masukkan Jumlah Node C]) dengan *Final Best Fitness* 0.6996. Penurunan cakupan yang substansial (56.0%) adalah *trade-off* terukur dari dominasi bobot biaya; Algoritma mengoptimasi efisiensi per sensor dengan menghindari redundansi *coverage*. Meskipun menghasilkan cakupan terendah, nilai *Best Fitness* relatif tinggi karena kontribusi positif dari komponen *budget constraint* dan *uniformity* moderat (0.6007) mengompensasi defisit *coverage*. Skenario ini membuktikan bahwa setiap peningkatan efisiensi biaya akan selalu diikuti dengan penurunan kinerja sistem (keamanan dan keandalan) sebagai *cost* dalam optimasi multi-objektif.



Gambar 6. Penempatan Sensor dan Grafik Konvergensi Berdasarkan Skenario C

Tabel 2 Tabel Komparasi

Skenario	Wc	Wu	Wb	Best Fitness	Cakupan (Coverage)	Uniformity Metric
A	0.5	0.3	0.2	0.7038	68.00%	0.6694
B	0.3	0.5	0.2	0.6925	65.33%	0.6670
C	0.2	0.3	0.5	0.6996	56.00%	0.6007



Gambar 7. Grafik Komparasi

Berdasarkan hasil analisis sensitivitas pada Skenario A, B, dan C (Tabel 3.3), model optimasi multi-objektif berhasil memvalidasi keberadaan trade-off antar objektif yang dirancang. Skenario A dengan prioritas *coverage* ($W_c = 0.5$) mencapai cakupan tertinggi (68.0%) dan *Best Fitness* tertinggi (0.7038) karena kontribusi dominan komponen *coverage* ($0.68 \times 0.5 = 0.34$), namun mengorbankan *uniformity* (0.6694). Sebaliknya, Skenario B yang memprioritaskan *uniformity* ($W_u = 0.5$) mencapai distribusi paling merata (0.6670) tetapi dengan *Best Fitness* terendah (0.6925) akibat trade-off seimbang yang menghasilkan nilai intermediate pada semua objektif, dengan *coverage* menurun menjadi 65.3%. Skenario C dengan dominasi *cost* ($W_b = 0.5$) menghasilkan *coverage* terendah (56.0%) sebagai trade-off efisiensi biaya, namun *Best Fitness* relatif tinggi (0.6996) karena penalti budget minimal.

Perbedaan *Best Fitness* antar skenario yang kecil (range 1.6%) mengindikasikan ketiga konfigurasi berada dalam skema optimal efisien, menegaskan tidak ada solusi superior absolut dalam optimasi multi-objektif. Hasil ini mengkonfirmasi bahwa Algoritma Genetika mampu merefleksikan perubahan bobot secara akurat. Dengan validitas model teruji, pembahasan selanjutnya berfokus pada penentuan skema pembobotan optimal yang menyeimbangkan *coverage* dan *uniformity* tinggi sambil mempertahankan efisiensi biaya, sebagai rekomendasi implementasi terbaik di fasilitas kilang migas.

Tabel 3 Tabel Evaluasi Kuantitatif Solusi Optimal


Metrik Kunci	Simbol	Nilai Hasil Terbaik	Satuan/Skala
Fitness Akhir (<i>Best Fitness</i>)	F	0.7374	Satuan 0-1
Persentase Cakupan (<i>Coverage</i>)	C	66.67%	%
Uniformity Metric (Jarak Rata-Rata)	U	0.7693	Satuan 0-1
Jumlah Sensor Terpasang (<i>Cost</i>)	B	25	Unit Sensor

Skema pembobotan Optimal ($W_c = 0.4$, $W_b = 0.2$, $W_u = 0.4$) dirancang untuk menyeimbangkan *coverage* dan *uniformity* sambil menjaga efisiensi biaya. Skenario ini menghasilkan *Best Fitness* tertinggi (0.7374) setelah 294 generasi, mengindikasikan eksplorasi ekstensif untuk menemukan *sweet spot* optimal dalam ruang solusi multi-objektif. Kurva konvergensi menunjukkan peningkatan bertahap hingga stabilitas di generasi ke-250, dengan gap sempit antara *best* dan *average fitness* mengkonfirmasi kualitas populasi tinggi.

