

**TUGAS AKHIR - TF 234801**

**OPTIMISASI *RATE OF PENETRATION* (ROP) PADA  
OPERASI *DRILLING* MENGGUNAKAN *PREDICTIVE  
MODELLING* DAN *PARTICLE SWARM OPTIMIZATION*  
(PSO) UNTUK MEMINIMALKAN WAKTU DAN BIAYA  
(STUDI KASUS : SUMUR X LAPANGAN MUDI)**

**HAYA AQILAH ZAHRA**  
NRP 5009201062

Dosen Pembimbing  
**Prof. Totok R. Biyanto, Ph.D.**  
NIP 19710702 199802 1 001

**Program Studi S1 Teknik Fisika**  
Departemen Teknik Fisika  
Fakultas Teknologi Industri dan Rekayasa Sistem  
Institut Teknologi Sepuluh Nopember  
Surabaya  
2024





Tugas Akhir - TF 234801

**OPTIMISASI *RATE OF PENETRATION* (ROP) PADA OPERASI *DRILLING* MENGGUNAKAN *PREDICTIVE MODELLING* DAN *PARTICLE SWARM OPTIMIZATION* (PSO) UNTUK MEMINIMALKAN WAKTU DAN BIAYA (STUDI KASUS : SUMUR X LAPANGAN MUDI)**

**HAYA AQILAH ZAHRA**  
NRP 5009201062

Dosen Pembimbing  
**Prof. Totok R Biyanto, Ph.D.**  
NIP 19710702 199802 1 001

**Program Studi S1 Teknik Fisika**  
Departemen Teknik Fisika  
Fakultas Teknologi Industri dan Rekayasa Sistem  
Institut Teknologi Sepuluh Nopember  
Surabaya  
2024

*Halaman ini sengaja dikosongkan*



**FINAL PROJECT - TF 234801**

***OPTIMIZING THE RATE OF PENETRATION (ROP) IN DRILLING OPERATIONS USING PREDICTIVE MODELING AND PARTICLE SWARM OPTIMIZATION (PSO) TO MINIMIZE TIME AND COSTS (CASE STUDY: WELL X FIELD MUDI)***

**HAYA AQILAH ZAHRA  
NRP 5009200162**

Advisor

**Prof. Totok R. Biyanto, Ph.D.  
NIP 19710702 199802 1 001**

**Study Program Bachelor of Engineering Physics  
Department of Engineering Physics  
Faculty of Industrial Technology and System Engineering  
Institut Teknologi Sepuluh Nopember  
Surabaya  
2024**

*Halaman ini sengaja dikosongkan*

## PERNYATAAN ORISINALITAS

Yang bertanda tangan di bawah ini.

Nama Mahasiswa / NRP : Haya Aqilah Zahra/ 5009201062

Departemen / Prodi : Teknik Fisika / S1 Teknik Fisika

Dosen Pembimbing / NIP : Prof. Totok R Biyanto, Ph.D./ 19710702 199802 1 001

dengan ini menyatakan bahwa Tugas Akhir dengan judul "***OPTIMISASI RATE OF PENETRATION (ROP) PADA OPERASI DRILLING MENGGUNAKAN PREDICTIVE MODELLING DAN PARTICLE SWARM OPTIMIZATION (PSO) UNTUK MEMINIMALKAN WAKTU DAN BIAYA (STUDI KASUS : SUMUR X LAPANGAN MUDI)***" adalah hasil karya saya sendiri, bersifat orisinal, dan ditulis dengan mengikuti kaidah penulisan ilmiah.

Bilamana di kemudian hari ditemukan ketidaksesuaian dengan pernyataan ini, maka saya bersedia menerima sanksi sesuai dengan ketentuan yang berlaku di Institut Teknologi Sepuluh Nopember.

Surabaya, 15 Juli 2024

Mahasiswa,



Haya Aqilah Zahra

NRP. 5009201062



## STATEMENT OF ORIGINALITY

The undersigned below:

Name of student / NRP : Haya Aqilah Zahra/ 5009201062

Department : Engineering Physics

Advisor / NIP : Prof. Totok R. Biyanto., Ph.D. / 19710702 199802 1 001

hereby declare that the Final Project with the title of **“OPTIMIZING THE RATE OF PENETRATION (ROP) IN DRILLING OPERATIONS USING PREDICTIVE MODELING AND PARTICLE SWARM OPTIMIZATION (PSO) TO MINIMIZE DRILLING TIME AND COSTS (CASE STUDY: WELL X FIELD MUDI)”** is the result of my own work, is original, and is written by following the rules of scientific writing.

If in the future there is a discrepancy with this statement, then I am willing to accept sanctions in accordance with the provisions that apply at Institut Teknologi Sepuluh Nopember.

Surabaya, 15 July 2024

Student



(Haya Aqilah Zahra)

NRP. 5009201062



## LEMBAR PENGESAHAN

**OPTIMISASI *RATE OF PENETRATION* (ROP) PADA OPERASI *DRILLING*  
MENGUNAKAN *PREDICTIVE MODELLING* DAN *PARTICLE SWARM*  
*OPTIMIZATION* (PSO) UNTUK MEMINIMALKAN WAKTU DAN BIAYA  
(STUDI KASUS : SUMUR X LAPANGAN MUDI)**

### TUGAS AKHIR

Diajukan untuk memenuhi salah satu syarat  
memperoleh gelar Sarjana Teknik pada  
Program Studi Sarjana Teknik Fisika  
Departemen Teknik Fisika  
Fakultas Teknologi Industri dan Rekayasa Sistem  
Institut Teknologi Sepuluh Nopember

Oleh:

**HAYA AQILAH ZAHRA**

**NRP. 5009201062**

Surabaya,

Menyetujui,

Dosen Pembimbing

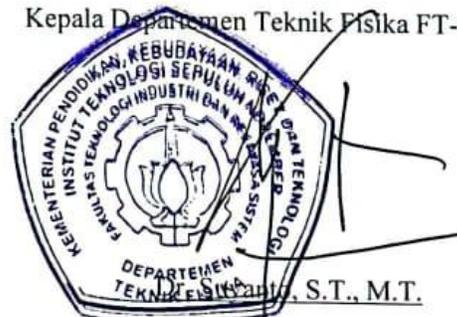


Prof. Totok Ruki Biyanto, S.T., M.T., Ph.D

NIP. 19710702 199802 1 001

Mengetahui,

Kepala Departemen Teknik Fisika FT-IRS ITS



Dr. Susanto, S.T., M.T.

NIP 19711113 199512 1 002



**LEMBAR PENGESAHAN**  
**OPTIMISASI *RATE OF PENETRATION* (ROP) PADA OPERASI *DRILLING***  
**MENGGUNAKAN *PREDICTIVE MODELLING* DAN *PARTICLE SWARM***  
***OPTIMIZATION* (PSO) UNTUK MEMINIMALKAN WAKTU DAN BIAYA**  
**(STUDI KASUS : SUMUR X LAPANGAN MUDI)**

**TUGAS AKHIR**

Diajukan untuk memenuhi salah satu syarat  
memperoleh gelar Sarjana Teknik pada  
Program Studi Sarjana Teknik Fisika  
Departemen Teknik Fisika  
Fakultas Teknologi Industri dan Rekayasa Sistem  
Institut Teknologi Sepuluh Nopember

Oleh:

**HAYA AQILAH ZAHRA**

**NRP. 5009201062**

Disetujui oleh Tim Penguji Tugas Akhir:

1. Prof. Totok R. Biyanto, Ph.D.

 (Pembimbing)

2. Dr. Ir. Purwadi Agus Darwito, M.Sc.

 (Ketua Penguji)

3. Prof. Dr. Ir. Aulia Siti Aisjah, M.T.

 (Penguji)

4. Ir. Harsono, M.Sc., Ph.D.

 (Penguji)

**SURABAYA**

**Juli, 2024**



**APPROVAL SHEET**

***OPTIMIZING THE RATE OF PENETRATION (ROP) IN DRILLING  
OPERATIONS USING PREDICTIVE MODELING AND PARTICLE  
SWARM OPTIMIZATION (PSO) TO MINIMIZE TIME AND COSTS  
(CASE STUDY: WELL X FIELD MUDI)***

**FINAL PROJECT**

Submitted to fulfill one of the requirements  
for obtaining a degree Bachelor of Engineering at  
Undergraduate Study Program of Engineering Physics  
Department of Engineering Physics  
Faculty of Industrial Technology and Systems Engineering  
Institut Teknologi Sepuluh Nopember

By:

**HAYA AQILAH ZAHRA**


**NRP. 5009201062**

Approved Final Project by Examiner Team:

5. Prof. Totok R. Biyanto, Ph.D.

 (Advisor)

6. Dr. Ir. Purwadi Agus Darwito, M.Sc.

 (Chief Examiner)

7. Prof. Dr. Ir. Aulia Siti Aisjah, M.T.

 (Examiner)

8. Ir. Harsono, M.Sc., Ph.D.

 (Examiner)

**SURABAYA**

**July, 2024**



**OPTIMISASI RATE OF PENETRATION (ROP) PADA OPERASI  
DRILLING MENGGUNAKAN *PREDICTIVE MODELLING* DAN  
*PARTICLE SWARM OPTIMIZATION* (PSO) UNTUK MEMINIMALKAN  
WAKTU DAN BIAYA  
(STUDI KASUS : SUMUR X LAPANGAN MUDI)**

Nama Mahasiswa / NRP : Haya Aqilah Zahra/5009200162  
Departemen : Teknik Fisika FTIRS – ITS  
Dosen Pembimbing : Prof. Totok Ruki Biyanto, S.T.,  
M.T., Ph.D./ 19710702 199802 1 001

### **Abstrak**

Operasi pemboran diketahui merepresentasikan 30% dari total biaya produksi pada sumur minyak dan gas. Biaya pemboran memiliki hubungan yang erat dengan waktu pemboran, yang mana semakin singkat waktu pemboran, maka biaya pemboran akan semakin murah, dan begitu juga sebaliknya. Parameter utama yang mempengaruhi secara langsung waktu pemboran adalah *Rate of Penetration* (ROP). Untuk itu, dalam memecahkan masalah biaya dan waktu pemboran, dilakukan penelitian untuk mengoptimasi ROP dengan mempertimbangan tiga parameter utama, yaitu *Weight on Bit* (WOB), *Rotation per Minute* (RPM), dan *Flowrate*. Metode *Predictive Modelling* dan *Particle Swarm Optimization* (PSO) diterapkan untuk mengoptimasi ROP. Metode *Predictive Modelling* merupakan metode *data-driven based* yang menggantikan persamaan tradisional. Penelitian ini menggunakan empat model regresi, memungkinkan model untuk dapat mengidentifikasi hubungan kompleks antara parameter pemboran dengan membaca data historis yang diberikan. Empat algoritma *predictive modelling* yang disimulasikan lalu dievaluasi menggunakan nilai RMSE,  $R^2$ , MAE, dan MAPE. *Random Forest Regressor* dipilih sebagai model yang paling akurat dengan nilai  $R^2$  mencapai 0.92. Optimisasi ROP memberikan hasil yang signifikan, yaitu pengurangan waktu pemboran sampai 6.2 hari dan biaya hingga Rp1,812,531.93 atau 16% lebih murah dari biaya aktual.

