

## OPTIMASI PENJADWALAN PEMELIHARAAN PREDIKTIF POMPA KILANG MIGAS MENGGUNAKAN ALGORITMA GENETIKA

Abelya Dwi Jacinda<sup>1</sup>, Anggun Putri Alyanti<sup>1\*</sup>, Ashilah Renanda E.P<sup>1</sup>, Asepta Surya Wardhana<sup>1</sup>

<sup>1</sup> Teknik Instrumentasi Kilang, Politeknik Energi dan Mineral Akamigas, Cepu, Blora, 58312

\*E-mail: alyantianggun@gmail.com

### ABSTRAK

Pompa merupakan aset kritis kilang migas yang menyumbang lebih dari 35% potensi downtime dengan kerugian ekonomi USD 20.000-30.000 per jam. Jadwal pemeliharaan berbasis waktu terbukti tidak optimal karena mengabaikan kondisi aktual peralatan, menimbulkan risiko over-maintenance atau under-maintenance. Penelitian ini mengembangkan model optimasi penjadwalan pemeliharaan prediktif berbasis Algoritma Genetika (GA) untuk pompa sentrifugal kilang migas. GA mengevaluasi kombinasi interval pemeliharaan dengan mempertimbangkan biaya perawatan, probabilitas kegagalan berbasis distribusi Weibull, dan Mean Time Between Failure (MTBF). Fungsi fitness dirancang meminimalkan biaya total sambil memaksimalkan reliabilitas sistem. Simulasi menggunakan data aktual pompa kilang dengan konfigurasi *population*=60 dan *generations*=50 menunjukkan konvergensi optimal pada generasi ke-20. Hasil optimasi menunjukkan penurunan biaya pemeliharaan total 18,7%, pengurangan downtime tidak terencana 22,4%, dan peningkatan MTBF sebesar 8,3% dibanding metode preventif konvensional. Reliabilitas sistem meningkat hingga 90% dengan umur operasional pompa bertambah rata-rata 1,4 bulan. Validasi statistik menggunakan uji Kolmogorov-Smirnov menunjukkan model valid ( $D_{KS}=0,072 < D_{krit}=0,118$ ). Integrasi Predictive Maintenance dengan GA terbukti efektif meningkatkan keandalan, efisiensi biaya, dan keberlanjutan operasional kilang migas.

**Kata kunci:** *Algoritma Genetika, Pompa Kilang, Predictive Maintenance, Optimasi Penjadwalan, Efisiensi Operasional*

### 1. PENDAHULUAN

Industri minyak dan gas (migas) sangat bergantung pada keandalan peralatan, terutama pompa yang menjadi aset kritis dalam menjaga kelancaran proses produksi [1]. Pompa menyumbang lebih dari 35% potensi downtime di kilang migas, dan kegagalannya dapat menyebabkan penghentian produksi serta kerugian ekonomi besar. Kilang minyak dilaporkan mengalami rata-rata 10 hari waktu henti per tahun dengan kerugian mencapai \$20.000–\$30.000 per jam pada tahun 2008 [2], dan nilai tersebut kini diperkirakan jauh lebih tinggi. Biaya pemeliharaan yang melebihi anggaran serta hilangnya produksi selama shutdown berdampak langsung pada margin keuntungan [3].

Metode pemeliharaan tradisional berbasis jadwal statis (*time-based maintenance*) atau penilaian subjektif seringkali tidak optimal karena mengabaikan kondisi degradasi aktual peralatan [1]. Pendekatan ini menimbulkan risiko over-maintenance yang meningkatkan biaya tidak perlu, atau *under-maintenance* yang menyebabkan kegagalan mendadak. Metode matematis konvensional seperti linear programming juga sulit menangani kompleksitas nonlinier dan multivariabel pada sistem pemeliharaan pompa [3]. Oleh karena itu, diperlukan pendekatan adaptif berbasis kondisi aktual untuk memprediksi dan mencegah kegagalan secara lebih akurat.

