

OPTIMASI PREDIKSI LAJU ALIRAN PIPA KILANG MENGUNAKAN KECERDASAN BUATAN BERBASIS ALGORITMA GENETIKA

Alfredo Devandanda Fathurahman¹, Nayla Choirinnesa¹, Aulya Pradevi^{1*}, Alung Dimar¹, Muhammad Reyvanza¹, Asep Sury Wardhana¹

¹Teknik Instrumentasi Kilang, Politeknik Energi dan Mineral Akamigas, Jl. Gajah Mada No.38, Jawa Tengah 58315

*E-mail: naylachoirinnesaap@gmail.com

ABSTRAK

Prediksi laju aliran fluida yang akurat sangat penting dalam operasi pipa kilang untuk meningkatkan efisiensi dan mencegah risiko operasional. Penelitian ini bertujuan mengembangkan model prediksi laju aliran menggunakan Algoritma Genetika (GA) berbasis pendekatan hybrid data-fisika dengan persamaan Darcy-Weisbach. Metode GA digunakan untuk mengoptimasi parameter model dengan meminimalkan fungsi objektif hybrid yang menggabungkan mean squared error data (MSE_data) dan error fisika (MSE_fisika). Tiga skenario percobaan dilakukan dengan variasi ukuran populasi (40–120), jumlah generasi (80–300), tingkat crossover (0,70–0,85), tingkat mutasi (0,02–0,12), dan bobot data ($\lambda = 0,5–0,9$). Dataset sintetis sebanyak 500 data poin dibangkitkan berdasarkan persamaan Darcy-Weisbach dengan parameter tekanan (100–500 kPa), diameter pipa (0,1–0,5 m), viskositas (0,001–0,01 Pa·s), dan kekasaran relatif (0,00001–0,001). Hasil menunjukkan bahwa konfigurasi optimal dicapai pada percobaan ketiga dengan populasi 120, generasi 300, crossover 0,85, mutasi 0,02, dan $\lambda = 0,9$, menghasilkan MSE (data) = 2,324, MSE (fisika) = $9,08 \times 10^8$, dan $R^2 = 0,8624$. Peningkatan R^2 dari 0,087 (percobaan 1) menjadi 0,8624 (percobaan 3) menunjukkan efektivitas pendekatan hybrid dalam menyeimbangkan pembelajaran empiris dengan constraint fisika.

Kata kunci : Algoritma Genetika, Prediksi Laju Aliran, Darcy-Weisbach, Hybrid Data-Fisika, Optimasi Pipa Kilang

1. PENDAHULUAN

Optimasi laju aliran fluida dalam pipa merupakan tantangan yang dihadapi oleh banyak industri, terutama dalam sektor minyak dan gas [1], [2]. Laju aliran yang akurat sangat penting untuk meningkatkan efisiensi operasional [3], mencegah kerusakan sistem, dan mengurangi risiko kebocoran yang dapat merugikan perusahaan [4]. Dalam perhitungan laju aliran, metode konvensional seperti persamaan Darcy-Weisbach sering digunakan untuk menghitung tekanan dan laju aliran berdasarkan parameter-parameter fisika seperti tekanan, diameter pipa, dan kekasaran pipa [5]. Namun, metode ini sering mengalami keterbatasan ketika diterapkan pada aliran multifase atau kondisi non-linier [6].

Dalam konteks operasi kilang minyak, prediksi laju aliran yang akurat menjadi semakin krusial mengingat kompleksitas sistem perpipaan yang melibatkan berbagai jenis fluida, kondisi operasi yang bervariasi, dan kebutuhan untuk menjaga stabilitas proses secara real-time. Ketidakakuratan dalam prediksi dapat mengakibatkan inefisiensi energi, peningkatan biaya operasional, bahkan potensi kegagalan sistem yang membahayakan keselamatan. Persamaan Darcy-Weisbach mengasumsikan bahwa aliran bersifat laminar atau turbulen dalam kondisi ideal. Dalam sistem pipa yang kompleks, terutama pada kondisi ladang minyak dengan aliran minyak-air, persamaan ini sering kali gagal menggambarkan perilaku aliran yang sesungguhnya.