**Kata Kunci:** *Machine Learning, Optimisasi, Pemboran Predictive Modelling*

*Halaman ini sengaja dikosongkan*

**OPTIMIZING THE RATE OF PENETRATION (ROP) IN DRILLING  
OPERATIONS USING PREDICTIVE MODELING AND PARTICLE  
SWARM OPTIMIZATION (PSO) TO MINIMIZE TIME AND COSTS  
(CASE STUDY: SUMUR X FIELD MUDI)**

**Student Name /NRP** : Haya Aqilah Zahra / 5009200162  
**Department** : Engineering Physics INSYS – ITS  
**Advisor** : Prof. Totok R. Biyanto, Ph.D./  
19710702 199802 1 001

**Abstract**

Drilling operations are known to represent 30% of the total production cost in oil and gas wells. Drilling costs are closely related to drilling time; the shorter the drilling time, the cheaper the drilling costs, and vice versa. The primary parameter that directly influences drilling time is the Rate of Penetration (ROP). Therefore, to address the issues of drilling costs and time, a study was conducted to optimize ROP by considering three main parameters: Weight on Bit (WOB), Revolutions per Minute (RPM), and Flowrate. Predictive Modeling and Particle Swarm Optimization (PSO) methods were applied to optimize ROP. Predictive Modeling is a data-driven method that replaces traditional equations. This study utilized four regression models, allowing the model to identify complex relationships between drilling parameters by reading the provided historical data. Four predictive modeling algorithms were simulated and then evaluated using RMSE,  $R^2$ , MAE, and MAPE values. Random Forest Regressor was selected as the most accurate model with an  $R^2$  value of 0.92. The ROP optimization yielded significant results, reducing drilling time by up to 6.2 days and costs by Rp1,812,531.93 or 16% cheaper than actual costs.

**Keywords:** Drilling, Machine Learning, Optimization, Predictive Modelling

*Halaman ini sengaja dikosongkan*

## **KATA PENGANTAR**

Puji syukur kepada Allah SWT yang senantiasa memberikan rahmat dan petunjuk-Nya, sehingga kita selalu berada dalam naungan-Nya. Shalawat dan salam senantiasa tercurahkan kepada Nabi Muhammad SAW, yang memungkinkan penulis untuk menyelesaikan penelitian Tugas Akhir dengan judul:

***“OPTIMISASI RATE OF PENETRATION (ROP) PADA OPERASI DRILLING  
MENGUNAKAN PREDICTIVE MODELLING DAN PARTICLE SWARM  
OPTIMIZATION (PSO) UNTUK MEMINIMALKAN WAKTU DAN BIAYA ( STUDI  
KASUS : SUMUR X LAPANGAN MUDI)”***

1. Dr. Suyanto, S.T., M.T., sebagai Kepala Departemen Teknik Fisika, yang telah memberikan pengetahuan, bimbingan, dan sarana selama saya belajar di Teknik Fisika.
2. Prof. Totok R. Biyanto, S.T., M.T., Ph.D., sebagai dosen pembimbing Tugas Akhir saya, yang telah memberikan pengetahuan, panduan, nasihat, dan inspirasi yang akan menjadi bekal berharga dalam perjalanan hidup saya ke depan.
3. Dr. Ridho Hantoro, ST., MT., sebagai dosen wali, yang telah memberikan bimbingan, pengetahuan, arahan, dan perhatiannya selama saya kuliah di Teknik Fisika.
4. Astrini Yuswandari, S.T., dan Dhony Afriyanto, S.T., selaku pembimbing di lapangan serta pihak PT Pertamina EP Cepu yang telah memfasilitasi dan memberikan data serta ilmu-ilmu yang dapat meninjau penelitian saya.
5. Semua dosen, staf, dan komunitas akademik ITS, yang telah memberikan kesempatan, bantuan, dan kerjasamanya selama saya belajar di ITS.
6. Orang tua dan keluarga saya, atas cinta dan doa serta dukungan yang tak henti-hentinya.
7. Teman-teman terdekat saya, yaitu Muhammad Ridho Prakoso, Athalariq Yassirasyid Caesarani, Rakan Akmal Musalim, Danish Puspita Estiningtyas, Fahmi Fitraturrahim, Relita Shinta M. H., dan Aulia Febrian Ulil Albab yang telah memberikan dukungan serta bantuan selama penulis berkuliah di Teknik Fisika
8. Teman-teman asisten Laboratorium Instrumentasi, Kontrol, dan Optimisasi, yang telah banyak membantu saya dalam aktivitas akademik dan non-akademik.

Surabaya, 15 Juli 2024

Penulis



## DAFTAR ISI

PERNYATAAN ORISINALITAS .....	vi
LEMBAR PENGESAHAN .....	x
LEMBAR PENGESAHAN .....	xii
APPROVAL SHEET .....	xiv
Abstrak.....	xvi
<i>Abstract</i> .....	xviii
KATA PENGANTAR .....	xx
DAFTAR ISI.....	xxii
DAFTAR GAMBAR.....	xxvi
DAFTAR TABEL.....	xxx
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	3
1.3 Tujuan.....	3
1.4 Lingkup Kajian.....	3
1.5 Sistematika Laporan .....	4
BAB II TINJAUAN PUSTAKA DAN DASAR TEORI.....	5
2.1 Proses Operasi Pemboran.....	5
2.2 Parameter pada Operasi Pemboran.....	7
2.2.1 Rate of Penetration (ROP) .....	7
2.2.2 <i>Weight on Bit</i> (WOB).....	8
2.2.3 <i>Rotation Speed</i> (RPM) .....	9
2.2.4 <i>Flow Rate</i> (Q).....	10
2.2.5 Hubungan antara ROP, RPM, dan, WOB.....	11
2.3 Pemodelan Tradisional ROP .....	13

2.4	<i>Predictive modelling</i> .....	13
2.4.1	<i>Support Vector Regression (SVR)</i> .....	13
2.4.2	Random Forest (RF) .....	15
2.4.3	Gradient Boosting (GB) Regressor .....	16
2.4.4	<i>K-Nearest Neighbor (kNN)</i> .....	17
2.5	Algoritma Optimisasi.....	18
2.5.1	Particle Swarm Optimization (PSO) Algorithm.....	19
2.6	Kriteria Evaluasi .....	21
2.6.1	<i>Root Mean Squared Error (RMSE)</i> .....	21
2.6.2	<i>Coefficient of Determination (R<sup>2</sup>)</i> .....	21
2.6.3	<i>Mean Absolute Error (MAE)</i> .....	21
2.6.4	<i>Mean Absolute Percentage Error (MAPE)</i> .....	22
2.7	Pra Pemrosesan Data .....	23
BAB III METODOLOGI PENELITIAN .....		25
3.1	Pengumpulan Data Operasi Pemboran pada Sumur X Lapangan Mudi.....	26
3.2	Identifikasi Masalah.....	27
3.3	Pra Pemrosesan Data .....	27
3.4	Pemodelan dan Simulasi <i>Predictive Modelling</i> .....	28
3.2	Evaluasi Hasil dan Pemilihan <i>Predictive modelling</i> .....	30
3.3	Simulasi <i>Predictive Modelling</i> dan PSO .....	30
3.4	Uji Kelayakan Operasi Pemboran Aktual.....	32
3.4.1	<i>Weight on Bit (WOB)</i> .....	32
3.4.2	<i>Flow rate</i> .....	37
3.4.3	<i>Rotation per Minute (RPM)</i> .....	42
3.5	Simulasi <i>Predictive modelling</i> dan PSO dengan Penyesuaian Hasil Uji Kelayakan.....	42
3.6	Perhitungan Waktu Pemboran Hasil Optimisasi .....	43

3.7	Perhitungan Biaya Pemboran Hasil Optimisasi .....	44
3.11	Analisis dan Evaluasi Hasil .....	46
3.12	Penarikan Kesimpulan.....	46
BAB IV HASIL DAN PEMBAHASAN .....		47
4.1	Hasil Simulasi Model ROP .....	47
4.1.1	Bagian 26”.....	47
4.1.2	Bagian 17.5”.....	59
4.1.3	Bagian 12.25”.....	69
4.1.4	Bagian 8.5”.....	79
4.1.5	Pemilihan Model ROP .....	89
4.2	Hasil Optimisasi sebelum Uji Kelayakan.....	91
4.2.1	Bagian 26”.....	91
4.2.2	Bagian 17.5”.....	93
4.2.3	Bagian 12.25”.....	96
4.2.4	Bagian 8.5”.....	98
4.3	Hasil Optimasi Setelah Uji Kelayakan.....	100
4.3.1	Bagian 26”.....	100
4.3.2	Bagian 17.5”.....	102
4.3.3	Bagian 12.25”.....	103
4.3.4	Bagian 8.5”.....	105
4.4	Analisis Hasil RPM, WOB, dan <i>FlowRate</i> terhadap ROP.....	106
4.5	Hasil Perhitungan Waktu Pemboran Hasil Optimisasi.....	108
4.6	Hasil Perhitungan Biaya Pemboran Hasil Optimisasi.....	112
BAB V KESIMPULAN DAN SARAN.....		113
5.1	Kesimpulan.....	113
5.2	Saran.....	113

DAFTAR PUSTAKA.....	115
LAMPIRAN .....	119
BIODATA PENULIS.....	137

## DAFTAR GAMBAR

<b>Gambar 2. 1</b> <i>Rotating System</i> (Hyne,1995) .....	6
<b>Gambar 2. 2</b> <i>Circulation System</i> (Whittaker, 1985).....	7
<b>Gambar 2. 3</b> <i>Buckling pada Drill string</i> (Wu et al., 2024) .....	9
<b>Gambar 2. 4</b> Hubungan antara <i>Rate of Penetration (ROP)</i> dan <i>Rotation Speed (RPM)</i> (Prassl, 2003) .....	11
<b>Gambar 2. 5</b> Hubungan antara <i>Rate of Penetration (ROP)</i> dan <i>Weight on Bit (WOB)</i> (Prassl, 2003) .....	12
<b>Gambar 2. 6</b> Grafik Hasil Prediksi dari SVR Kernel Linear (Douglass, 2020) .....	14
<b>Gambar 2. 7</b> Arsitektur Gradient Boosting (Xu et al., 2023) .....	16
<b>Gambar 2. 8</b> Konsep pencarian Pbest dan Gbest dari PSO (Kennedy J, 1995) .....	19
<b>Gambar 3. 1</b> Diagram Alir Penelitian.....	25
<b>Gambar 3. 2</b> Diagram Blok <i>Predictive Modelling</i> .....	29
<b>Gambar 3. 3</b> Hasil Simulasi <i>Buckling</i> untuk Bagian 26” .....	33
<b>Gambar 3. 4</b> Hasil Simulasi <i>Buckling</i> untuk Bagian 17.5” .....	34
<b>Gambar 3. 5</b> Hasil Simulasi <i>Buckling</i> untuk Bagian 12.25” .....	35
<b>Gambar 3. 6</b> Hasil Simulasi <i>Buckling</i> untuk Bagian 8.5” .....	36
<b>Gambar 3. 7</b> Langkah Uji Kelayakan yang Dilakukan untuk <i>Flow rate</i> .....	37
<b>Gambar 3. 8</b> Grafik Perbandingan Waktu Pemboran Perencanaan dan Aktual Sumur X Lapangan Mudi .....	44
<b>Gambar 3. 9</b> Grafik Perbandingan Perencanaan dan Aktual Biaya Pemboran Sumur X Lapangan Mudi .....	46
<b>Gambar 4. 1</b> Plot Data Aktual Bagian 26” .....	47
<b>Gambar 4. 2</b> Grafik <i>True values Vs Predictions</i> Gradient Boosting 26” .....	48
<b>Gambar 4. 3</b> Plot Perbandingan Nilai <i>Actual</i> dan <i>Predicted</i> ROP GB 26” .....	49
<b>Gambar 4. 4</b> Grafik <i>True values Vs Predictions</i> Random Forest 26” .....	51
<b>Gambar 4. 5</b> Plot Perbandingan Nilai <i>Actual</i> dan <i>Predicted</i> ROP RF 26” .....	52
<b>Gambar 4. 6</b> Grafik <i>True values Vs Predictions</i> <i>k-Nearest Neighbor</i> 26” .....	53
<b>Gambar 4.7</b> Plot Perbandingan Nilai <i>Actual</i> dan <i>Predicted</i> ROP KNN 26” .....	54
<b>Gambar 4. 8</b> Grafik <i>True values Vs Predictions</i> <i>Support Vector Regression</i> 26” .....	56
<b>Gambar 4. 9</b> Plot Perbandingan Nilai <i>Actual</i> dan <i>Predicted</i> ROP SVR 26” .....	57
<b>Gambar 4. 10</b> Grafik <i>True Values Vs Predictions</i> Bingham 26” .....	58