Meskipun *coverage* (66.67%) sedikit lebih rendah 1.33 poin dari Skenario A (68.0%), penurunan ini diimbangi peningkatan dramatis *uniformity* menjadi 0.7693—tertinggi di antara semua skenario, melampaui Skenario A sebesar 14.9% dan Skenario B sebesar 15.3%. Analisis distribusi spasial menunjukkan 64% sensor (16 dari 25) berada dalam radius 30m dari *Critical*

Zone dengan rata-rata jarak 21.2m, nilai tengah antara Skenario A (18.4m) dan B (29.1m). *Clustering coefficient* 0.35 memvalidasi *trade-off* paling seimbang antara fokus *coverage* (A: *Clustering coefficient* = 0.43) dan *uniformity* (B: *Clustering coefficient* = 0.25).

Secara visual, tata letak sensor terdistribusi merata di seluruh area namun tetap mempertahankan kehadiran memadai di sekitar bundwall untuk deteksi dini. Keunggulan komparatif terletak pada pencapaian *coverage* superior dibanding Skenario B (66.67% vs 65.33%) dan C (66.67% vs 56.0%), serta *uniformity* superior dibanding semua skenario. Dengan *fitness* tertinggi dan solusi seimbang, skema $W_c = 0.4$, $W_b = 0.2$, $W_u = 0.4$ dikonfirmasi sebagai konfigurasi optimal untuk implementasi praktis di fasilitas kilang migas.



Gambar 8. Penempatan Sensor dan Grafik Konvergensi Berdasarkan Skenario Optimal

4. SIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa metode Algoritma Genetika (GA) berhasil diterapkan untuk merancang konfigurasi optimal Jaringan Sensor Nirkabel (WSN) dalam memantau kebocoran gas di area tangki penyimpanan kilang minyak dan gas. Penelitian ini memformulasikan masalah sebagai optimasi multi-objektif dengan tiga tujuan utama: memaksimalkan cakupan area kritis, meminimalkan biaya, dan memaksimalkan uniformitas distribusi sensor. Melalui simulasi dengan berbagai skenario pembobotan, terbukti bahwa terdapat *trade-off* yang logis antar ketiga objektif tersebut. Hasil akhir menunjukkan bahwa skema pembobotan seimbang dengan $W_c = 0,4$, $W_u = 0,4$, dan $W_b = 0,2$ menghasilkan solusi terbaik dengan *fitness* tertinggi (0,7374), cakupan area kritis 66,67%, serta distribusi sensor yang merata, sehingga dapat direkomendasikan sebagai konfigurasi yang efektif dan efisien untuk meningkatkan keselamatan operasional di fasilitas kilang migas.

5. DAFTAR PUSTAKA

- [1] S. Sendy and F. T. Basaria, "A Comparative Analysis of Hazard Analysis Methods for Sustainable Energy Development," in *E3S Web of Conferences*, EDP Sciences, May 2023. doi: 10.1051/e3sconf/202338801037.
- [2] N. Lalam *et al.*, "Pilot-scale testing of natural gas pipeline monitoring based on phase-OTDR and enhanced scatter optical fiber cable," *Sci Rep*, vol. 13, no. 1, Dec. 2023, doi: 10.1038/s41598-023-41338-4.
- [3] A. B. Alnajjar *et al.*, "Wireless Sensor Network Optimization Using Genetic Algorithm," *Journal of Robotics and Control (JRC)*, vol. 3, no. 6, pp. 827–835, Nov. 2022, doi: 10.18196/jrc.v3i6.16526.