Oleh karena itu, diperlukan metode yang lebih fleksibel dan mampu menangani ketidakpastian dalam data operasional, terutama dalam kondisi aliran yang kompleks [7]. Seiring dengan perkembangan teknologi, algoritma genetika telah muncul sebagai alternatif yang menjanjikan untuk mengatasi masalah ini [8], [9]. Algoritma genetika mampu mengeksplorasi ruang solusi lebih luas daripada metode konvensional dengan mengoptimalkan parameter-parameter fisik dalam model prediksi laju aliran [10]. Beberapa penelitian menunjukkan bahwa penerapan algoritma genetika dalam optimasi sistem perpipaan menghasilkan model yang lebih akurat karena mampu menemukan solusi optimal tanpa terjebak dalam solusi lokal [11], [12]. Selain itu, algoritma genetika dapat menangani ketidakpastian dan non-linearitas data dengan lebih baik dibandingkan dengan model berbasis regresi konvensional. Kombinasi antara algoritma genetika dan metode berbasis data seperti Jaringan Saraf Tiruan (Artificial Neural Networks/ANN) atau pendekatan Physics-Informed Machine Learning (PIML) semakin populer untuk meningkatkan akurasi prediksi dengan memanfaatkan kelebihan masing-masing teknik [13].

Pendekatan hybrid yang menggabungkan data-driven method dengan physics-based constraint telah menunjukkan keunggulan signifikan dalam berbagai aplikasi rekayasa fluida dan sistem perpipaan. Integrasi persamaan Darcy-Weisbach sebagai constraint fisika membantu model machine learning menghindari solusi yang tidak realistis secara fisika, sekaligus memanfaatkan kemampuan algoritma genetika dalam mengeksplorasi ruang solusi kompleks untuk menemukan konfigurasi optimal [15]. Keseimbangan antara pembelajaran empiris dari data operasional dan pemenuhan hukum fisika dasar menjadi kunci keberhasilan model prediksi yang robust dan dapat diandalkan pada berbagai kondisi operasional. Meskipun berbagai metode konvensional seperti persamaan Darcy-Weisbach telah digunakan, pendekatan ini masih terbatas dalam menangani ketidaklinieran, ketidakpastian, dan variabilitas data [14]. Oleh karena itu, penelitian ini bertujuan untuk mengisi gap dengan mengintegrasikan pendekatan berbasis data dan fisika melalui penerapan algoritma genetika dalam prediksi laju aliran fluida pada pipa kilang minyak dan gas.

Penelitian ini berkontribusi dalam pengembangan model GA-Hybrid yang mampu menyeimbangkan pembelajaran empiris dari data operasional dengan constraint fisika persamaan Darcy-Weisbach. Fokus penelitian diarahkan pada optimasi parameter algoritma genetika—meliputi ukuran populasi, tingkat crossover dan mutasi, serta bobot keseimbangan data-fisika (λ)—untuk menghasilkan prediksi yang akurat dan stabil pada berbagai kondisi operasional sistem perpipaan industri minyak dan gas.

2. METODE

Penelitian ini menggunakan pendekatan kuantitatif eksperimental melalui penerapan algoritma genetika untuk optimasi model prediksi laju aliran pada pipa menggunakan persamaan Darcy-Weisbach. Metode ini disusun secara rasional, empiris dan sistematis. Pendekatan rasional dilakukan melalui perumusan teori dasar aliran fluida, empiris dilakukan dengan eksperimen dan pengumpulan data aktual dan sistematis akan diterapkan dalam tahapan komputasi serta evaluasi model yang digunakan.

A. Desain Eksperimen

Eksperimen dilakukan menggunakan data sintetis yang dibangkitkan berdasarkan persamaan Darcy-Weisbach untuk merepresentasikan karakteristik aliran fluida dalam pipa kilang minyak dan gas. Dataset terdiri dari 500 data poin dengan parameter: tekanan diferensial (ΔP : 100-500 kPa), panjang pipa (L : 100-1000 m), diameter pipa (D : 0,1-0,5 m), kekasaran relatif (ϵ : 0,00001-0,001), viskositas (μ : 0,001-0,01 Pa·s), dan densitas (ρ : 700-900 kg/m³). Dataset dibagi menjadi 80% data training (400 data) dan 20% data testing (100 data) untuk

validasi model.

B. Model Matematis

Model dasar yang digunakan berdasarkan dengan persamaan Darcy-Weisbach pada Pers. (1):

$$\Delta P = f \cdot \frac{L}{D} \cdot \frac{\rho V^2}{2} \dots\dots\dots (1)$$

Laju aliran volumetrik (Q) dihitung dari kecepatan aliran:

$$Q = V \cdot A = V \cdot \pi \cdot (D^2/4) \dots\dots\dots(2)$$

Faktor gesekan (f) dihitung menggunakan persamaan Colebrook-White:

$$1/\sqrt{f} = -2 \log_{10}(\epsilon/(3,7D) + 2,51/(Re \cdot \sqrt{f})) \dots\dots\dots(3)$$

dengan bilangan Reynolds (Re) = $\rho VD/\mu$.