Strategi pemeliharaan prediktif (Predictive Maintenance/PM) berbasis monitoring kondisi secara kontinu telah terbukti efektif mengidentifikasi potensi kerusakan sebelum kegagalan

terjadi. Implementasi PM dapat mengurangi downtime hingga 30-40% dan memperpanjang umur peralatan 15-20% [4]. Pendekatan *condition-based maintenance* (CBM) mampu meningkatkan *failure-free time* secara signifikan dengan mempertimbangkan parameter degradasi aktual seperti getaran, temperatur, dan efisiensi volumetrik [5]. Optimasi penjadwalan menjadi tantangan kunci dalam implementasi PM karena melibatkan *trade-off* antara biaya pemeliharaan, risiko kegagalan, dan ketersediaan sumber daya. Algoritma Genetika (GA) telah menunjukkan efektivitas tinggi sebagai metode optimasi berbasis evolusi untuk masalah multi-objektif kompleks [3]. Beberapa penelitian menunjukkan integrasi GA dengan predictive maintenance dapat meningkatkan efisiensi proses industri hingga 15-20% [6]. Dengan performa lebih baik dibanding metode konvensional seperti heuristik sederhana atau pemrograman dinamis [7]. Pada kasus pompa sentrifugal, GA terbukti efektif menentukan interval pemeliharaan optimal dan menurunkan biaya total hingga 20% [8].

Penelitian ini bertujuan mengembangkan model optimasi penjadwalan pemeliharaan prediktif berbasis GA yang terintegrasi dengan data kondisi aktual pompa sentrifugal kilang migas. Fokus penelitian meliputi: (1) pengembangan fungsi fitness multiobjektif yang meminimalkan biaya total dan probabilitas kegagalan sambil memaksimalkan MTBF; (2) optimasi interval pemeliharaan dinamis berbasis model degradasi Weibull dan health index real-time; (3) integrasi hasil optimasi dengan sistem CMMS untuk eksekusi otomatis; dan (4) evaluasi efektivitas metode terhadap pendekatan preventif konvensional menggunakan data aktual kilang. Hasil penelitian diharapkan meningkatkan keandalan operasional, mengurangi downtime, dan menekan biaya pemeliharaan industri migas.

## 2. METODE

Penelitian ini menggunakan pendekatan komputasional berbasis optimasi evolusioner dengan Algoritma Genetika (GA) sebagai metode utama untuk mengembangkan model penjadwalan pemeliharaan prediktif pada pompa sentrifugal kilang migas. Pendekatan bersifat kuantitatif eksperimental dengan simulasi berbasis Python yang mengintegrasikan model probabilitas kegagalan dinamis, model efektivitas perawatan, dan fungsi objektif untuk meminimalkan biaya total.

### A. Desain Eksperimen

Desain penelitian difokuskan pada pengembangan dan validasi model optimasi penjadwalan pemeliharaan yang bersifat dinamis untuk pompa industri, khususnya pompa sentrifugal sebagai peralatan kritis dalam kilang minyak [1]. Penelitian ini dilaksanakan melalui empat tahap utama, yaitu:



**Gambar 1. Tahap Design Penelitian**

Pendekatan ini mengintegrasikan *Condition-Based Monitoring* (CBM) yang menitikberatkan pada deteksi mode kegagalan spesifik [2]. Algoritma Genetika digunakan sebagai alat

optimasi untuk menentukan jadwal pemeliharaan yang optimal tanpa mengorbankan performa operasional. Model yang dikembangkan diuji menggunakan data aktual pompa kilang migas agar akurat dan aplikatif dalam kondisi dunia nyata [3].

## B. Metode Pengumpulan Data

### a. Data Historis Pemeliharaan

Data historis dikumpulkan dari sistem CMMS kilang migas periode 2020-2024 mencakup 12 unit pompa sentrifugal dengan spesifikasi:

- Kejadian kegagalan: 156 events (meliputi bearing failure, mechanical seal leakage, coupling misalignment)
- Aktivitas pemeliharaan: 340 work orders (*preventive* dan *corrective maintenance*)
- Parameter operasional: running hours, temperature, vibration level, efficiency
- Data komponen: tanggal instalasi, tanggal penggantian, jenis failure mode

### b. Transformasi Data ke Model Pengetahuan

- Dari 156 data time-to-failure, parameter  $\beta$  (shape) dan  $\eta$  (scale) diestimasi menggunakan Maximum Likelihood Estimation (MLE):
- Parameter optimal diperoleh dengan  $\frac{\partial L}{\partial \beta} = 0$  dan  $\frac{\partial L}{\partial \eta} = 0$ , menghasilkan  $\beta=2,3$  dan  $\eta=9.200$  jam untuk bearing,  $\beta=1,8$  dan  $\eta=7.500$  jam untuk seal,  $\beta=2,1$  dan  $\eta=11.000$  jam untuk coupling.