<b>Gambar 4. 11</b> Plot Data Aktual Bagian 17.5” .....	59
<b>Gambar 4. 12</b> Grafik <i>True values Vs Predictions</i> Gradient Boosting 17.5” .....	60
<b>Gambar 4. 13</b> Plot Perbandingan Nilai <i>Actual</i> dan <i>Predicted</i> ROP GB 17.5” .....	61
<b>Gambar 4. 14</b> Grafik <i>True values Vs Predictions</i> Random Forest 17.5” .....	62
<b>Gambar 4. 15</b> Plot Perbandingan Nilai <i>Actual</i> dan <i>Predicted</i> ROP RF 17.5” .....	63
<b>Gambar 4. 16</b> Grafik <i>True values Vs Predictions k-Nearest Neighbor</i> 17.5” .....	64
<b>Gambar 4. 17</b> Plot Perbandingan Nilai <i>Actual</i> dan <i>Predicted</i> ROP KNN 17.5” .....	65
<b>Gambar 4. 18</b> Grafik <i>True values Vs Predictions Support Vector Regression</i> 17.5” .....	66
<b>Gambar 4. 19</b> Plot Perbandingan Nilai <i>Actual</i> dan <i>Predicted</i> ROP SVR 26” .....	67
<b>Gambar 4. 20</b> Grafik <i>True values Vs Predictions</i> Bingham 17.5” .....	68
<b>Gambar 4. 21</b> Plot Data Aktual Bagian 12.25” .....	69
<b>Gambar 4. 22</b> Grafik <i>True values Vs Predictions Gradient Boosting Regression</i> 12.25” .....	70
<b>Gambar 4. 23</b> Plot Perbandingan Nilai <i>Actual</i> dan <i>Predicted</i> ROP GB 12.25” .....	71
<b>Gambar 4. 24</b> Grafik <i>True values Vs Predictions</i> Random Forest 12.25” .....	72
<b>Gambar 4.25</b> Plot Perbandingan Nilai <i>Actual</i> dan <i>Predicted</i> ROP RF 12.25” .....	73
<b>Gambar 4.26</b> Grafik <i>True values Vs Predictions k-Nearest Neighbor</i> 12.25” .....	74
<b>Gambar 4. 27</b> Plot Perbandingan Nilai <i>Actual</i> dan <i>Predicted</i> ROP KNN 12.25” .....	75
<b>Gambar 4. 28</b> Grafik <i>True values Vs Predictions Support Vector Regression</i> 12.25” .....	76
<b>Gambar 4. 29</b> Plot Perbandingan Nilai <i>Actual</i> dan <i>Predicted</i> ROP SVR 12.25” .....	77
<b>Gambar 4. 30</b> Grafik <i>True values Vs Predictions</i> Bingham 17.5” .....	78
<b>Gambar 4. 31</b> Plot Data Aktual Bagian 8.5” .....	79
<b>Gambar 4. 32</b> Grafik <i>True values Vs Predictions</i> Gradient Boosting 8.5” .....	80
<b>Gambar 4. 33</b> Plot Perbandingan Nilai <i>Actual</i> dan <i>Predicted</i> ROP GB 8.5” .....	81
<b>Gambar 4. 34</b> Grafik <i>True values Vs Predictions</i> Random Forest 8.5” .....	82
<b>Gambar 4. 35</b> Plot Perbandingan Nilai <i>Actual</i> dan <i>Predicted</i> ROP RF 8.5” .....	83
<b>Gambar 4. 36</b> Grafik <i>True values Vs Predictions k-Nearest Neighbor</i> 8.5” .....	84
<b>Gambar 4. 37</b> Plot Perbandingan Nilai <i>Actual</i> dan <i>Predicted</i> ROP KNN 8.5” .....	85
<b>Gambar 4. 38</b> Grafik <i>True values Vs Predictions Support Vector Regression</i> 8.5” .....	86
<b>Gambar 4. 39</b> Plot Perbandingan Nilai <i>Actual</i> dan <i>Predicted</i> ROP SVR 8.5” .....	87
<b>Gambar 4. 40</b> Grafik <i>True values Vs Predictions</i> Bingham 8.5” .....	88
<b>Gambar 4. 41</b> Plot Data Hasil Optimisasi Pertama Bagian 26” .....	92
<b>Gambar 4. 42</b> Plot Data Hasil Optimisasi Pertama Bagian 17.5” .....	95
<b>Gambar 4. 43</b> Plot Data Hasil Optimisasi Pertama Bagian 12.25” .....	97

<b>Gambar 4. 44</b> Plot Data Hasil Optimisasi Pertama Bagian 8.5” .....	99
<b>Gambar 4. 45</b> Plot Data Hasil Optimisasi Kedua Bagian 26” .....	101
<b>Gambar 4. 46</b> Plot Data Hasil Optimisasi Kedua Bagian 17.5” .....	103
<b>Gambar 4. 47</b> Plot Data Hasil Optimisasi Kedua Bagian 12.25” .....	104
<b>Gambar 4. 48</b> Plot Data Hasil Optimisasi Kedua Bagian 8.5” .....	106
<b>Gambar 4. 49</b> Perbandingan ROP Aktual dan ROP Optimisasi.....	110
<b>Gambar 4. 50</b> Grafik Perbandingan antara <i>Planned</i> , <i>Actual</i> , dan <i>Optimized</i> Waktu Pemboran .....	111
<b>Gambar 4. 51</b> Grafik Perbandingan antara <i>Planned</i> , <i>Actual</i> , dan <i>Optimized</i> Biaya Pemboran .....	112

*Halaman ini sengaja dikosongkan*

## DAFTAR TABEL

<b>Tabel 2. 1</b> Aturan Praktis RPM .....	9
<b>Tabel 2. 2</b> Aturan Praktis <i>Annular Velocity</i> .....	10
<b>Tabel 2. 3</b> Interpretasi Nilai Mape (Lewis, 1982) .....	22
<b>Tabel 3. 1</b> <i>Lower-Upper Bound</i> berdasarkan Data Historis .....	31
<b>Tabel 3. 2</b> Perbandingan <i>Lower-Upper Bound</i> WOB Data Historis dan Simulasi <i>Buckling</i> ..	37
<b>Tabel 3. 3</b> Spesifikasi <i>Mud Pump</i> HHF-1600HL .....	38
<b>Tabel 3. 4</b> Perhitungan <i>Flow rate</i> untuk Bagian 26" .....	39
<b>Tabel 3. 5</b> Perhitungan <i>Flow rate</i> untuk Bagian 17.5" .....	39
<b>Tabel 3. 6</b> Perhitungan <i>Flow rate</i> untuk Bagian 12.25" .....	40
<b>Tabel 3. 7</b> Perhitungan <i>Flow rate</i> untuk Bagian 8.5" .....	41
<b>Tabel 3. 8</b> Perbandingan Nilai <i>FlowRate</i> Data Historis dan <i>FlowRate</i> Hasil Uji Kelayakan .	41
<b>Tabel 3. 9</b> Perbandingan Nilai RPM Data Historis dan RPM secara Aturan Praktis .....	42
<b>Tabel 3. 10</b> <i>Lower-upper bound</i> Hasil Validasi Uji Kelayakan .....	43
<b>Tabel 3. 11</b> Ringkasan Waktu Pemboran Perencanaan dan Aktual Sumur X Lapangan Mudi .....	44
<b>Tabel 3. 12</b> <i>Tangible Drilling Cost (TDC) and Intangible Drilling Cost (IDC)</i> .....	45
<b>Tabel 4. 1</b> Hasil Prediksi Model Gradient Boosting pada Bagian 26" .....	48
<b>Tabel 4. 2</b> Kriteria Evaluasi Gradient Boosting untuk Bagian 26" .....	50
<b>Tabel 4. 3</b> Hasil Prediksi Random Forest pada Bagian 26" .....	51
<b>Tabel 4. 4</b> Kriteria Evaluasi Random Forest untuk Bagian 26" .....	52
<b>Tabel 4. 5</b> Hasil Prediksi kNN pada Bagian 26" .....	53
<b>Tabel 4. 6</b> Kriteria Evaluasi kNN untuk Bagian 26" .....	55
<b>Tabel 4. 7</b> Hasil Prediksi SVR pada Bagian 26" .....	56
<b>Tabel 4. 8</b> Kriteria Evaluasi SVR untuk Bagian 26" .....	57
<b>Tabel 4. 9</b> Kriteria Evaluasi Bingham untuk Bagian 26" .....	58
<b>Tabel 4. 10</b> Hasil Prediksi GB pada Bagian 17.5" .....	60
<b>Tabel 4. 11</b> Kriteria Evaluasi Gradient Boosting untuk Bagian 17.5" .....	61
<b>Tabel 4. 12</b> Hasil Prediksi RF pada Bagian 17.5" .....	62
<b>Tabel 4. 13</b> Kriteria Evaluasi Random Forest untuk Bagian 17.5" .....	63
<b>Tabel 4. 14</b> Hasil Prediksi kNN pada Bagian 17.5" .....	64
<b>Tabel 4. 15</b> Kriteria Evaluasi kNN untuk Bagian 17.5" .....	65
<b>Tabel 4. 16</b> Hasil Prediksi SVR pada Bagian 17.5" .....	66

<b>Tabel 4. 17</b> Kriteria Evaluasi SVR untuk Bagian 17.5" .....	67
<b>Tabel 4. 18</b> Kriteria Evaluasi Bingham untuk Bagian 17.5" .....	68
<b>Tabel 4. 19</b> Hasil Prediksi GB pada Bagian 12.25" .....	70
<b>Tabel 4. 20</b> Kriteria Evaluasi GB untuk Bagian 12.25" .....	71
<b>Tabel 4. 21</b> Hasil Prediksi RF pada Bagian 12.25" .....	72
<b>Tabel 4. 22</b> Kriteria Evaluasi RF untuk Bagian 12.25" .....	73
<b>Tabel 4.23</b> Hasil Prediksi kNN pada Bagian 12.25" .....	74
<b>Tabel 4. 24</b> Kriteria Evaluasi kNN untuk Bagian 12.25" .....	75
<b>Tabel 4. 25</b> Hasil Prediksi SVR pada Bagian 12.25" .....	76
<b>Tabel 4. 26</b> Kriteria Evaluasi SVR untuk Bagian 12.25" .....	77
<b>Tabel 4. 27</b> Kriteria Evaluasi Bingham untuk Bagian 17.5" .....	78
<b>Tabel 4. 28</b> Hasil Prediksi GB pada Bagian 8.5" .....	80
<b>Tabel 4. 29</b> Kriteria Evaluasi GB untuk Bagian 8.5" .....	81
<b>Tabel 4. 30</b> Hasil Prediksi RF pada Bagian 8.5" .....	82
<b>Tabel 4. 31</b> Kriteria Evaluasi RF untuk Bagian 8.5" .....	83
<b>Tabel 4. 32</b> Hasil Prediksi kNN pada Bagian 8.5" .....	84
<b>Tabel 4. 33</b> Kriteria Evaluasi kNN untuk Bagian 8.5" .....	85
<b>Tabel 4. 34</b> Hasil Prediksi SVR pada Bagian 8.5" .....	86
<b>Tabel 4. 35</b> Kriteria Evaluasi SVR untuk Bagian 8.5" .....	87
<b>Tabel 4.36</b> Hasil Kriteria Evaluasi Kelima Model pada Bagian 26" .....	89
<b>Tabel 4.37</b> Hasil Kriteria Evaluasi Kelima Model pada Bagian 17.5" .....	89
<b>Tabel 4.38</b> Hasil Kriteria Evaluasi Kelima Model pada Bagian 12.25" .....	89
<b>Tabel 4.39</b> Hasil Kriteria Evaluasi Kelima Model pada Bagian 8.5" .....	90
Pada <b>Tabel 4.37</b> berikut, disajikan hasil optimisasi untuk lima belas kedalaman pertama pada bagian 26". Optimisasi yang dilakukan sebelum uji kelayakan menggunakan <i>lower-upper bound</i> berdasarkan data historis seperti yang tertera pada <b>Tabel 3.1</b> . <b>Tabel 4. 40</b> Data <i>Head</i> Hasil Optimisasi sebelum Uji Kelayakan Bagian 26" .....	91
<b>Tabel 4. 41</b> Hasil Optimisasi sebelum Uji Kelayakan 26" .....	93
<b>Tabel 4. 42</b> Perbandingan Hasil Optimisasi dan Hasil Uji Kelayakan bagian 26" .....	93
<b>Tabel 4. 43</b> Hasil Optimisasi sebelum Uji Kelayakan 17.5" .....	95
<b>Tabel 4. 44</b> Perbandingan Hasil Optimisasi dan Hasil Uji Kelayakan bagian 17.5" .....	95
<b>Tabel 4. 45</b> Data <i>Head</i> Hasil Optimisasi Pertama Bagian 12.25" .....	96
<b>Tabel 4. 46</b> Hasil Optimisasi sebelum Uji Kelayakan 12.25" .....	97