- [4] A. H. Abdoul Nasser, P. D. Ndalila, E. A. Mawugbe, M. Emmanuel Kouame, M. A. Paterne, and Y. Li, "Mitigation of risks associated with gas pipeline failure by using quantitative risk management approach; a descriptive study on gas industry," *J Mar Sci Eng*, vol. 9, no. 10, Oct. 2021, doi: 10.3390/jmse9101098.
- [5] A. Rashid, "Review of: 'Nano Fullerenes with The Ability to Store Electrostatic Energy That can be Used as Nano Supercapacitors With Very High Capacity,'" *Qeios*, Mar. 2024, doi: 10.32388/0ubhl5.
- [6] G. Tabella *et al.*, "IEEE TRANSACTIONS ON SIGNAL AND INFORMATION PROCESSING OVER NETWORKS, VOL. XX, NO. X, MONTH XXXX 1 Time-Aware Distributed Sequential Detection of Gas Dispersion via Wireless Sensor Networks." [Online]. Available: www.ntnu.edu/bru21
- [7] P. F. Suawa and C. Herglotz, "Optimizing Sensor Placement for Event Detection: A Case Study in Gaseous Chemical Detection," *Sensors*, vol. 25, no. 8, Apr. 2025, doi: 10.3390/s25082397.
- [8] H. Tian, Z. Lang, C. Cao, and B. Wang, "Optimizing Sensor Placement for Enhanced Source Term Estimation in Chemical Plants," *Processes*, vol. 13, no. 3, Mar. 2025, doi: 10.3390/pr13030825.
- [9] S. Luo, Q. Liu, X. Guo, M. Yin, Z. Li, and X. Lang, "Chemical Safety Inspection Path Optimization Problems Using Improved Multi-Objective Discrete Growth Optimization Algorithm," *Processes*, vol. 13, no. 5, May 2025, doi: 10.3390/pr13051445.
- [10] M. Civera, M. L. Pecorelli, R. Ceravolo, C. Surace, and L. Zanotti Fragonara, "A multi-objective genetic algorithm strategy for robust optimal sensor placement," *Computer-Aided Civil and Infrastructure Engineering*, vol. 36, no. 9, pp. 1185–1202, Sep. 2021, doi: 10.1111/mice.12646.
- [11] M. Murugan Jaya, R. Ceravolo, L. Zanotti Fragonara, and E. Matta, "An optimal sensor placement strategy for reliable expansion of mode shapes under measurement noise and modelling error," *J Sound Vib*, vol. 487, Nov. 2020, doi: 10.1016/j.jsv.2020.115511.
- [12] R. Costa and T. A. Wettergren, "A Sampling-Based Approach for Achieving Desired Patterns of Probabilistic Coverage with Distributed Sensor Networks," *Sensors*, vol. 23, no. 13, Jul. 2023, doi: 10.3390/s23135999.
- [13] M. Kim, H. Yetkin, D. J. Stilwell, J. Jimenez, S. Shrestha, and N. Stark, "Toward optimal placement of spatial sensors," Jul. 2023, [Online]. Available: <http://arxiv.org/abs/2307.04634>
- [14] M. Jia, T. Robert Sorensen, and D. Martina Hammerling, "Optimizing Point-in-Space Continuous Monitoring System Sensor Placement on Oil and Gas Sites," *ACS Sustainable Resource Management*, vol. 2, no. 1, pp. 72–81, Jan. 2025, doi: 10.1021/acssusresmg.4c00333.
- [15] I. Nur Darmawan, Kholistianingsih, A. Noor Fatah, P. Yulianto, and S. Adhi Pramono, "Analisis Methane Gas Detector dengan Sensor Catalytic dan Sensor Infrared di Maintenance Area II PT Kilang Pertamina Internasional RU IV Cilacap," *J-Proteksion: Jurnal Kajian Ilmiah dan Teknologi Teknik Mesin*, vol. 8, no. 1, pp. 53–63, Aug. 2023, doi: 10.32528/jp.v8i1.726.
- [16] A. Petrov, "Mathematical Method of Rational Placement of Gas Fire Sensors," *Sensors (Basel)*, vol. 23, no. 20, Oct. 2023, doi: 10.3390/s23208349.
- [17] J. A. Gustafson and C. E. Wilmer, "Intelligent Selection of Metal-Organic Framework Arrays for Methane Sensing via Genetic Algorithms," *ACS Sens*, vol. 4, no. 6, pp. 1586–1593, Jun. 2019, doi: 10.1021/acssensors.9b00268.