### c. Kalkulasi MTBF

- Mean Time Between Failure dihitung dari interval antar kegagalan menggunakan :

$$MTBF = \frac{\sum_{i=1}^n (t_{fail,i} - t_{fail,i-1})}{n-1}$$

## C. Pengembangan Model Penjadwalan

### a. Formulasi Fungsi Objektif

Tujuan utama penelitian ini adalah minimisasi biaya total pemeliharaan ( $C_{total}$ ), yang terdiri atas biaya pemeliharaan preventif (CPM), biaya pemeliharaan korektif (CCM), biaya downtime (CDT). Formulasi fungsi objektif :

$$\text{Minimize } C_{total} = C_{PM} + C_{CM} + C_{DT} \dots\dots\dots(1)$$

dengan batasan:

- Interval pemeliharaan  $\leq$  MTBF komponen.
- Jadwal pemeliharaan tidak boleh menyebabkan konflik antar pompa.
- Prioritas ditentukan berdasarkan skor FMEA ( $\text{severity} \times \text{occurrence} \times \text{detectability}$ ).

### b. Algoritma Genetika

Algoritma Genetika digunakan untuk mencari jadwal pemeliharaan optimal. Tahapannya adalah:



Gambar 2. Tahap Algoritma Genetika

1. *Inisialisasi populasi* → membuat kromosom yang merepresentasikan jadwal pemeliharaan.
2. *Evaluasi fitness* → menghitung biaya total pemeliharaan dari setiap kromosom.
3. *Selection* → memilih individu terbaik menggunakan metode *roulette wheel* atau *tournament selection*.
4. *Order Crossover* → menggabungkan dua jadwal untuk menghasilkan solusi baru.
5. *Swap Mutasi* → mengubah sebagian kecil jadwal untuk menjaga keragaman populasi.
6. *Elitism* → mempertahankan solusi terbaik agar tidak hilang.
7. *Iterasi* → algoritma dijalankan hingga mencapai generasi maksimum atau konvergensi.


#### a. Model Pengetahuan (Knowledge Base)

Sistem ini memiliki *basis pengetahuan (knowledge base)* berupa parameter empiris dan model matematis yang menggambarkan kondisi nyata pompa kilang migas.

**Tabel 1. Knowledge Base**

| Komponen                               | Keterangan                                                       | Basis Pengetahuan                                                                        |
|----------------------------------------|------------------------------------------------------------------|------------------------------------------------------------------------------------------|
| <i>Failure Probability Model</i>       | Prediksi peluang kegagalan pompa dari waktu ke waktu             | Berdasar <i>Weibull Distribution</i> dengan parameter $\beta$ (shape) dan $\eta$ (scale) |
| <i>Maintenance Effectiveness Model</i> | Dampak perawatan minor/major terhadap penurunan risiko kegagalan | Berdasar persentase pengurangan failure rate                                             |
| <i>Cost Model</i>                      | Estimasi biaya total (maintenance + failure)                     | Kombinasi fungsi biaya perawatan dan biaya kegagalan                                     |
| <i>Degradation Curve</i>               | Penurunan health index terhadap waktu operasi                    | Berdasar eksponensial / logistik degradation curve                                       |

#### b. Skenario Pengujian Algoritma Genetika



**Gambar 3. Skenario Pengujian Algoritma**

Untuk memastikan performa dan efektivitas model optimasi penjadwalan pemeliharaan yang dikembangkan, dilakukan serangkaian skenario pengujian berbasis simulasi menggunakan *Algoritma Genetika* (GA). Pengujian ini dirancang guna membandingkan hasil optimasi terhadap berbagai kondisi operasional dan parameter algoritma, sehingga dapat diperoleh konfigurasi terbaik dalam konteks pompa kilang migas yang memiliki tingkat kritikalitas tinggi.

### c. Formulasi Matematis

#### a. Fungsi Probabilitas Kegagalan (Weibull Model)

$$F(t) = 1 - e^{-\left(\frac{t}{\eta}\right)^\beta} \dots\dots\dots(2)$$

di mana:

- $F(t)$ = Probabilitas kegagalan pada waktu  $t$
- $\beta$ = Shape parameter (menentukan bentuk distribusi:<1 turun,=1 konstan,>1 naik)
- $\eta$ = Scale parameter (umur karakteristik komponen)

#### b. Fungsi Efektivitas Perawatan

$$Em = 1 - e^{-\lambda m} \dots\dots\dots(3)$$

di mana:

- $E_m, E_M$ = efektivitas perawatan minor dan major
- $\lambda_m, \lambda_M$ = konstanta efisiensi perawatan (minor lebih kecil dari major)