<b>Tabel 4. 47</b> Perbandingan Hasil Optimisasi dan Hasil Uji Kelayakan bagian 12.25” .....	98
<b>Tabel 4. 48</b> Data Head Hasil Optimisasi Pertama Bagian 8.5” .....	98
<b>Tabel 4.49</b> Hasil Optimisasi sebelum Uji Kelayakan 8.5” .....	100
<b>Tabel 4. 50</b> Perbandingan Hasil Optimisasi dan Hasil Uji Kelayakan bagian 8.5” .....	100
<b>Tabel 4. 51</b> Data Head Hasil Optimisasi Kedua Bagian 26” .....	101
<b>Tabel 4. 52</b> Hasil Optimisasi setelah Uji Kelayakan 26” .....	102
<b>Tabel 4. 53</b> <i>Data Head</i> Hasil Optimisasi Kedua Bagian 17.5” .....	102
<b>Tabel 4. 54</b> Hasil Optimisasi setelah Uji Kelayakan 17.5” .....	103
<b>Tabel 4. 55</b> <i>Data Head</i> Hasil Optimisasi Kedua Bagian 12.25 .....	104
<b>Tabel 4. 56</b> Hasil Optimisasi setelah Uji Kelayakan 12.25” .....	105
<b>Tabel 4. 57</b> <i>Data Head</i> Hasil Optimisasi Kedua Bagian 8.5” .....	105
<b>Tabel 4. 58</b> Hasil Optimisasi setelah Uji Kelayakan 8.5” .....	106
<b>Tabel 4. 59</b> Hasil Perhitungan Waktu Pemboran menggunakan ROP Hasil Optimisasi .....	108
<b>Tabel 4. 60</b> Ringkasan Perbandingan Waktu Pemboran .....	111
<b>Tabel 4. 61</b> Ringkasan Perbandingan Biaya Pemboran .....	112

*Halaman ini sengaja dikosongkan*

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

Industri minyak dan gas merupakan salah satu penggerak utama ekonomi dunia. Sektor ini merupakan salah satu sektor terbesar dalam ekonomi global. Di Amerika Serikat, Sektor ini menghasilkan 4,8% dari PDB (Produk Domestik Bruto). Industri ini diperkirakan ekspansinya akan terus meningkat di masa depan. Menurut riset yang dilakukan oleh IBISWorld, total pendapatan untuk sektor minyak dan gas mencapai sekitar \$4,3 triliun pada tahun 2023 (U.S. Energy Information Administration, 2022). Industri minyak dan gas terbagi menjadi tiga proses utama, yaitu *upstream*, *midstream*, dan *downstream*. *Upstream* merupakan tahap pertama dalam proses yang melibatkan aktivitas eksplorasi dan produksi minyak dan gas alam dari reservoir bawah tanah. Tahap ini mencakup pemboran sumur minyak, eksplorasi geologis, produksi, dan pengelolaan reservoir. Proses pemboran memiliki urgensi yang sangat besar dalam tahap *upstream*. Pemboran sumur ditujukan untuk mengeksplorasi dan menghasilkan minyak bumi dan gas alam dari reservoir yang tersembunyi di bawah permukaan bumi. Pemboran merupakan proses memecahkan berbagai jenis batuan dan mencapai target formasi untuk mendapatkan sumber daya yang terkubur (Zhou, Y. et al., 2021). Keberhasilan proses pemboran merupakan kunci untuk menemukan dan mengakses sumber daya energi yang dibutuhkan. Pemboran merupakan langkah awal yang sangat penting dalam menentukan keberhasilan proses *upstream*, dan hasilnya dapat berdampak signifikan pada pasokan minyak dan gas dunia.

Kementerian Energi dan Sumber Daya Mineral Indonesia melakukan upaya untuk mengeksplorasi serta memproduksi secara optimal dalam memenuhi target produksi minyak dan gas sebesar 1 juta barel minyak per hari dan 12 miliar kaki kubik gas per hari (BSCFD) pada tahun 2030. Wakil Kepala SKK Migas Nanang Abdul Manaf mengatakan, setidaknya dibutuhkan investasi sebesar US\$ 18 miliar atau Rp 276 triliun per tahunnya guna mencapai target produksi migas tersebut (SKK Migas, 2023). Proses pemboran sendiri merepresentasikan 20% - 30% dari total *production cost*. Hal ini mengantarkan kepada urgensi untuk meminimalkan *drilling cost*. Upaya meminimalkan *drilling cost* tersebut dapat dilakukan dengan meminimalkan *drilling time* dan memaksimalkan nilai *Rate of Penetration* (ROP). ROP merupakan kecepatan mata bor dalam memecahkan batuan di bawahnya sehingga menghasilkan pertambahan kedalaman ke arah yang diinginkan (Vega, M.P., 2014).

ROP tergantung pada berbagai faktor seperti sifat formasi, kedalaman sumur, sifat lumpur, berat mata bor, kecepatan putaran rangkaian bor, sifat kehilangan fluida, jenis mata bor dan hidrolika, keausan mata bor dan pembersihan lubang (Moraveji, M.K., 2016). *Rate of Penetration* (ROP) merupakan salah satu indikator penting untuk menilai efektivitas pemboran. Meskipun ROP yang tinggi dianggap sebagai indikator yang berguna untuk kinerja dan efisiensi pemboran, tetapi pemboran yang lebih cepat dapat berdampak pada pengangkutan *cutting*, menyebabkan ketidakstabilan di dalam lubang bor, dan mengakibatkan pembersihan lubang yang tidak memadai. ROP dapat mengindikasikan keausan mata bor dan bervariasi tergantung pada jenis batuan yang dibor. Oleh karena itu, perusahaan mencari tingkat ROP yang tinggi dengan mengikuti prosedur keselamatan yang disarankan (Hedge et al., 2017).

Parameter statis dan dinamis merupakan faktor yang mempengaruhi optimisasi ROP. *Weigh on Bit* (WOB), *Rotation per Minute* (RPM), dan *Flow rate* (Q) merupakan parameter dinamis yang dapat dikontrol. Kualitas formasi seperti kekuatan tekan dan tekanan formasi merupakan parameter statis. Terdapat dua metode yang dapat digunakan untuk memprediksi nilai ROP, yaitu *physics-based model* atau pemodelan tradisional ROP dan *data-driven based*. *Physics-based model* adalah formula, atau fungsi matematika, yang ditemukan melalui pengujian laboratorium. Pemodelan ROP tradisional yang sudah sering diimplementasikan, yaitu Bingham Model, Bourgoyne and Young Model, Winters, Warren, and Onyia Model, serta Mothhari Model. Sebaliknya, *data-driven model* merupakan model yang memprediksi ROP menggunakan *Machine Learning* dengan inputan data historis. *Machine Learning* yang dapat digunakan dalam memprediksi ROP, yaitu *Gradient Boosting Regression*, *Random Forest Regression*, *Support Vector Regression*, dan *K-Nearest Neighbors*. Berdasarkan penelitian sebelumnya, *data-driven based* model memiliki tingkat akurasi dan reliabilitas lebih tinggi dibandingkan *physics-based* model dalam melakukan prediksi nilai ROP (Hedge et al., 2017).

Penulis menggabungkan metode *predictive modelling* untuk melakukan prediksi pada nilai ROP dan optimisasi menggunakan *Particle Swarm Optimization* (PSO) untuk mendapatkan hasil prediksi yang lebih akurat dan memiliki reabilitas lebih tinggi serta mengoptimalkan nilai ROP, meminimalkan biaya pemboran, dan meminimalkan waktu pemboran. Pemilihan PSO sebagai algoritma optimisasi karena dianggap memiliki efisiensi komputasi yang lebih tinggi dibandingkan algoritma optimisasi lainnya seperti *Genetic Algorithm* (GA) atau *Differential Evaluation* (DE) (Piotrowski et al., 2023).

## 1.2 Rumusan Masalah

Dari latar belakang tersebut, beberapa rumusan masalahnya adalah sebagai berikut:

- a. Bagaimana menentukan *Predictive Modelling* yang memiliki keakuratan paling besar dalam memprediksi nilai *Rate of Penetration* (ROP)?
- b. Bagaimana mengaplikasikan *Particle Swarm Optimization* (PSO) untuk mengoptimisasi ROP dengan input parameter WOB, RPM, dan *Flowrate* pada operasi pemboran?
- c. Bagaimana meminimalkan waktu dan biaya pemboran?

## 1.3 Tujuan

Dari rumusan masalah tersebut, tujuannya adalah sebagai berikut:

- a. Mengetahui cara menentukan *Predictive Modelling* yang memiliki keakuratan paling besar dalam memprediksi nilai *Rate of Penetration* (ROP).
- b. Mengetahui cara mengaplikasikan *Particle Swarm Optimization* (PSO) untuk mengoptimisasi ROP dengan input parameter WOB, RPM, dan *Flowrate* pada operasi pemboran.
- c. Mengetahui cara meminimalkan waktu dan biaya pemboran.

## 1.4 Lingkup Kajian

Tugas akhir ini memiliki beberapa batasan masalah sebagai berikut:

- a. *Predictive modelling* yang digunakan untuk dijadikan acuan komparasi keakuratan adalah *Gradient Boosting Regressor*, *Random Forest Regressor*, *K-Nearest Neighbors*, dan *Support Vector Regressor*.
- b. Data historis yang digunakan sebagai data training dan data set adalah *Rate of Penetration* (ROP), *Weight on Bit* (WOB), *Rotation per Minute* (RPM), dan *Flow rate* (Q) dari operasi pemboran pada Sumur X Lapangan Mudi
- c. Algoritma optimisasi yang digunakan adalah *Particle Swarm Optimization* (PSO)
- d. Kriteria evaluasi yang digunakan dalam menentukan *predictive modelling* adalah *Root Mean Squared Error* (RMSE), *Coefficient Determination* ( $R^2$ ), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE).
- e. Berkaitan dengan keadaan *subsurface*, hasil dari penelitian ini hanya berlaku untuk Sumur X Lapangan Mudi atau Sumur sekitarnya dengan kondisi formasi batuan yang sama. Akan tetapi, metode yang sama dapat diaplikasikan ke Sumur lainnya.
- f. Penelitian ini hanya berlaku untuk *rotating mode*, tidak berlaku untuk *sliding mode*.

## 1.5 Sistematika Laporan

Secara sistematis, laporan penelitian Tugas Akhir ini disusun dalam lima bab dengan penjelasan masing-masing babnya sebagai berikut.

### 1. Bab I Pendahuluan

Bab ini berisikan latar belakang, rumusan masalah, tujuan penelitian, batasan masalah, serta sistematika laporan

### 2. Bab II Tinjauan Pustaka dan Dasar Teori

Bab ini berisikan dasar teori yang digunakan pada penelitian ini. Dasar teori tercantum pada bab ini yaitu, Proses Pemboran, Parameter pada Operasi Pemboran, *Predictive Modelling*, Algoritma Optimisasi, dan Kriteria Evaluasi.