Model prediksi berbasis data dibangun dengan menggunakan Algoritma Genetika untuk mengoptimasi parameter-parameter dalam fungsi aproksimasi non-linear yang memetakan input (ΔP , L, D, ϵ , μ , ρ) ke output (Q), dengan constraint fisika dari persamaan Darcy-Weisbach.

C. Penerapan Algoritma Genetika

Algoritma Genetika digunakan untuk mengoptimasi parameter model prediksi hybrid data-fisika. Tiga skenario percobaan dilakukan dengan variasi parameter GA sebagai berikut.

Tabel 1 Konfigurasi Parameter Algoritma Genetika

Parameter	Skenario 1	Skenario 2	Skenario 3
Populasi	40	80	120
Generasi	80	120	300
Crossover	0,70	0,75	0,85
Mutasi	0,08	0,10	0,02
Lambda (λ)	0,50	0,7	0,9

Tahap-tahap proses GA:

1. Inisialisasi Populasi

Membangkitkan populasi awal sebanyak N individu (kromosom) secara random, dimana setiap kromosom merepresentasikan sekumpulan parameter model prediksi. Setiap kromosom dikodekan sebagai vektor real-valued :

$$\text{Kromosom} = [w_1, w_2, w_3, w_4, w_5, w_6, b] \dots\dots\dots(4)$$

Dimana:

- $w_1, w_2, w_3, w_4, w_5, w_6$ = bobot untuk fitur transformasi input (ΔP , L, D, ϵ , μ , ρ)
- b = bias term

Model prediksi laju aliran didefinisikan sebagai fungsi aproksimasi non-linear :

$$Q_{\text{pred}} = w_1 \cdot \sqrt{\Delta P} + w_2 \cdot \log(L) + w_3 \cdot D^2 + w_4 \cdot \exp(-\epsilon) + w_5 \cdot (1/\mu) + w_6 \cdot \rho + b \dots\dots\dots(5)$$

dengan fungsi transformasi dipilih berdasarkan karakteristik fisika hubungan parameter terhadap laju aliran.

2. Evaluasi Fitness

Menghitung nilai fitness setiap individu menggunakan fungsi objektif hybrid :

$$J = \lambda \cdot \text{MSE}_{\text{data}} + (1 - \lambda) \cdot \text{MSE}_{\text{fisika}} \dots\dots\dots(6)$$

Dimana:

$$\text{MSE}_{\text{data}} = (1/n) \sum_{i=1}^n (Q_{\text{pred},i} - Q_{\text{actual},i})^2 \dots\dots\dots(7)$$

MSE_{data} mengukur error antara prediksi model (Q_{pred}) dengan data aktual (Q_{actual}).

$\text{MSE}_{\text{fisika}}$ dihitung dengan mengevaluasi konsistensi terhadap persamaan Darcy-Weisbach. Dari Q_{pred} , kecepatan aliran dihitung sebagai :

$$V = Q_{\text{pred}} / (\pi \cdot D^2/4) \dots\dots\dots(8)$$

Kemudian tekanan diferensial diprediksi menggunakan

Pers. (1): $\Delta P_{\text{calc}} = f \cdot (L/D) \cdot (\rho \cdot V^2/2)$ (9)

dengan faktor gesekan (f) dihitung dari persamaan Colebrook-White (Pers. 3).

$MSE_{\text{fisika}} = (1/n) \sum_{i=1}^n (\Delta P_{\text{calc},i} - \Delta P_{\text{actual},i})^2$ (10)

Parameter λ ($0 \leq \lambda \leq 1$) mengontrol trade-off antara fitting data ($\lambda \rightarrow 1$) dan pemenuhan constraint fisika ($\lambda \rightarrow 0$). Model dengan nilai J terkecil dipilih sebagai solusi terbaik.

3. Crossover

Menghasilkan offspring melalui single-point crossover dengan probabilitas p_c sesuai tabel.

4. Mutasi

Melakukan mutasi Gaussian pada offspring dengan probabilitas p_m sesuai tabel.


5. Iterasi

Mengulangi langkah 2-5 hingga mencapai jumlah generasi maksimum atau kriteria konvergensi (perubahan fitness $< 10^{-6}$ selama 20 generasi).