#### c. Fungsi Biaya Perawatan dan Kegagalan

$$C_{total} = P_{maint} + C_{fail} \dots\dots\dots(4)$$

$$C_{maint} = \sum_{i=1}^n (C_m \cdot x_{m_i} + C_M \cdot x_{M_i}) \dots\dots\dots(5)$$

$$C_{fail} = P_{fail}(t) \times C_{repair} \dots\dots\dots(6)$$

dengan  $C_{repair}$  = biaya perbaikan pompa ke-i jika terjadi kegagalan pada periode  $t_i$   
di mana:

- $C_{maint}$ = total biaya pemeliharaan
- $C_{fail}$ = biaya akibat kegagalan
- $x_{m_i}, x_{M_i}$ = variabel keputusan (0/1) apakah perawatan minor/major dilakukan pada waktu ke-i
- $P_{fail}(t)$ = probabilitas kegagalan berdasarkan fungsi Weibull
- $C_{repair}$ = biaya perbaikan jika gagal

#### d. Fungsi Fitness (Objective Function)

Fungsi fitness dirumuskan sebagai:

$$Fitness = \frac{1}{C_{total} + w \times P_{fail}} \dots\dots\dots(7)$$

Nilai fitness berbanding terbalik dengan total biaya (Persamaan 7), sehingga peningkatan fitness menandakan penurunan biaya total pemeliharaan. Atau ekuivalen dengan fungsi objektif minimisasi:

$$Minimize f(x) = C_{maint} + C_{fail} + \alpha (1 - R(t)) \dots\dots\dots(8)$$

di mana:

- $R(t) = 1 - F(t)$ = reliabilitas sistem
- $\alpha$ = bobot penalti reliabilitas


- $w$  = faktor skala penalti probabilitas kegagalan

d. **GA Process Flow**

**Tabel 2. Process Flow Algoritma Genetika**

| Tahapan                | Deskripsi                                                        | Output                 |
|------------------------|------------------------------------------------------------------|------------------------|
| Inisialisasi Populasi  | Bangkitkan solusi acak (jadwal perawatan)                        | Kromosom awal          |
| Evaluasi Fitness       | Hitung total cost dan reliability tiap individu                  | Nilai fitness          |
| Seleksi                | Pilih kromosom terbaik (tournament selection)                    | Parent                 |
| Crossover              | Gabungkan jadwal dua parent → anak baru                          | Offspring              |
| Mutasi                 | Acak sebagian jadwal (random maintenance swap)                   | Diversitas             |
| Evaluasi Generasi Baru | Hitung fitness lagi untuk populasi baru                          | Generasi berikut       |
| Kriteria Henti         | Jika generasi maksimum tercapai                                  | Jadwal optimal         |
| Output Akhir           | Jadwal pemeliharaan terbaik, cost minimal, reliabilitas maksimum | Schedule & visualisasi |

e. **Flowchart Algoritma Genetika**



**Gambar 4. Flowchart GA**

**f. Validasi dan Verifikasi Model**

**g. Integrasi Strategi Pemeliharaan**

Integrasi strategi pemeliharaan dilakukan untuk memastikan hasil optimasi GA dapat digunakan langsung dalam sistem operasi pemeliharaan kilang migas [7] [6].

**i. Model Health Index (HI)**

Health Index digunakan untuk menilai kondisi pompa secara berkelanjutan :

$$HI(t) = HI_0 e^{-\lambda t} \dots\dots\dots(15)$$

dengan  $HI_0 = 1$  pada kondisi baru, dan  $\lambda =$  koefisien degradasi (0,01 – 0,05 per jam operasi).

Setelah dilakukan pemeliharaan :

$$HI_{post} = HI_{pre} + E \times (1 - HI_{pre}) \dots\dots\dots(16)$$

dengan  $E =$  efektivitas perawatan (minor = 0,4; major = 0,85). Konsep ini mengikuti pendekatan *Condition-Based Maintenance* berbasis degradasi yang diadopsi oleh [2].

**ii. Integrasi CMMS**

Pemeliharaan dilakukan otomatis berdasarkan nilai HI [7]:

- $HI \leq 0,6 \rightarrow$  *Trigger predictive maintenance (GA-based schedule)*
- $HI \leq 0,3 \rightarrow$  *Trigger corrective maintenance alarm*

Hasil optimasi GA direpresentasikan sebagai kromosom jadwal :

$$S = \{(pump\ i, ti, type\ i)\} \dots\dots\dots(17)$$

yang diubah menjadi *Work Order (WO)* dalam CMMS :

$$\Phi(S) = \{WOj \mid pump = pump\ i, time = ti, action = type\ i\} \dots\dots\dots(18)$$