### 3. Bab III Metodologi Penelitian

Bab ini berisikan langkah-langkah dalam melakukan penelitian ini, yaitu Penentuan Masalah, Pengumpulan Data Operasi Pemboran pada Sumur X Lapangan Mudi, Pra Pemrosesan, Simulasi *Predictive Modelling*, Evaluasi Hasil dan Pemilihan *Predictive Modelling*, Simulasi *Predictive Modelling* dan PSO, Perhitungan Waktu Pemboran Hasil Optimisasi, Perhitungan Biaya Pemboran Hasil Optimisasi, Analisis Evaluasi dan Hasil, serta Penarikan Kesimpulan

### 4. Bab IV Hasil dan Pembahasan

Bab ini berisikan hasil-hasil serta pembahasan yang diperoleh dari penelitian ini. Hasil-hasil tersebut terbagi menjadi lima bagian, yaitu Hasil Simulasi *Predictive Modelling*, Hasil Optimisasi sebelum Uji Kelayakan, Hasil Simulasi setelah Uji Kelayakan, Hasil Perhitungan Waktu Pemboran, dan Hasil Perhitungan Biaya Pemboran.

### 5. Bab V Kesimpulan dan Saran

Bab ini berisikan hasil kesimpulan serta saran yang dapat diberikan dari penelitian yang telah dilakukan ini.

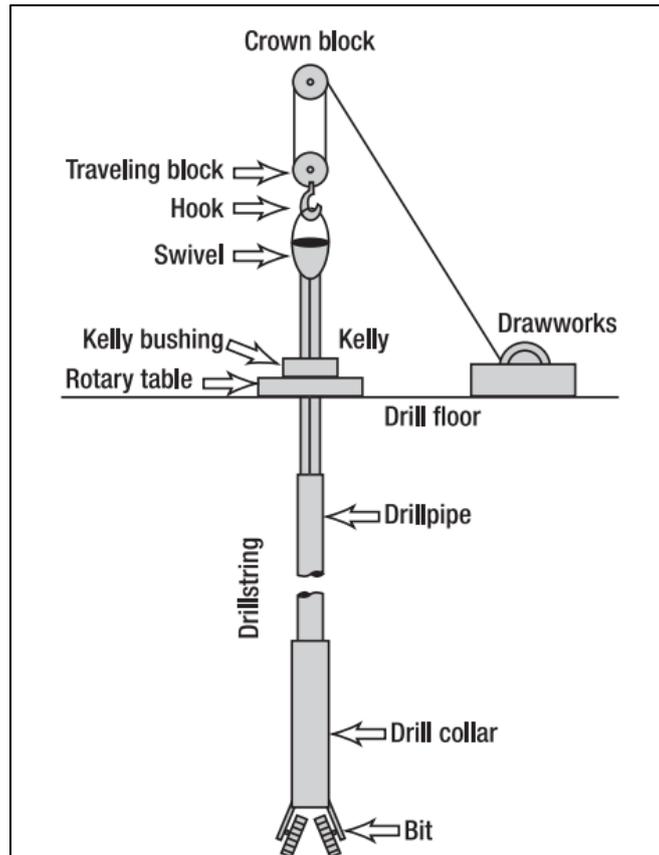
## BAB II

### TINJAUAN PUSTAKA DAN DASAR TEORI

#### 2.1 Proses Operasi Pemboran

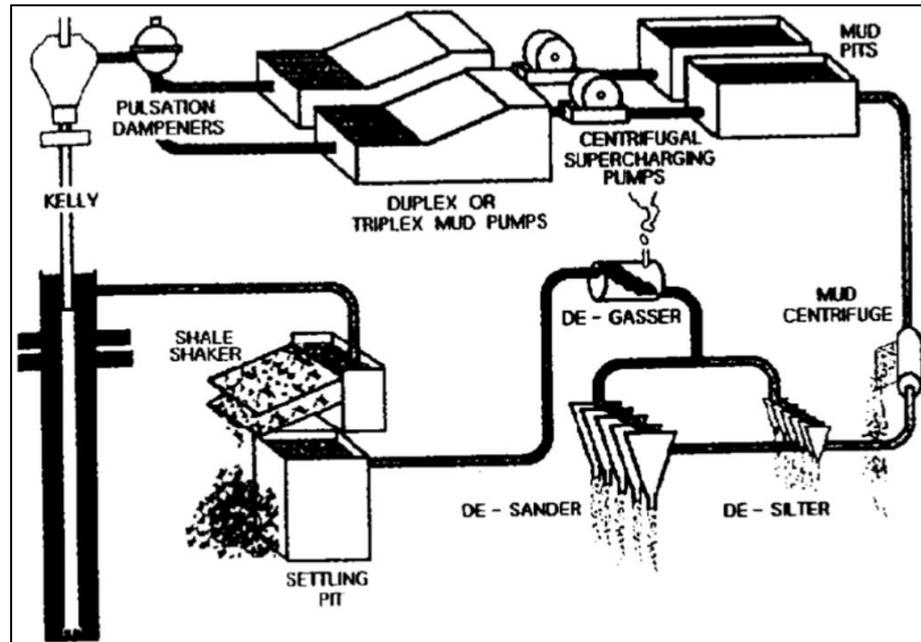
Proses pemboran (*drilling*) merupakan proses pembuatan atau pembesaran lubang dengan gerakan rotasi dari alat pemboran yang digunakan, dapat berupa alat tunggal atau *multi-edge* sirkular. Proses pemboran juga dapat diartikan sebagai proses penetrasi melalui tanah dan ekstraksi batu dari berbagai kedalaman di bawah permukaan untuk mengkonfirmasi keadaan geologi di bawah dan/ atau menyediakan sampel yang dapat digunakan untuk dianalisis. Terdapat dua sistem utama dalam proses pemboran, yaitu *drill string system* dan *circulation system*. *Drill string system* bertanggungjawab dalam mentransmisikan gaya torsi dan axial kepada *drill bit*, sedangkan *circulation system* memiliki fungsi untuk membersihkan atau menghilangkan *cuttings* dari lubang serta memiliki fungsi untuk mendinginkan dan melumaskan *drill bit* (Heinemann, 2019). *Drill string system* terdiri atas beberapa komponen seperti yang tertera pada Gambar 2.1 , yaitu:

- *Drill bit*: Terletak pada bagian bawah *drill string* dan memiliki fungsi dalam membuat lubang dalam proses pemboran. *Drill bit* merupakan komponen yang pertama menyentuh permukaan tanah.
- *Drill collar*: Terletak di atas *drill bit* dan setelah heavy drillpipe. Komponen ini memiliki fungsi untuk memberikan tenaga axial kepada bit. Terdapat dua variasi bentuk, yaitu spiral *drill collar* dan slick *drill collar*.
- Drill pipe: Terletak di bawah Kelly dan memiliki bentuk pipa dengan diameter luar berkisar antara 2.375 inch – 6.625 inch. Berfungsi dalam mentransmisikan tenaga torsi dan axial kepada *drill bit*.
- Kelly: Batang baja panjang yang menghubungkan swivel dan drillpipe serta melalui rotary table. Berfungsi dalam mentransmisikan pergerakan rotasi dari rotary table ke *drill string* (Hyne, 1995).



**Gambar 2. 1** *Rotating System* (Hyne,1995)

Komponen utama sistem sirkulasi pada proses *pemboran* adalah *drilling fluid* atau *mud*. Sistem sirkulasi adalah sistem pompa, jalur distribusi, tangki penyimpanan, lubang penyimpanan, dan unit pembersihan yang berkesinambungan yang memungkinkan cairan pemboran memenuhi tujuan utamanya. Cairan pemboran dicampur di dalam lubang lumpur dan dipompa oleh pompa lumpur melalui putaran, ke bawah pipa bor berongga, melalui lubang (*jet nozzle*) di mata bor, ke atas ruang melingkar antara pipa bor dan lubang sumur (tempat mengangkat lubang lumpur dan potongan batuan) ke permukaan, melalui peralatan kontrol padatan (*shale shaker, desander, dan desilter*), dan kembali ke lubang lumpur. Komponen utama yang berhubungan dengan sistem sirkulasi adalah pompa lumpur, lubang lumpur, peralatan pencampur lumpur, dan peralatan pembuangan kontaminan. Pompa lumpur pada sistem sirkulasi dan drawwork pada sistem pengangkat merupakan dua sumber daya terbesar yang diambil dari sistem tenaga (*power system*). Komponen-komponen tersebut beserta penerapannya di lapangan dapat dilihat pada Gambar 2.2 (Whittaker, 1985).



Gambar 2. 2 Circulation System (Whittaker, 1985).

## 2.2 Parameter pada Operasi Pemboran

Dalam operasi pemboran terdapat beberapa parameter utama, yaitu *Rate of Penetration* (ROP), *Weight on Bit* (WOB), *Rotation Speed* (RPM), dan *Flow rate* (Q).

### 2.2.1 Rate of Penetration (ROP)

*Rate of Penetration* (ROP) adalah parameter penting dalam operasi pemboran yang mengukur kecepatan masuknya mata bor ke dalam formasi. ROP dinyatakan dalam satuan kedalaman per satuan waktu, seperti kaki per jam (ft/hr) atau meter per jam (m/hr) (Alsaihati, 2022). ROP dipengaruhi oleh berbagai parameter pemboran, antara lain *weight on bit* (WOB), *rotation per minute* (RPM), *flowrate* dari lumpur pemboran, sifat lumpur, dan jenis mata bor (Alkinani et al., 2019).

Selain parameter-parameter tersebut, kondisi geologi seperti kekerasan dan komposisi batuan sangat mempengaruhi ROP. Formasi batuan keras biasanya menghasilkan ROP yang lebih rendah dibandingkan formasi yang lebih lunak. Desain dan kondisi bit juga memainkan peran penting; bit yang dirancang khusus untuk kondisi formasi tertentu dapat meningkatkan ROP. Teknologi dan teknik pengeboran modern, termasuk penggunaan sistem kontrol tekanan dan *bit rotary steerable* juga dapat mengoptimalkan ROP (Mitchell & Miska, 2011).

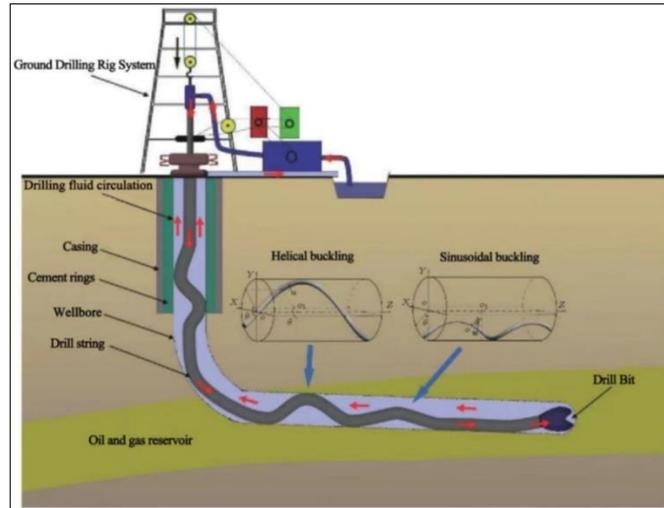
Untuk mengoptimalkan ROP, penting untuk memilih bit yang tepat sesuai dengan kondisi formasi dan tujuan pengeboran, menyesuaikan parameter pengeboran seperti WOB, RPM, dan *flow rate*, serta menggunakan sistem pengawasan dan kontrol yang canggih untuk

memantau dan menyesuaikan parameter pengeboran secara real-time. Operator yang terlatih dan berpengalaman juga dapat membuat keputusan yang lebih baik dalam mengelola parameter pengeboran untuk mencapai ROP yang optimal. ROP yang lebih tinggi berarti pengeboran lebih cepat dan efisien, yang dapat mengurangi waktu dan biaya pengeboran secara keseluruhan. Oleh karena itu, memahami dan mengoptimalkan ROP sangat penting untuk kesuksesan operasi pengeboran (Mitchell & Miska, 2011).

### 2.2.2 *Weight on Bit* (WOB)

*Weight on bit* (WOB) adalah parameter penting dalam operasi pemboran yang mengukur gaya yang diberikan pada mata bor oleh tali bor dan berat kerah bor serta komponen rakitan lubang bawah lainnya. WOB didefinisikan sebagai gaya yang diterapkan pada mata bor ke arah pemboran. WOB ditransmisikan melalui tali bor dan mata bor ke formasi batuan, yang menyebabkan mata bor menembus batuan (Shi et al., 2019). WOB dipengaruhi oleh berbagai parameter pemboran, antara lain berat tali bor, berat rakitan lubang bawah, berat mata bor, dan berat kolom lumpur di dalam lubang sumur. Menurut penelitian yang diterbitkan dalam *Journal of Petroleum Science and Engineering* oleh Xiao et al. (2019), pengaturan yang tepat dari WOB dapat mengoptimalkan interaksi antara alat bor dan formasi batuan, yang pada gilirannya meningkatkan efisiensi operasional secara keseluruhan.