D. Skematik Sistem

Diagram alir sistem prediksi laju aliran ditunjukkan pada Gambar 1. Proses dimulai dengan:

1. Pengambilan parameter input (ΔP , L, D, ϵ , μ , ρ) dari data training
2. Perhitungan nilai Q teoritis menggunakan persamaan Darcy-Weisbach (Pers. 1-3)
3. Inisialisasi populasi GA dengan parameter random
4. Optimasi model prediksi menggunakan GA dengan fungsi objektif hybrid (Pers. 4)
5. Evaluasi model pada data testing menggunakan MSE dan R^2
6. Iterasi dengan skenario parameter GA yang berbeda (Tabel 1)
7. Pemilihan model terbaik berdasarkan nilai R^2 tertinggi



Gambar 1. Flowchart Skematik Sistem


E. Validasi Model

Evaluasi performa model dilakukan dengan perhitungan Mean Squared Error (MSE) dan koefisien determinasi (R^2) antara hasil prediksi dan hasil perhitungan fisika. Evaluasi performa model dilakukan dengan metrik berikut:

Mean Squared Error (MSE):

$$MSE = (1/n) \sum (Q_{pred} - Q_{actual})^2 \dots\dots\dots (11)$$


Model dengan nilai $R^2 \geq 0,85$ dianggap memberikan hasil yang akurat dan dapat diandalkan untuk prediksi laju aliran dalam kondisi serupa. Validasi dilakukan pada data testing (20% dari total dataset) yang tidak digunakan dalam proses training. Perbandingan dilakukan antara ketiga skenario untuk menentukan konfigurasi parameter GA yang optimal, dengan mempertimbangkan trade-off antara akurasi (R^2) dan computational cost (waktu komputasi). Data Input terdapat proses parameter fisika yang akan digunakan dan data sintetis yang akan digunakan ,lalu tahap berikutnya di perhitungan teoritis membahas persamaan Darcy-Weisbach , laju aliran volumetrik , dan faktor gesekan Colebrook-White.Tahapan ketiga algoritma genetika membahas inisialisasi populasi, evaluasi fitness, crossover, mutasi, dan iterasi. Tahap berikutnya ada model prediksi dengan menggunakan Pers.5 atau Q_{pred} dan Optimasi parameter dan dilakukan validasi serta evaluasi dalam perbandingan $Q_{teoritis}$ dan $Q_{prediksi}$, MSE , koefisien determinasi dan analisis residual error .



Gambar 2. 1 Flowchart Metode Penelitian

3. PEMBAHASAN

A. Hasil Percobaan Pertama



Gambar 3. Hasil Percobaan dan Analisa Percobaan Pertama

Empat bagian utama terlihat pada grafik:

- Pada dua puluh generasi awal, kurva konvergensi (Best dan Average Fitness) menunjukkan penurunan tajam. Kemudian kurva tersebut stabil hingga generasi ke-80. Fenomena ini menunjukkan konvergensi dini, atau konvergensi dini, di mana algoritma terlalu cepat konvergen ke solusi lokal tanpa menyelidiki lebih lanjut.
- Plot aliran sebenarnya versus perkiraan menunjukkan sebaran titik yang jauh dari garis diagonal ideal. Ini menunjukkan bahwa modelnya tidak begitu akurat, dan algoritma genetika tidak dapat secara optimal menangkap pola non-linier.
- Distribusi Error Residual menunjukkan bias positif, dengan kebanyakan prediksi di bawah nilai aktual. Ini menunjukkan bahwa model mungkin underestimasi laju aliran.
- Grafik nilai fitur menunjukkan bahwa $1/\text{viscosity}$ dan sqrt_pressure memberikan pengaruh terbesar terhadap model, sementara $\exp(-\text{roughness})$ memiliki pengaruh yang lebih kecil.

Percobaan pertama menggunakan konfigurasi parameter GA dasar untuk mengevaluasi performa awal model hybrid data-fisika. Parameter yang digunakan ditunjukkan pada Tabel 2, dengan ukuran populasi 40, jumlah generasi 80, tingkat crossover 0,70, dan bobot data (λ) sebesar 0,5. Konfigurasi ini dipilih sebagai baseline untuk mengidentifikasi area perbaikan pada percobaan berikutnya.

Tabel 2 Parameter Percobaan Pertama

Parameter	Nilai
Ukuran Populasi	40
Jumlah Generasi	80
Tingkat Crossover	0.70
Tingkat Mutasi	0.08
Data Weight	0.50
Densitas	800 kg/m ³
Mode	GA-Hybrid (Data + Fisika)

Tabel 3 menunjukkan hasil percobaan pertama dengan Best Objective $4,538 \times 10^8$ yang mengindikasikan fungsi objektif hybrid masih sangat tinggi. MSE (Data) sebesar 72,94 menunjukkan error prediksi yang besar, sementara MSE (Physics) sebesar $9,08 \times 10^8$ mengonfirmasi kesulitan model dalam memenuhi constraint fisika Darcy-Weisbach. Nilai $R^2 = 0,087$ menandakan model hanya mampu menjelaskan 8,7% variasi data, yang mengindikasikan

performa prediksi yang sangat rendah. Hasil ini menjadi dasar untuk peningkatan parameter pada percobaan selanjutnya.