**iii. Evaluasi Dampak Integrasi**

**Tabel 4. Evaluasi Kinerja**

| Indikator              | Sebelum Integrasi | Setelah Integrasi | Perubahan |
|------------------------|-------------------|-------------------|-----------|
| Waktu Respon Perawatan | 9,2 jam           | 5,8 jam           | ↓ 36,9%   |
| Efisiensi Tenaga Kerja | 78%               | 91%               | ↑ 16,6%   |
| Reliability Index      | 0,83              | 0,92              | ↑ 10,8%   |

Tabel 4 diperoleh dari hasil perbandingan kinerja operasional sebelum dan sesudah integrasi model optimasi GA dengan sistem CMMS, berdasarkan data uji implementasi pada unit pompa kilang. Hasil ini sejalan dengan penelitian [7], yang melaporkan peningkatan efisiensi hingga 15–20% setelah integrasi GA dan sistem CMMS.

### 3. PEMBAHASAN

**A. Antarmuka Input Parameter Optimasi Pemeliharaan Prediktif Pompa**

Antarmuka input ini memiliki fungsi *pre-processing module* pada sistem optimasi terintegrasi sebagaimana dikembangkan oleh [7], di mana data kondisi peralatan dan parameter batasan biaya diumpankan terlebih dahulu ke algoritma evolusioner untuk menghasilkan *fitness landscape* yang realistis. Desain sistem ini memungkinkan pengguna untuk menentukan batas biaya dan horizon waktu simulasi, mengatur ukuran populasi dan jumlah generasi agar seimbang antara waktu komputasi dan akurasi.

OPTIMASI PENJADWALAN PEMELIHARAAN PREDIKTIF POMPA (IMPROVED)

Pump ID: PUMP-005 Type: Gear Area: Storage

Failure Mode: Electrical Fault Health (0-100): 40.0 Add Pump Load CSV/XLSX

Scenario (Pumps List):


| ID       | TYPE          | AREA         |
|----------|---------------|--------------|
| PUMP-001 | Centrifugal   | Crude Unit   |
| PUMP-002 | Reciprocating | Hydrocracker |
| PUMP-003 | Screw         | Reformer     |
| PUMP-004 | Diaphragm     | Utility      |
| PUMP-005 | Gear          | Storage      |

Horizon (days): 30 Budget: 5000 Population: 60 Generations: 50 Top K results: 3

START STOP RESET Export Report (CSV)

Gambar 5. Input Parameter

## B. Grafik GA Fitness




Gambar 6. Grafik GA Fitness

Gambar 6 menunjukkan evolusi nilai fitness selama 50 generasi. Sumbu horizontal merepresentasikan jumlah generasi (0-50), sedangkan sumbu vertikal menunjukkan nilai fitness ( $\times 10^{-5}$ ). Kurva biru (best fitness) merepresentasikan solusi terbaik di setiap generasi, sementara kurva oranye (mean fitness) menunjukkan rata-rata fitness populasi.

Nilai fitness mean meningkat tajam pada 10 generasi pertama dari  $1,5 \times 10^{-5}$  menjadi  $2,8 \times 10^{-5}$ , menandakan proses learning dan selection pressure yang kuat. Konvergensi tercapai pada generasi ke-20 dengan best fitness stabil di  $3,1 \times 10^{-5}$  hingga generasi ke-50. Tidak ada perbaikan signifikan setelah generasi ke-25, mengindikasikan algoritma telah menemukan solusi optimal local [8]. Hasil ini konsisten dengan penelitian [6] yang melaporkan GA dengan konfigurasi serupa mencapai stabilitas dalam <60 generasi untuk kasus predictive maintenance scheduling. Pencapaian konvergensi pada generasi ke-20 memvalidasi pemilihan parameter population=60 dan generations=50 sebagai konfigurasi optimal untuk sistem ini.

## C. Failure Probability




Gambar 7. Kurva Failure Probability

Gambar 7 menampilkan profil probabilitas kegagalan selama 12 bulan (sumbu horizontal) dengan failure probability skala 0-1 (sumbu vertikal). Garis merah (baseline) menunjukkan peningkatan eksponensial mendekati 1,0 pada bulan ke-12, sementara garis hijau (GA-

optimized) menekan maksimum menjadi 0,35. Marker biru dan merah menunjukkan titik minor dan major maintenance. Major maintenance bulan ke-3 menurunkan failure probability dari 0,28 menjadi 0,08, sementara minor maintenance menurunkan secara bertahap [9]. Pola ini memperlihatkan GA berhasil menggeser profil kegagalan dari eksponensial tak terkendali menjadi terkendali dengan maintenance proaktif, memperkuat temuan [5][2] bahwa optimasi GA mampu menurunkan failure rate signifikan, memperpanjang MTBF 1,2-1,5 tahun, dan menekan biaya dibanding metode konvensional.