Untuk memastikan operasi pemboran paling efisien, WOB harus diatur ke nilai optimal. *Buckling* pada *drill string* dapat terjadi bila berat pada *drill bit* lebih tinggi dari nilai optimumnya, akibat gaya ke bawah yang berlebihan yang diberikan oleh tali. *Buckling* dapat terjadi ketika pipa dikenai beban tekan yang meningkat, pipa tersebut akan melalui beberapa tahapan atau perubahan konfigurasi. *Sinusoidal buckling* terjadi ketika gaya tekan pada *drill string* menjadi sangat tinggi, menyebabkan *drill string* melengkung seperti ular. Dalam kondisi ini, pipa akan mengalami perubahan bentuk atau deformasi. Selanjutnya, *helical buckling* merupakan bentuk *buckling* yang menyebabkan kerusakan lebih tinggi, yang terjadi saat gaya tekan telah melampaui tahap *sinusoidal buckling* dan melampaui batas dari *helical buckling* itu sendiri. *Helical buckling* dapat menyebabkan terjadinya kontak antara pipa dengan dinding sumur, yang memberikan tekanan pada dinding sumur. Gambaran *helical* dan *sinusoidal buckling* dapat dilihat pada Gambar 2.3 berikut (Z. Wu et al., 2023).



**Gambar 2. 3** Buckling pada Drill string (Wu et al., 2024)

### 2.2.3 Rotation Speed (RPM)

*Rotation speed*, juga dikenal sebagai putaran per menit (RPM), merupakan parameter penting dalam operasi pemboran yang mengukur kecepatan putaran mata bor. RPM didefinisikan sebagai jumlah putaran lengkap yang dilakukan mata bor dalam satu menit yang secara langsung mempengaruhi laju penembusan ROP dan efisiensi pemboran. RPM dipengaruhi oleh berbagai parameter pemboran, termasuk berat mata bor, sifat lumpur, jenis mata bor, dan karakteristik formasi (Khalilidermani, 2023). Kecepatan putaran yang optimal dapat meningkatkan interaksi antara mata bor dan formasi batuan sehingga dapat mempercepat proses pemboran. Akan tetapi, kecepatan putaran yang terlalu tinggi juga dapat menyebabkan keausan pada *drill bit* (Gao et al, 2018). Dalam melakukan penentuan nilai RPM, praktisi menggunakan aturan praktis untuk RPM seperti yang tertera pada **Tabel 2.1** berikut.

**Tabel 2. 1** Aturan Praktis RPM

<b>Rotation per Minute - Aturan Praktis</b> <b>Sumber : K&amp;M Technology</b>	
26"	>180 rpm
17.5"	>180 rpm
12.25"	>120 rpm
9.875"	>120 rpm
8.5"	lebih disarankan >120 rpm, tetapi >70 rpm dapat diterapkan

#### 2.2.4 Flow Rate (Q)

*Flow Rate* (Q) merupakan parameter kritis dalam operasi pemboran yang mengukur volume fluida atau lumpur yang mengalir melalui lubang Sumur per satuan waktu. *Flow rate* didefinisikan sebagai volume fluida atau lumpur yang melewati luas penampang tertentu lubang Sumur per satuan waktu. *Flow rate* dipengaruhi oleh berbagai parameter pemboran, termasuk sifat lumpur, laju pompa, jenis mata bor, dan karakteristik formasi (Alkinani et al., 2019). *Flow rate* memiliki hubungan yang erat dengan *annular velocity*. *Annular velocity* mengukur kecepatan aliran fluida di ruang annular, yaitu celah antara pipa bor dan dinding lubang bor. Peningkatan *flowrate* biasanya akan meningkatkan *annular velocity*, yang sangat penting untuk mengangkat potongan bor (*cuttings*) ke permukaan dan mencegah penumpukan di dasar lubang. *Annular velocity* yang optimal memastikan pembersihan lubang bor yang efektif dan mencegah masalah seperti *stuck pipe* dan *hole cleaning inefficiency*. Studi oleh Li et al. (2016) menunjukkan bahwa pengaturan yang tepat dari *flowrate* dan *annular velocity* harus mempertimbangkan viskositas fluida, ukuran annulus, dan karakteristik potongan bor untuk mencapai efisiensi pengeboran yang maksimal dan mencegah masalah operasional. Hubungan antara *annular velocity* dan *flowrate* dapat dilihat pada persamaan berikut.

$$AV = \frac{24.5 \times Q}{Dh^2 - Dp^2} \quad (2.1)$$

$$Q = \frac{AV(Dh^2 - Dp^2)}{24.5} \quad (2.2)$$

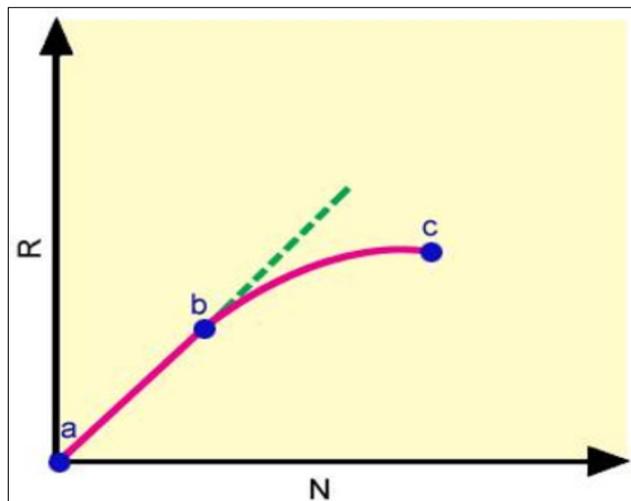
Selain persamaan di atas, praktisi juga menggunakan aturan praktis untuk *annular velocity* yang berkaitan dengan pembersihan *cuttings* seperti pada **Tabel 2.2** berikut.

**Tabel 2. 2** Aturan Praktis *Annular Velocity*

<b><i>Annular Velocity</i> – Aturan Praktis</b> <b>Sumber: K&amp;M Technology</b>	
Ideal	200 ft/min (1.00 m/sec)
Minimum (untuk pembersihan lubang yang efisien)	150 ft/min (0.75 m/sec)
Pembersihan Buruk + Masalah Barit Sag	100 ft/min (0.50 m/sec)

### 2.2.5 Hubungan antara ROP, RPM, dan, WOB

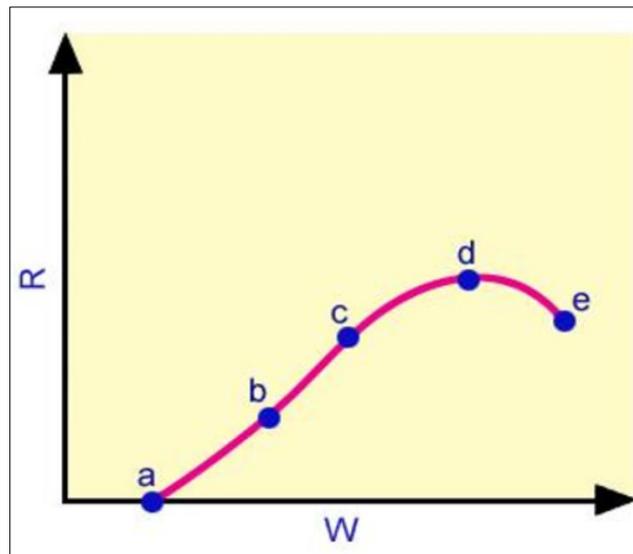
Hubungan antara ROP dan RPM digambarkan oleh grafik pada **Gambar 2.4**. R pada sumbu y menggambarkan nilai ROP dan N pada sumbu x menggambarkan nilai RPM. ROP biasanya meningkat secara linear seiring dengan meningkatnya nilai RPM untuk nilai RPM yang rendah. Pada nilai RPM yang lebih tinggi, laju kenaikan ROP akan berkurang. Pada **Gambar 2.4**, titik b merupakan titik kehilangan linearitas atau disebut sebagai titik pendirian. Fenomena tersebut pada dasarnya disebabkan oleh kurang efisiennya pembersihan lubang dasar dan juga bergantung pada parameter fluida pemboran (densitas, faktor daya apung).



**Gambar 2. 4** Hubungan antara *Rate of Penetration* (ROP) dan *Rotation Speed* (RPM) (Prassl, 2003)

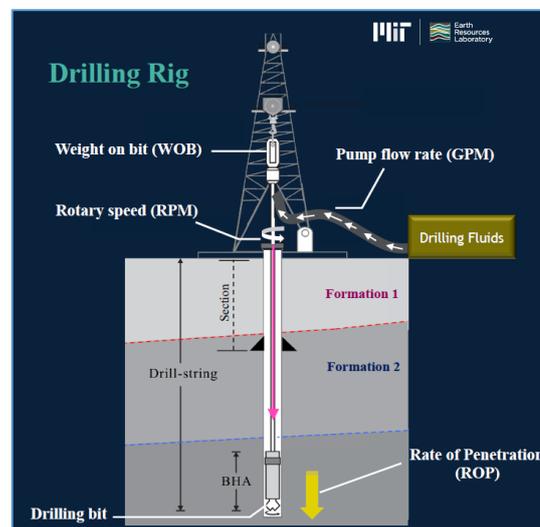
Hubungan antara WOB dan ROP dapat dilihat pada **Gambar 2.5** di bawah. R pada sumbu y mewakili ROP dan W pada sumbu x mewakili WOB. Grafik tersebut diasumsikan tidak terdapat keausan pada *drill bit*. Titik a merepresentasikan tidak adanya perolehan ROP yang signifikan hingga ambang batas tegangan formasi terlampaui. Pada segmen a-b, ROP meningkat secara bertahap dan linier dengan meningkatnya nilai WOB (untuk nilai WOB yang rendah). Pada segmen b-c, kurva linier kembali diperoleh pada WOB yang lebih tinggi, segmen ini menunjukkan kemiringan yang lebih curam, yang menunjukkan peningkatan efisiensi pemboran. Selanjutnya, titik b merupakan titik transisi yang mana modulus keruntuhan batuan berubah dari *scraping* atau *grinding* menjadi *shearing*. Pada segmen c-d, menggambarkan peningkatan WOB berikutnya yang hanya menyebabkan sedikit peningkatan ROP. Segmen d-e menunjukkan dalam beberapa kasus dapat terjadi penurunan ROP pada saat memiliki nilai WOB yang sangat tinggi. Respons yang buruk terhadap ROP pada nilai WOB

yang tinggi biasanya disebabkan oleh kurang efisiennya pembersihan lubang karena laju pembentukan *cuttings* yang lebih tinggi.



**Gambar 2.5** Hubungan antara *Rate of Penetration* (ROP) dan *Weight on Bit* (WOB) (Prasli, 2003)

Selanjutnya, disajikan pula **Gambar 2.6** berikut yang memberikan gambaran penempatan keempat parameter (ROP, RPM, WOB, dan *Flowrate*) pada rig yang digunakan untuk operasi pemboran.



**Gambar 2.6** Parameter Pemboran pada *Drilling Rig* (MIT Earth Resources Laboratory, 2022)

### 2.3 Pemodelan Tradisional ROP

Bingham adalah model ROP tradisional tertua. Model ini dirancang untuk berbagai jenis mata bor dan menganggap ROP sebagai fungsi dari WOB, RPM, dan diameter bit. Meskipun model ini sederhana, model ini masih merupakan titik awal yang baik untuk prediksi ROP.

$$ROP = k \left( \frac{WOB}{d_b} \right)^a RPM \quad (2.3)$$

di mana ROP adalah laju penetrasi (ft/jam), WOB adalah berat pada bit (klb), RPM adalah kecepatan putar (putaran/menit),  $d_b$  adalah diameter bit (inci), dan 'a' serta 'k' adalah konstanta formasi batuan yang diperoleh melalui regresi linier.