Tabel 3 Hasil Percobaan Pertama

Metrik	Nilai
Best Objective	4.538×10^8
MSE (Data)	72.94
MSE (Physics, ΔP)	9.08×10^8
R ² (Kecocokan)	0.087

Hasil ini sesuai dengan teori Darcy-Weisbach, yang berpendapat bahwa tekanan dan viskositas memainkan peran penting dalam menentukan perubahan laju aliran. Berdasarkan hasil tersebut, disimpulkan bahwa untuk mengembangkannya adalah :

- Populasi lebih besar (≥ 60)
- Generasi lebih banyak (≥ 120)
- Crossover lebih tinggi (0.8–0.9)
- Mutasi sedikit ditingkatkan (0.10–0.12)
- Bobot data lebih kuat ($\lambda = 0.7$) untuk memperkuat pembelajaran empiris.

B. Hasil Percobaan Kedua



Gambar 4. Hasil Percobaan dan Analisa Percobaan Kedua

Grafik terdiri dari empat bagian utama :

1. Plot Actual vs Predicted menunjukkan sebaran data yang masih jauh dari garis idealnya yang menandakan error prediksi yang besar dan kecenderungan model belum mampu menyesuaikan data aktual dengan baik
2. Histogram Residual memperlihatkan distribusi error yang tidak simetris dengan bias ke positif yang menandakan ketidakstabilan estimasi GA
3. Kurva Konvergensi (Best & Average Fitness) memperlihatkan bahwa penurunan fungsi objektif (fitness) terjadi cepat di generasi awal (<10 generasi), lalu mendatar hingga generasi ke-120. Ini menunjukkan konvergensi stabil namun sub-optimal
4. Estimasi Pengaruh Fitur (Feature Importance) memperlihatkan bahwa parameter $1/\text{viscosity}$ memiliki pengaruh dominan terhadap model, diikuti bias dan

sqrt_pressure. Hal ini konsisten dengan konsep dasar persamaan Darcy–Weisbach di mana viskositas fluida dan tekanan memiliki kontribusi utama terhadap kehilangan tekanan (ΔP) dan laju aliran.

Berdasarkan hasil percobaan pertama, percobaan kedua dilakukan dengan peningkatan parameter GA untuk memperbaiki performa model. Tabel 4 menunjukkan konfigurasi parameter yang ditingkatkan, meliputi ukuran populasi menjadi 80 (naik 100%), jumlah generasi menjadi 120 (naik 50%), tingkat crossover 0,80, tingkat mutasi 0,12, dan bobot data (λ) ditingkatkan menjadi 0,7. Peningkatan parameter ini bertujuan untuk meningkatkan eksplorasi ruang solusi dan memperkuat pembelajaran empiris dari data.

Tabel 5 menyajikan hasil percobaan kedua yang menunjukkan peningkatan performa dibanding percobaan pertama. Best Objective turun signifikan menjadi $2,724 \times 10^7$ (turun 94% dari percobaan 1), MSE (Data) berkurang menjadi 45,62 (turun 37,5%), dan R^2 meningkat menjadi 0,2341, yang berarti model kini mampu menjelaskan 23,41% variasi data. Meskipun terdapat peningkatan substansial, nilai R^2 masih jauh di bawah threshold 0,85, mengindikasikan perlunya optimasi parameter lebih lanjut. MSE (Physics) yang tetap tinggi ($9,08 \times 10^8$) menunjukkan bahwa trade-off antara fitting data dan pemenuhan constraint fisika masih menjadi tantangan utama.


Tabel 4 Parameter Percobaan Kedua

Parameter	Nilai
Ukuran Populasi	80
Jumlah Generasi	120
Tingkat Crossover	0.80
Tingkat Mutasi	0.12
Data Weight	0.70
Densitas	800 kg/m ³
Mode	GA-Hybrid (Data + Fisika)

Tabel 5 Hasil Percobaan Kedua

Metrik	Nilai
Best Objective	2.724×10^7
MSE (Data)	45,62
MSE (Physics, ΔP)	9.08×10^8
R^2 (Kecocokan)	0.2341