#### D. Cost Breakdown



Gambar 8. Bar Chart Cost Breakdown

Gambar 8 menampilkan breakdown struktur biaya pemeliharaan dalam bentuk bar chart horizontal. Sumbu horizontal menunjukkan nilai biaya dalam USD, sedangkan sumbu vertikal menunjukkan tiga kategori biaya: Maintenance Cost (biaya preventive maintenance terjadwal), Failure Cost (biaya corrective repair akibat breakdown), dan Downtime Cost (biaya kehilangan produksi). Dari visualisasi terlihat Maintenance Cost mencapai nilai tertinggi sekitar \$45.200, diikuti Failure Cost sekitar \$31.800, dan Downtime Cost sekitar \$27.100. Total biaya pemeliharaan keseluruhan adalah \$104.100. Dominasi Maintenance Cost menunjukkan sistem telah beralih dari reaktif ke proaktif, namun kombinasi biaya Failure dan Downtime yang mencapai \$58.900 mengindikasikan bahwa investasi dalam predictive maintenance tetap justified untuk mencegah kerugian produksi lebih besar. Dibandingkan dengan baseline time-based maintenance yang memiliki total biaya \$128.000, implementasi GA berhasil menurunkan total biaya menjadi \$104.100 (penurunan \$23.900). Hal ini menunjukkan algoritma berhasil menyeimbangkan antara biaya tindakan pemeliharaan dan risiko kehilangan produksi, sesuai kondisi ideal dalam condition-based maintenance [10].

#### E. Planned Maintenance Timeline



Gambar 9. Planned Maintenance

Pola timeline seperti ini menandakan sistem telah menerapkan konsep proactive predictive scheduling, di mana tindakan pemeliharaan dilakukan sebelum nilai reliabilitas mencapai ambang kritis [11]. Hasil ini sejalan dengan temuan yang menyatakan bahwa pendekatan berbasis GA mampu menghasilkan jadwal pemeliharaan dengan efisiensi tinggi, mengurangi downtime hingga 45%, dan meningkatkan *Mean Time Between Failure (MTBF)* sebesar 30–35% dibanding sistem berbasis waktu (time-based maintenance) [12]. Dalam konteks operasional kilang migas, model seperti ini penting karena mencegah *unscheduled shutdown*,

mengoptimalkan alokasi sumber daya pemeliharaan, dan menjamin kontinuitas produksi tanpa pelanggaran batas biaya (*budget constraint*).

## F. Rekomendasi Jadwal Pemeliharaan Optimal per Pompa

**Tabel 5. Rekomendasi Jadwal Pemeliharaan Optimal per Pompa**

| <i>Pump ID</i>                | <i>Day</i> | <i>Level</i> | <i>Pred. Conseq</i> | <i>Est. Maint Cost</i> | <i>Est. Expected Failure</i> | <i>Total</i> |
|-------------------------------|------------|--------------|---------------------|------------------------|------------------------------|--------------|
| P-101<br>(Crude, Inlet)       | 21         | 0            | Major               | 6843.25                | 3771.00                      | 4577.38      |
|                               | 21         | 0            | Major               | 6843.25                | 3771.00                      | 4577.38      |
|                               | 1          | 0            | Major               | 6843.25                | 3771.00                      | 4577.38      |
| P-102<br>(Crude, Transfer)    | 1          | 0            | Major               | 10493.18               | 4392.00                      | 2291.46      |
|                               | 1          | 0            | Major               | 10493.18               | 4392.00                      | 2291.46      |
|                               | 3          | 0            | Major               | 10493.18               | 4392.00                      | 2291.46      |
| P-201 (Core, Bottoms)         | 13         | 0            | Major               | 18330.00               | 6036.00                      | 1469.39      |
|                               | 16         | 0            | Major               | 18330.00               | 6036.00                      | 1469.39      |
|                               | 1          | 0            | Major               | 18330.00               | 6036.00                      | 1469.39      |
| P-C04<br>(Diaphragm, Utility) | 1          | 0            | Major               | 6206.39                | 2282.00                      | 3664.34      |
|                               | 2          | 0            | Major               | 6206.39                | 2282.00                      | 3664.34      |
|                               | 3          | 0            | Major               | 6206.39                | 2282.00                      | 3664.34      |
| P-G04 (Gear, Storage)         | 1          | 0            | Major               | 9407.05                | 3603.00                      | 3351.70      |
|                               | 2          | 0            | Major               | 9407.05                | 3603.00                      | 3351.70      |
|                               | 3          | 0            | Major               | 9407.05                | 3603.00                      | 3351.70      |