### 2.4 Predictive modelling

*Predictive modelling* adalah teknik statistik yang menggunakan *machine learning* dan penambangan data untuk memprediksi dan memperkirakan kemungkinan hasil di masa depan dengan bantuan data historis dan data yang ada. *Predictive modelling* bekerja dengan menganalisis data terkini dan historis serta memproyeksikan apa yang dipelajarinya pada model yang dihasilkan untuk memperkirakan kemungkinan hasil. Model prediktif tidaklah tetap; itu divalidasi atau direvisi secara berkala untuk memasukkan perubahan pada data yang mendasarinya (Samuel, 2000).

*Predictive modelling* adalah komponen penting dari analisis prediktif, yaitu jenis analisis data yang menggunakan data terkini dan historis untuk memperkirakan aktivitas, perilaku, dan tren. Pemodelan prediktif adalah suatu bentuk penambangan data yang menganalisis data historis dengan tujuan mengidentifikasi tren atau pola dan kemudian menggunakan wawasan tersebut untuk memprediksi hasil di masa depan. Pemodelan prediktif digunakan di berbagai bidang, termasuk asuransi, pemasaran, dan keuangan. Manfaat pemodelan prediktif antara lain peningkatan kualitas produk, identifikasi variabel masukan yang optimal, pengurangan variabilitas, dan kepraktisan (Samuel, 2000).

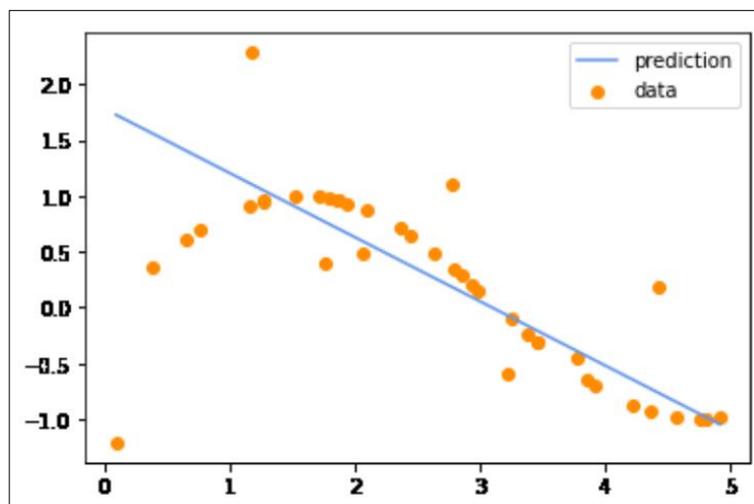
#### 2.4.1 Support Vector Regression (SVR)

*Support Vector Regression* (SVR) adalah *supervised learning algorithm* yang digunakan untuk memprediksi nilai kontinu. SVR adalah jenis Support Vector Machine (SVM) yang digunakan untuk melakukan tugas regresi (Chen, 2006). Tujuan SVR adalah menemukan fungsi yang paling baik dalam memprediksi nilai keluaran kontinu untuk nilai masukan tertentu. SVR menggunakan prinsip yang sama dengan SVM, yaitu mencari

*hyperplane* dalam ruang berdimensi  $n$  yang secara maksimal memisahkan berbagai kelas atau nilai keluaran (Huang, 2010).

Pilihan kernel bergantung pada karakteristik data dan kompleksitas tugas. *Hyperparameter* yang digunakan dalam SVR meliputi *hyperplane*, *kernel*, dan fungsi biaya (Huang, 2010). Kernel pada SVR dibagi menjadi tiga jenis, yaitu Linear Kernel, Polynomial Kernel, dan Radial Basis Function (RBF) Kernel. Linear Kernel merupakan kernel yang cocok untuk kasus yang memiliki hubungan linear antara fitur dan target. Polynomial Kernel adalah kernel yang dapat menangani hubungan non-linear antara fitur dan target. RBF Kernel merupakan kernel yang cocok untuk masalah dengan batas keputusan yang kompleks dan tidak teratur (Douglass, 2020). *Support Vector Regression* (SVR) memiliki beberapa keunggulan, antara lain:

1. Ketahanan terhadap *outlier*. SVR kurang sensitif terhadap outlier dibandingkan algoritma regresi lainnya, sehingga lebih tahan terhadap data yang memiliki banyak noise
2. Fleksibilitas dalam pemilihan kernel. SVR memungkinkan penggunaan berbagai jenis kernel, termasuk kernel linier dan non-linier, yang dapat menangkap pola kompleks dalam data.
3. Prediksi yang cepat. SVR efisien secara komputasi dan dapat membuat prediksi dengan cepat bahkan dengan kumpulan data yang besar
4. Kemampuan untuk menangani tugas klasifikasi dan regresi. SVR dapat digunakan untuk tugas klasifikasi dan regresi, menjadikannya algoritma yang serbaguna (Huang, 2010).



**Gambar 2. 6** Grafik Hasil Prediksi dari SVR Kernel Linear (Douglass, 2020)

### 2.4.2 Random Forest (RF)

Random Forest adalah metode *ensembled learning* yang digunakan untuk klasifikasi, regresi, dan tugas lain dalam *machine learning*. RF pada dasarnya merupakan kumpulan dari *decision tree algorithm*, di mana setiap pohon dipelajari dari subset sampel acak dari *training set* (Amit, 1997). Algoritma ini dikembangkan oleh Leo Breiman dan Adele Cutler, yang mendaftarkan "Random Forests" sebagai merek dagang pada tahun 2006. Ekstensi ini menggabungkan ide "bagging" Breiman dan pemilihan fitur secara acak, yang pertama kali diperkenalkan oleh Ho dan kemudian secara independen oleh Amit dan Geman, untuk membangun kumpulan *decision trees* dengan varians terkendali (Tyralis, 2019). Keuntungan menggunakan Random Forest dalam pembelajaran mesin mencakup ketahanan terhadap outlier, fleksibilitas dalam pemilihan kernel, prediksi cepat, dan kemampuan untuk menangani tugas klasifikasi dan regresi. Akan tetapi, performa algoritma bisa menjadi sensitif terhadap pilihan kernel, dan pemilihan kernel yang salah dapat menyebabkan hasil yang buruk (Mahdavinejad et al., 2018).

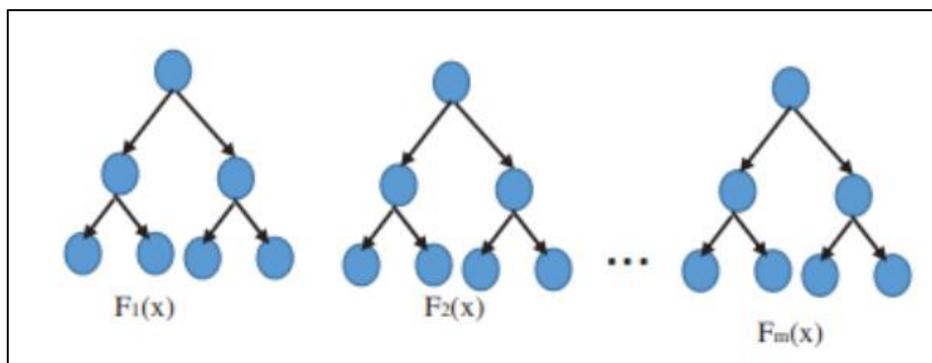
Random Forest merupakan kombinasi dari *tree Predictor* yang pada setiap pohonnya memiliki ketergantungan pada nilai acak vector yang disampling secara independen dan dengan melakukan distribusi ke semua pohon yang ada pada *Forest*. Random Forest menghasilkan ratusan atau bahkan ribuan *decision tree* yang akan bertindak sebagai fungsi regresi dan pada output akhir dari *Random Forest Regression* adalah rata-rata dari output dari *decision tree*. Setiap *decision tree* terdiri atas *decision nodes* dan juga *leaf nodes*. *Decision nodes* tersebut akan melakukan evaluasi pada setiap sample dengan fungsi tes dan melemparkan ke cabang lainnya berdasar dari fitur dari sampel tersebut. Beberapa alasan Random Forest menjadi teknik *mass appraisal* yang sangat sesuai, yaitu:

1. Berdasarkan beberapa penelitian sebelumnya, menyebutkan bahwa RF sangat jarang memiliki masalah performa pada skema regresi.
2. RF mampu bekerja dengan kategori dari banyak tingkat.
3. RF mampu bekerja dengan *missing data*. Apabila sejumlah data hilang, prediksi dilakukan dengan *tree* yang sudah dibuat dan pengecualian observasi tidak diperlukan.
4. RF sangat tahan dari *outliers* dengan adanya *bagging*
5. Metode *regression trees* memperbolehkan data non-linear dan variabel yang tidak stabil tetap mempengaruhi segmen lain.
6. RF dapat menghindarkan hasil prediksi tergolong *underestimation* atau *overestimation*.

Dalam menginisialisasi model *Random Forest Regression*, terdapat *hyperparameter* yang perlu diatur, yaitu *n\_estimators* dan *random\_state*. *N\_estimators* merupakan banyaknya jumlah pohon dalam hutan, semakin banyak pohon, maka semakin baik model akan berperforma, tetapi memakan waktu yang lebih banyak untuk melatihnya. Dalam penentuan *n\_estimators* juga harus dipastikan jumlah pohon tidak menimbulkan terjadinya *overfitting* (model terlalu kompleks atau *ensemble* menangkap *noise* dan detail yang tidak relevan dalam data). Selanjutnya, *random\_state* merupakan parameter yang mengontrol inisialisasi bilangan acak yang dapat memastikan reproduktibilitas hasil yang sama setiap kali model dilatih. Pada umumnya, penerapan *hyperparameter* ini adalah *n\_estimators* = 100 dan *random\_state* = 42 (Douglass, 2020).

### 2.4.3 Gradient Boosting (GB) Regressor

Gradient Boosting termasuk *supervised learning* berbasis *decision tree* yang digunakan untuk klasifikasi dan regresi. Ide awal dari Gradient Boosting awalnya dikemukakan oleh Leo Breiman. Pada penelitiannya, dikatakan bahwa *boosting* memiliki *cost function* yang sesuai. Selanjutnya, Gradient Boosting dikembangkan lebih lanjut oleh Jerome H. Friedman yang menggunakan algoritma tersebut untuk prediksi dan klasifikasi. Friedman juga menggambarkan Gradient Boosting yang mengonstruksikan model regresi dengan melakukan *fitting* secara sekuensial pada fungsi parameter sederhana ke “pseudo”-residual dengan square terkecil pada setiap iterasi. Teknik Gradient Boosting dibuat dengan urutan pohon sederhana yang pada tiap pohon melakukan prediksi residual pada tree sebelumnya. Gradient Boosting merupakan prosedur fitting yang sangat bergantung pada hyperparameter. Gambaran arsitektur Gradient Boosting dapat dilihat pada Gambar 2.7 berikut (Douglass, 2020).



**Gambar 2.7** Arsitektur Gradient Boosting (Xu et al., 2023)

*Gradient Boosting Regression* berbeda dari teknik *bagging* yang mana teknik ini melakukan metode secara sekuensial. Akurasi dari prediksi ditingkatkan melalui pengembangan beberapa model pada sebuah. Perbedaan yang dapat terlihat dari *bagging* dan *boosting* adalah *boosting* memiliki strategi untuk melakukan *resample* pada data *training* untuk menyediakan informasi yang berguna untuk setiap model. Distribusi dari tiap langkah *training* berdasar dari error yang dibuat dari model sebelumnya. Tidak seperti *bagging* yang pada tiap sampel-nya terbentuk untuk membuat *training* dataset, probabilitas dari pemilihan sampel tidak sama pada *boosting* (Huang, 2010). Pengaturan *hyperparameter* yang perlu dilakukan adalah sebagai berikut.