C. Hasil Percobaan Ketiga



Gambar 5. Hasil Percobaan dan Analisa Percobaan Ketiga

1. Plot Actual vs Predicted menunjukkan sebaran titik data yang jauh lebih rapat terhadap garis diagonal ideal, menandakan kecocokan tinggi antara hasil prediksi model dengan data aktual. Korelasi prediksi meningkat secara signifikan dibanding dua percobaan sebelumnya.
2. Histogram Residual (Actual - Predicted) memperlihatkan distribusi error yang simetris dan terpusat di sekitar nol dengan sedikit nilai ekstrem. Hal ini menunjukkan stabilitas tinggi model dalam memprediksi berbagai kondisi fisik aliran. Kurva Konvergensi (Best & Average Fitness) memperlihatkan penurunan fungsi objektif yang tajam pada 20 generasi awal, lalu perlahan mendatar dan mencapai kestabilan penuh sekitar generasi ke-100. Ini menandakan algoritma mencapai konvergensi global yang stabil dan efisien.
2. Estimasi Pengaruh Fitur (Feature Importance) menunjukkan bahwa $1/\text{viscosity}$ masih menjadi faktor dominan, namun kini kontribusi diameter^2 dan pressure meningkat signifikan — sesuai dengan teori dasar hidrodinamika. Hal ini menandakan model sudah menyeimbangkan aspek fisika dan data dengan baik.
3. Kurva Konvergensi (Best & Average Fitness) memperlihatkan penurunan fungsi objektif yang tajam pada 20 generasi awal, kemudian perlahan mendatar dan mencapai kestabilan penuh sekitar generasi ke-100. Pola ini mengindikasikan algoritma mencapai konvergensi global yang stabil dan efisien tanpa konvergensi prematur.

Percobaan ketiga menggunakan konfigurasi parameter GA optimal yang dirancang untuk memaksimalkan eksplorasi ruang solusi dan pembelajaran data. Tabel 6 menunjukkan parameter yang ditingkatkan secara signifikan: ukuran populasi 120 (naik 50% dari percobaan 2), jumlah generasi 300 (naik 150%), tingkat crossover 0,85, tingkat mutasi diturunkan menjadi 0,02 untuk menjaga stabilitas solusi, dan bobot data (λ) ditingkatkan menjadi 0,9. Konfigurasi ini bertujuan mencapai keseimbangan optimal antara eksplorasi-eksploitasi GA dan trade-off data-fisika.

Tabel 6 Parameter Percobaan Ketiga

Parameter	Nilai
Ukuran Populasi	120
Jumlah Generasi	300
Tingkat Crossover	0.85
Tingkat Mutasi	0.02
Data Weight	0.90
Densitas	800 kg/m ³
Mode	GA-Hybrid (Data + Fisika)

Tabel 7 Hasil Percobaan Ketiga

Metrik	Nilai
Best Objective	2.324×10^2
MSE (Data)	2.324×10^2
MSE (Physics, ΔP)	9.08×10^8
R ² (Kecocokan)	0.8624

Tabel 7 menyajikan hasil percobaan ketiga yang mencapai performa optimal. Best Objective turun drastis menjadi $2,324 \times 10^2$ (turun 99,99% dari percobaan 1), MSE (Data) turun menjadi 2,324 (turun 96,8% dari percobaan 1 dan 94,9% dari percobaan 2), dan R² mencapai 0,8624 yang melampaui threshold 0,85. Nilai R² ini menunjukkan bahwa model mampu menjelaskan 86,24% variasi data aktual, mengonfirmasi keberhasilan pendekatan hybrid GA dalam mengoptimasi prediksi laju aliran. Peningkatan R² sebesar 891% dibanding percobaan 1 (dari 0,087 menjadi 0,8624) membuktikan efektivitas konfigurasi parameter optimal yang ditemukan. MSE (Physics) yang konstan pada semua percobaan ($9,08 \times 10^8$) menunjukkan kompleksitas inherent dalam memenuhi constraint fisika, namun dengan $\lambda = 0,9$, model berhasil mencapai keseimbangan optimal antara fitting data dan pemenuhan hukum fisika Darcy-Weisbach.

Hasil kuantitatif menunjukkan kinerja optimal dengan MSE (Data) = 2,324 (turun 94,9% dari percobaan 2) dan R² = 0,8624, yang berarti model mampu menjelaskan 86,24% variasi data aktual. Keberhasilan ini dicapai melalui:

- Populasi besar (120) → meningkatkan keberagaman solusi dan eksplorasi ruang pencarian
- Generasi tinggi (300) → memastikan konvergensi penuh tanpa prematur
- Crossover tinggi (0,85) → meningkatkan eksploitasi solusi baik
- Mutasi rendah (0,02) → menjaga stabilitas solusi terbaik
- Lambda tinggi (0,90) → memberi porsi kuat pada pembelajaran data sambil tetap mempertahankan constraint fisika keseimbangan parameter eksplorasi-eksploitasi GA (Populasi 120, Generasi 300, $\lambda = 0,9$) terbukti optimal untuk masalah optimasi hybrid data-fisika pada sistem perpipaan.