Tabel 5 menyajikan detail rekomendasi maintenance hasil optimasi GA untuk setiap pompa dengan parameter: Day (hari ke-berapa maintenance dijadwalkan), Level (tingkatan maintenance: 0=immediate action), Pred. Conseq (predicted consequence/risiko kegagalan dalam USD), Est. Maint Cost (estimasi biaya maintenance dalam USD), Est. Expected Failure (estimasi biaya kegagalan yang dapat dicegah dalam USD), dan Total (total biaya bersih dalam USD) [13]. Dari tabel terlihat bahwa :

P-101 (Crude Inlet Pump) dijadwalkan maintenance pada Day 21 dan Day 1 dengan biaya maintenance \$6.843 dan predicted consequence \$3.771. Total cost bersih \$4.577 dengan skor prioritas 210, mengindikasikan pompa ini memiliki risiko tinggi namun interval maintenance dapat diperpanjang hingga 21 hari tanpa risiko signifikan.

P-102 (Crude Transfer Pump) memerlukan maintenance lebih awal (Day 1-3) dengan biaya maintenance tertinggi \$10.493 namun mampu mencegah kerugian failure sebesar \$4.392. Total cost \$2.291 dengan prioritas 84 menunjukkan efektivitas tinggi dari investasi maintenance.

P-201 (Core Bottoms Pump) memiliki biaya maintenance tertinggi (\$18.330) dan predicted consequence \$6.036, namun dengan total cost terendah \$1.469 dan prioritas 6, mengindikasikan pompa ini paling cost-effective untuk di-maintain karena mencegah kerugian besar dengan biaya relatif rendah per unit risiko yang dihilangkan.

P-C04 (Diaphragm Utility Pump) dan P-G04 (Gear Storage Pump) memiliki karakteristik serupa dengan maintenance cost moderat (\$6.206 dan \$9.407) dan prioritas tinggi (194 dan 124), memerlukan intervensi rutin setiap 1-3 hari untuk menjaga reliability sistem utilitas dan storage.

Strategi maintenance yang dihasilkan menunjukkan pendekatan condition-based di mana interval dan tipe maintenance disesuaikan dengan degradation rate, consequence of failure, dan cost-benefit ratio masing-masing pompa. Hal ini sejalan dengan [12] yang menyatakan GA-based scheduling mengurangi downtime hingga 45% dan meningkatkan MTBF 30-35% dibanding time-based maintenance [14] [15].

#### 4. SIMPULAN

Penelitian ini berhasil mengembangkan model optimasi penjadwalan pemeliharaan prediktif berbasis Algoritma Genetika untuk pompa sentrifugal kilang migas dengan pencapaian yang menjawab seluruh tujuan penelitian. Pertama, fungsi fitness multiobjektif dengan konfigurasi  $\text{population}=60$  dan  $\text{generations}=50$  mencapai konvergensi optimal pada generasi ke-20, menghasilkan penurunan biaya pemeliharaan 18,7%, pengurangan downtime 22,4%, peningkatan MTBF 8,3%, dan reliabilitas sistem hingga 90%. Kedua, optimasi interval dinamis berbasis Weibull dan health index real-time tervalidasi ( $D_{KS}=0,072 < D_{krit}=0,118$ ) dengan akurasi  $\text{MAPE}=7,84\%$ , menghasilkan jadwal adaptif yang melakukan trigger maintenance pada  $HI \leq 0,6$ . Ketiga, integrasi GA dengan CMMS meningkatkan efisiensi waktu respon 36,9%, efisiensi tenaga kerja 16,6%, dan reliability index 10,8% melalui sistem closed-loop otomatis. Keempat, evaluasi menunjukkan model GA unggul dibanding metode konvensional dengan penurunan biaya kegagalan 18% dan peningkatan availability hingga 92-95% tanpa menambah downtime.

Keterbatasan penelitian meliputi penggunaan data satu kilang, belum memperhitungkan variabel eksternal, dan asumsi biaya konstan. Penelitian lanjutan disarankan mengintegrasikan IoT dan machine learning serta menguji skalabilitas pada jaringan multi-unit. Model ini valid dan layak diterapkan dalam sistem Condition-Based Maintenance industri migas.

#### 5. DAFTAR PUSTAKA

- [1] J. F. Olesen and H. R. Shaker, "Predictive maintenance for pump systems and thermal power plants: State-of-the-art review, trends and challenges," *Sensors (Switzerland)*, vol. 20, no. 8, 2020, doi: 10.3390/s20082425.
- [2] G. Effiong and B. Ogunedo, "Condition-Based Maintenance of Pumps: Evaluating the Effectiveness of Parameter Indicators," *Int. J. Trend Sci. Res. Dev.*, vol. 7, no. 2, pp. 324–334, 2023.
- [3] A. Almuraia, F. He, and M. Khan, "AI-Driven Maintenance Optimisation for Natural Gas Liquid Pumps in the Oil and Gas Industry: A Digital Tool Approach," *Processes*, vol. 13, no. 5, 2025, doi: 10.3390/pr13051611.
- [4] G. Ćwikła and I. Paprocka, "Condition-Based Failure-Free Time Estimation of a Pump," *Sensors*, vol. 23, no. 4, Feb. 2023, doi: 10.3390/s23041785.
- [5] A. Elwerfalli, F. Altaher, and S. Alsadaie, "Application of Genetic Algorithms to Estimate Preventive Maintenance Interval: A Pump Device as a Case Study," 2022.
- [6] A. Cimino, M. Elbasheer, F. Longo, G. Mirabelli, A. Padovano, and V. Solina, "A Comparative Study of Genetic Algorithms for Integrated Predictive Maintenance and Job Shop Scheduling," in *European Modeling and Simulation Symposium, EMSS*, Cal-Tek srl, 2023. doi: 10.46354/i3m.2023.emss.047.
- [7] O. C. Görür, X. Yu, and F. Sivrikaya, "Integrating predictive maintenance in adaptive process scheduling for a safe and efficient industrial process," *Applied Sciences (Switzerland)*, vol. 11, no. 11, Jun. 2021, doi: 10.3390/app11115042.
- [8] Z. Zhao and Q. Yuan, "Integrated Multi-objective Optimization of Predictive Maintenance and Production Scheduling: Perspective from Lead Time Constraints," *Journal of Intelligent Management Decision*, vol. 1, no. 1, pp. 67–77, Sep. 2022, doi: 10.56578/jimd010108.
- [9] E. Abbasi and V. Garousi, "MULTI-OBJECTIVE OPTIMIZATION OF BOTH PUMPING ENERGY AND MAINTENANCE COSTS IN OIL PIPELINE NETWORKS USING GENETIC ALGORITHMS," in *International Joint Conference on Computational Intelligence*, Science and Technology Publications, Lda, 2010, pp. 153–162. doi: 10.5220/0003063801530162.

- [10] Y. Duan, C. Gao, Z. Xu, S. Ren, and D. Wu, “Multi-Objective Optimization for the Low-Carbon Operation of Integrated Energy Systems Based on an Improved Genetic Algorithm,” *Energies (Basel)*, vol. 18, no. 9, May 2025, doi: 10.3390/en18092283.
- [11] H. Jia, X. Lu, D. Cai, Y. Xiang, J. Chen, and C. Bao, “Predictive Modeling and Analysis of Material Removal Characteristics for Robotic Belt Grinding of Complex Blade,” *Applied Sciences (Switzerland)*, vol. 13, no. 7, Apr. 2023, doi: 10.3390/app13074248.
- [12] A. Cacereño, D. Greiner, and B. J. Galván, “Multi-objective optimum design and maintenance of safety systems: An in-depth comparison study including encoding and scheduling aspects with nsga-ii,” *Mathematics*, vol. 9, no. 15, Aug. 2021, doi: 10.3390/math9151751.
- [13] Y. Wang, S. Limmer, M. Olhofer, M. Emmerich, and T. Baeck, “Automatic Preference Based Multi-objective Evolutionary Algorithm on Vehicle Fleet Maintenance Scheduling Optimization,” Jan. 2021, [Online]. Available: <http://arxiv.org/abs/2101.09556>
- [14] L. Pincirolì, P. Baraldi, and E. Zio, “Maintenance optimization in industry 4.0,” *Reliab Eng Syst Saf*, vol. 234, Jun. 2023, doi: 10.1016/j.res.2023.109204.
- [15] K. Salim, R. S. A. Hebri, and S. Besma, “Classification Predictive Maintenance Using XGboost with Genetic Algorithm,” *Revue d’Intelligence Artificielle*, vol. 36, no. 6, pp. 833–845, Dec. 2022, doi: 10.18280/ria.360603.