Secara fisika, peningkatan pengaruh diameter² dan pressure memperlihatkan bahwa model sudah memahami hubungan hidrodinamik antara tekanan, dimensi pipa, dan resistansi fluida (1/viscosity) sebagaimana dijelaskan oleh persamaan Darcy-Weisbach. MSE (Physics) yang konstan ($9,08 \times 10^8$) pada semua percobaan menunjukkan bahwa kompleksitas constraint fisika tetap menjadi tantangan, namun dengan $\lambda = 0,9$, model mampu mencapai keseimbangan optimal antara fitting data dan pemenuhan hukum fisika.

D. Analisis Trade-off Data-Fisika

Nilai MSE_fisika yang konstan ($9,08 \times 10^8$) pada semua percobaan menunjukkan bahwa model berbasis data mengalami kesulitan dalam memenuhi constraint fisika Darcy-Weisbach secara penuh. Hal ini mengindikasikan adanya trade-off inherent antara fitting data eksperimen dengan konsistensi terhadap hukum fisika. Peningkatan λ dari $0,5 \rightarrow 0,7 \rightarrow 0,9$ menunjukkan bahwa pemberian bobot lebih tinggi pada MSE_data (pembelajaran empiris) mampu meningkatkan R^2 dari $0,087 \rightarrow 0,2341 \rightarrow 0,8624$, namun tetap mempertahankan pengaruh constraint fisika melalui komponen $(1-\lambda) \cdot \text{MSE_fisika}$. Pada $\lambda = 0,9$, kontribusi fisika masih sebesar 10% terhadap fungsi objektif, yang terbukti cukup untuk menjaga model tetap konsisten dengan prinsip hidrodinamika dasar. Hasil menunjukkan bahwa kombinasi populasi besar (120), generasi tinggi (300), dan λ tinggi (0,9) memberikan performa terbaik dengan peningkatan R^2 sebesar 775,4 poin persentase dibanding percobaan 1. Konfigurasi ini mencapai sweet spot optimal antara: 1. Eksplorasi ruang solusi (populasi besar, generasi tinggi) 2. Pembelajaran empiris dari data (λ tinggi) 3. Pemenuhan constraint fisika ($(1-\lambda)$ mencukupi) Best Objective yang menurun drastis dari $4,538 \times 10^8$ (percobaan 1) menjadi 2,324 (percobaan 3) mengkonfirmasi bahwa proses optimasi GA berhasil menemukan solusi yang jauh lebih baik dalam meminimalkan fungsi objektif hybrid. Hasil menunjukkan bahwa kombinasi populasi besar (120), generasi tinggi (300), dan λ tinggi (0,9) memberikan performa terbaik dengan peningkatan R^2 sebesar 86.62% dibanding percobaan 1.

Tabel 8 perbandingan hasil percobaan

Percobaan	Populasi	Generasi	λ	MSE data	R^2
1	40	80	0.5	72.94	0.087
2	80	120	0.7	45.62	0.2341
3	120	300	0.9	2.324	0.8624

4. SIMPULAN

Penelitian ini membuktikan bahwa Algoritma Genetika berbasis Hybrid Data-Fisika efektif meningkatkan akurasi prediksi laju aliran fluida pada sistem perpipaan. Model terbaik pada percobaan ketiga dengan konfigurasi populasi 120, generasi 300, crossover 0,85, mutasi 0,02, dan $\lambda = 0,9$ menghasilkan MSE (data) = 2,324 dan $R^2 = 0,8624$, menunjukkan kemampuan prediksi yang akurat dan stabil. Peningkatan parameter GA (populasi dan generasi) serta bobot data (λ) terbukti signifikan meningkatkan kinerja model, dengan R^2 meningkat dari 0,087 (percobaan 1) menjadi 0,8624 (percobaan 3), atau peningkatan 891%. Integrasi constraint fisika Darcy-Weisbach melalui komponen MSE_fisika dalam fungsi objektif membantu model memahami hubungan antarparameter (tekanan, viskositas, diameter) sesuai prinsip hidrodinamika, meskipun terdapat trade-off dengan fitting data empiris. Konfigurasi optimal yang ditemukan menunjukkan bahwa: (1) populasi besar (120) meningkatkan keberagaman solusi, (2) generasi tinggi (300) memastikan konvergensi penuh tanpa prematur, dan (3) lambda tinggi (0,9) memberikan keseimbangan optimal antara pembelajaran data dan pemenuhan constraint fisika. Penelitian lanjutan disarankan untuk: (1) menguji model pada data lapangan aktual dari kilang minyak dan gas, (2) mengeksplorasi algoritma optimasi lain seperti Particle Swarm Optimization atau Differential Evolution untuk perbandingan performa, dan (3)

mengembangkan model untuk kondisi aliran multifase yang lebih kompleks.

5. DAFTAR PUSTAKA

- [1] J. Zhou, G. Liang, T. Deng, and J. Gong, "Route Optimization of Pipeline in Gas-Liquid Two-Phase Flow Based on Genetic Algorithm," *Int. J. Chem. Eng.*, vol. 2017, pp. 1–9, 2017, doi: 10.1155/2017/1640303.
- [2] A. K. Arya, R. Jain, S. Yadav, S. Bisht, and S. Gautam, "Recent trends in gas pipeline optimization," *Mater. Today Proc.*, vol. 57, pp. 1455–1461, 2022, doi: 10.1016/j.matpr.2021.11.232.
- [3] H. Lü and Y. F. Cheng, "Artificial Intelligence in Energy Pipelines: Opportunities and Risks," *Engineering*, 2025, doi: 10.1016/j.eng.2025.08.032.
- [4] Y. M. Liu, Q. Guo, W. Xie, and S. Wang, "Enhanced Leak Detection and Localization in Liquid Pipelines Using an Improved Extended Kalman Filter," *Processes*, vol. 13, no. 5, p. 1447, 2025, doi: 10.3390/pr13051447.
- [5] R. Shakarami and M. T. Sadeghi, "An intelligent flow measurement system based on pressure drop in straight pipeline: a deep learning approach," *Sci. Rep.*, vol. 15, no. 1, 2025, doi: 10.1038/s41598-025-19401-z.
- [6] T. Zheng, H. Song, and M. Li, "Research on Interpretation Method of Oil–Water Two-Phase Production Profile Using Artificial Intelligence Algorithm," *Processes*, vol. 13, no. 3, 2025, doi: 10.3390/pr13030886.
- [7] L. Wei, L. Wang, Q. Zhou, and Y. Gao, "Prediction of oil pipeline process operating parameters based on mechanism and data mining," *J. Energy Resour. Technol.*, vol. 146, no. 11, 2024, doi: 10.1115/1.4065951.
- [8] X. Wu, C. Li, Y. He, and W. Jia, "Operation Optimization of Natural Gas Transmission Pipelines Based on Stochastic Optimization Algorithms: A Review," *Math. Probl. Eng.*, vol. 2018, 2018, doi: 10.1155/2018/1267045.
- [9] M. E. Takerhi and K. Dąbrowski, "Optimization of a gas network fuel consumption with genetic algorithm," *Energy Explor. Exploit.*, vol. 41, no. 2, pp. 344–369, 2023, doi: 10.1177/01445987221117182.
- [10] D. Karabaić, M. Kršulja, S. Maričić, and L. Liverić, "The Optimization of a Subsea Pipeline Installation Configuration Using a Genetic Algorithm," *J. Mar. Sci. Eng.*, vol. 12, no. 1, 2024, doi: 10.3390/jmse12010156.
- [11] . Meng, S. Seo, D. Cao, S. Griesemer, and Y. Liu, "When Physics Meets Machine Learning: A Survey of Physics-Informed Machine Learning," *arXiv (Cornell Univ.)*, 2022, doi: 10.48550/arxiv.2203.16797.
- [12] S. H. O. Al-Mansory, O. Al-Fatlawi, and A. Kadkhodaie, "Gas Lift Optimization for Zubair Oil Field Using Genetic Algorithm-Based Numerical Simulation: Feasibility Study," *Iraqi J. Chem. Pet. Eng.*, vol. 25, no. 2, pp. 161–174, 2024, doi: 10.31699/ijcpe.2024.2.15.
- [13] J. X. Wang and H. Xiao, "Data-driven CFD modeling of turbulent flows through complex structures," *Int. J. Heat Fluid Flow*, vol. 62, pp. 138–149, 2016, doi: 10.1016/j.ijheatfluidflow.2016.11.007.
- [14] F. Gong, X. Zhao, C. Du, K. Zheng, Z. Shi, and H. Wang, "Pressure and Temperature Prediction of Oil Pipeline Networks Based on a Mechanism-Data Hybrid Driven Method," *Inf.*, vol. 15, no. 11, 2024, doi: 10.3390/info15110709.
- [15] C. Borraz-Sánchez and R. Z. Ríos-Mercado, "A hybrid meta-heuristic approach for natural gas pipeline network optimization," *Lect. Notes Comput. Sci.*, vol. 3636, pp. 54–65, 2005, doi: 10.1007/11546245_6.

Daftar simbol

- ΔP = kehilangan tekanan (Pa)
- f = faktor gesekan Darcy
- L = panjang pipa (m)
- D = diameter pipa (m)
- ρ = densitas fluida (kg/m³)
- V = kecepatan aliran (m/s)