1. *N\_estimators* : Jumlah pohon yang akan dibangun. Semakin banyak pohon, semakin baik biasanya performa model.
2. *Learning\_rate* : Menentukan banyaknya jumlah “belajar” dari kesalahan prediksi model sebelumnya pada setiap pohon.
3. *Max\_depth* : Kedalaman maksimum setiap pohon. Semakin dalam pohon, semakin kompleks model yang dibangun, dan dapat meningkatkan resiko terjadinya *overfitting*.
4. *Min\_samples\_split* : Jumlah minimum sampel yang diperlukan untuk membagi node dalam pohon. Mampu mengontrol kompleksitas model dan mengurangi *overfitting*.

#### 2.4.4 *K-Nearest Neighbor (kNN)*

*K-Nearest Neighbors (kNN)* adalah sebuah metode klasifikasi dan regresi terhadap sekumpulan data berdasarkan pembelajaran data yang sudah terklasifikasikan sebelumnya. *k-Nearest Neighbors (kNN)* adalah algoritma *supervised learning* yang mana dapat memprediksi label atau nilai dari titik data baru (*instance*) berdasarkan kedekatannya dengan titik-titik data lain yang sudah diketahui dalam kumpulan data latih. Hasil prediksi untuk titik data baru ini ditentukan oleh mayoritas label atau nilai dari *k* titik data terdekat dalam kumpulan data latih. Algoritma *kNN* menggunakan klasifikasi ketetanggaan sebagai nilai prediksi dari *query instance* yang baru.

##### **Ukuran Jarak**

Jarak tetangga biasanya dihitung berdasarkan *Euclidean Distance*, perhitungannya sebagai berikut.

$$D(\mathbf{a}, \mathbf{b}) = \sqrt{\sum_{k=1}^d (\mathbf{a}_k - \mathbf{b}_k)^2} \quad (2.4)$$

Dengan  $D(a,b)$  adalah jarak skalar dari dua buah vektor data  $a$  dan  $b$  yang berupa matrik berukuran  $d$  dimensi. Berikut merupakan beberapa macam jarak yang dapat digunakan.

- Jarak *Euclidean*

$$d(\mathbf{x}, \mathbf{y}) = \|\mathbf{x} - \mathbf{y}\| = \sqrt{\sum_{i=1}^n (|x_i - y_i|)} \quad (2.5)$$

- Jarak *Manhattan* atau *Cityblock*

$$d(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^n (|x_i - y_i|) \quad (2.6)$$

- Jarak *Minkowski*

$$d(\mathbf{x}, \mathbf{y}) = \|\mathbf{x} - \mathbf{y}\|_q = (\sum |x - y|^q)^{\frac{1}{q}} \quad (2.7)$$

- Jarak *Mahalanobis*

$$d(\vec{\mathbf{x}}, \vec{\mathbf{y}}) = \sqrt{(\vec{\mathbf{x}} - \vec{\mathbf{y}})^T \mathbf{S}^{-1} (\vec{\mathbf{x}} - \vec{\mathbf{y}})} \quad (2.8)$$

Selanjutnya, untuk penentuan *hyperparameter* dapat dilakukan sebagai berikut.

1. Nilai  $k$  : Jumlah tetangga terdekat yang akan digunakan untuk memprediksi nilai target
2. Metrik Jarak : Jarak tetangga biasanya menggunakan *Euclidean* atau jarak lainnya seperti *Manhattan*, *Minkowski*, dan *Mahalanobis*.
3. Weighting : Memilih apakah bobot tetangga (*weights*) diberikan berdasarkan jaraknya atau tidak (*uniform weights*)

## 2.5 Algoritma Optimisasi

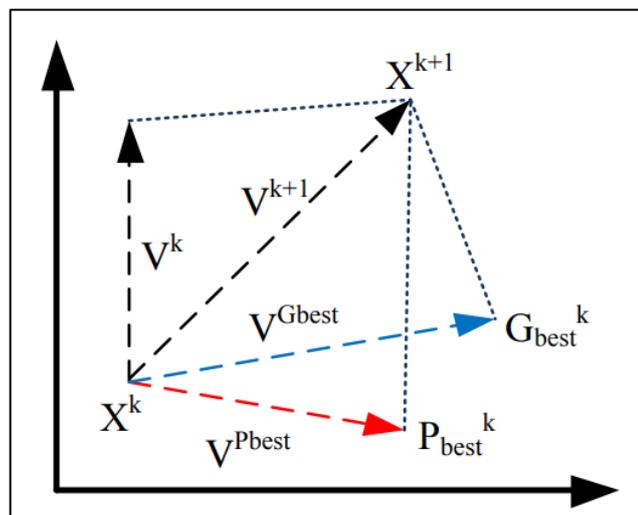
Algoritma optimasi adalah teknik matematika yang digunakan untuk menemukan alternatif terbaik yang tersedia dalam batasan tertentu. Ini adalah proses menemukan solusi terbaik terhadap suatu masalah dari semua solusi yang mungkin. Tujuan dari algoritma optimasi adalah untuk meminimalkan atau memaksimalkan fungsi tujuan tertentu dengan secara sistematis memilih nilai masukan dari dalam himpunan yang diperbolehkan dan menghitung nilai fungsi tersebut.

Algoritma optimasi dapat dibagi menjadi dua kategori, bergantung pada apakah variabelnya kontinu atau diskrit. Beberapa jenis algoritma optimasi yang paling umum termasuk algoritma klasik, algoritma langsung, algoritma stokastik, algoritma berbasis populasi, dan algoritma permukaan respons. Pilihan algoritma optimasi bergantung pada sifat masalah yang dipecahkan, informasi yang tersedia tentang fungsi tujuan, dan sumber daya komputasi yang tersedia (Yang, 2011).

### 2.5.1 Particle Swarm Optimization (PSO) Algorithm

Teknik optimisasi PSO pertama kali diusulkan oleh Kennedy dan Eberhart. Menurut Kennedy dan Eberhart (1995), Optimisasi dengan PSO terinspirasi dari cara hewan seperti burung, ikan, dan lebah berinteraksi dan bertukar informasi dalam kelompok mereka untuk mencari solusi terbaik. PSO adalah algoritma optimisasi global yang efektif untuk menyelesaikan berbagai masalah. Dalam PSO, solusi optimal dicari dalam ruang multidimensi. Algoritma ini didasarkan pada perilaku sosial di mana setiap individu dalam kelompok disebut partikel. Kawanan, atau *swarm*, adalah kumpulan partikel yang bekerja sama untuk mencapai tujuan dengan berinteraksi satu sama lain dan dengan lingkungannya. Setiap partikel dalam swarm berperan sebagai agen yang berkontribusi pada pencarian solusi dengan melihat perilaku dan interaksi partikel lainnya. Dengan mengikuti pola ini, algoritma berbasis swarm yang terinspirasi dari alam mampu menghasilkan solusi yang cepat, biaya rendah, dan efektif untuk menyelesaikan masalah (Kennedy J, 1995).

PSO menggunakan dua operator utama, yaitu pembaruan kecepatan dan pembaruan posisi. Pada setiap iterasi, setiap partikel diperbarui kecepatannya untuk mendekati posisi terbaik yang pernah dicapainya sendiri (*local best*) dan posisi terbaik yang pernah dicapai oleh seluruh populasi (*global best*). Kecepatan baru setiap partikel dihitung berdasarkan kecepatan saat ini, jarak ke posisi terbaiknya sendiri, dan jarak ke posisi terbaik global. Kecepatan baru ini kemudian digunakan untuk memperbarui posisi partikel dalam ruang pencarian. Proses ini terus berulang hingga partikel-partikel mencapai posisi yang stabil atau iterasi mencapai batas yang telah ditentukan, sehingga ditemukan solusi dengan kesalahan minimum (Kennedy J, 1995).



**Gambar 2. 8** Konsep pencarian Pbest dan Gbest dari PSO (Kennedy J, 1995)

Pada PSO, setiap calon solusi disebut sebagai “partikel” dan merupakan titik dalam ruang D-dimensi, jika D adalah jumlah parameter yang dioptimisasi. Dengan demikian, posisi partikel ke-I dapat digambarkan sebagai berikut.

$$\mathbf{X}_i = [X_{i1}, X_{i2}, \dots, X_{iD}] \quad (2.9)$$

Dan populasi dari  $N$  calon solusi yang merupakan *swarm*:

$$\mathbf{X} = \{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_N\} \quad (2.10)$$

Dalam mencari solusi yang optimal, partikel menentukan lintasan dalam ruang parameter (yaitu, iterasi yang memperbarui posisi partikel) berdasarkan persamaan gerak berikut.

$$\mathbf{X}_i(t + 1) = \mathbf{X}_i(t) + \mathbf{V}_i(t + 1) \quad (2.11)$$

Nilai  $t$  dan  $t + 1$  menunjukkan bahwa dua iterasi yang berurutan dari algoritma dan  $\mathbf{V}_i$  adalah kumpulan vektor kecepatan dan partikel ke- $i$  sepanjang dimensi D. Vektor kecepatan mengatur gerak partikel yang melintasi ruang pencarian. Maka, kecepatan partikel ke- $i$  didefinisikan sebagai berikut.

$$\mathbf{V}_i(t + 1) = \mathbf{V}_i(t) + c_1(\mathbf{p}_i - \mathbf{x}_i)(t)R_1 + c_2(\mathbf{g} - \mathbf{x}_i(t))R_2 \quad (2.12)$$

Nilai  $p_i$  disebut sebagai “*personal best*” dari partikel, yaitu koordinat solusi terbaik yang diperoleh sejauh individu dan  $g$  disebut sebagai “*global best*”, yaitu semua solusi yang diperoleh oleh *swarm*. Konstanta percepatan  $c_1$  dan  $c_2$  yang bernilai *real* biasanya dalam kisaran  $0 \leq c_1, c_2 \leq 4$  disebut sebagai “*cognitive coefficient*” dan “*social coefficient*”. Konstanta tersebut akan memodulasi besarnya langkah-langkah yang diambil oleh partikel ke arah *personal best* dan *global best*. Di sisi lain,  $R_1$  dan  $R_2$  merupakan dua diagonal dari matriks secara acak yang dihasilkan dari distribusi yang sama pada  $[0,1]$ . Secara keseluruhan, proses berulang dijelaskan pada persamaan (2.11) dan (2.12) yang diulangi hingga kriteria berhenti, misalnya menentukan jumlah iterasi, jumlah maksimum iterasi sejak pembaruan (*update*) *global best* atau nilai *fitness* telah terpenuhi (Kennedy J, 1995). Selanjutnya, penentuan *hyperparameter* dapat dilakukan sebagai berikut.

1. *Swarmsize* : Jumlah partikel dalam *swarm*.
2. *Omega* atau *Inertia Weight* : Nilai yang mengontrol kecepatan saat ini terhadap kecepatan partikel di iterasi selanjutnya.
3. *Phip* atau *Cognitive Coefficient* : Parameter yang menentukan seberapa besar partikel dipengaruhi oleh pengalaman terbaiknya sendiri (*local best*).
4. *Phig* atau *Social Coefficient*: Parameter yang menentukan seberapa besar partikel dipengaruhi oleh pengalaman terbaik dari seluruh populasi (*global best*).

5. Maxiter : Jumlah maksimum iterasi yang diperbolehkan sebelum algoritma berhenti.

## 2.6 Kriteria Evaluasi

### 2.6.1 Root Mean Squared Error (RMSE)

*Root Mean Squared Error* (RMSE) adalah salah satu metrik evaluasi yang paling umum digunakan untuk mengukur kesalahan pada model prediktif, khususnya dalam konteks regresi. RMSE memberikan gambaran tentang seberapa besar rata-rata kesalahan prediksi model dibandingkan dengan nilai sebenarnya, dengan memberikan penalti yang lebih besar untuk kesalahan yang lebih besar karena kesalahan kuadrat (James et al., 2021).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.13)$$

Dengan,

$n$  = jumlah sampel dalam dataset

$y_i$  = nilai sebenarnya dari sampel ke- $i$

$\hat{y}_i$  = nilai yang diprediksi oleh model untuk sampel ke- $i$

### 2.6.2 Coefficient of Determination ( $R^2$ )

Koefisien determinasi, atau sering disingkat sebagai  $R^2$ , adalah metrik penting dalam analisis regresi yang digunakan untuk mengevaluasi sejauh mana model regresi sesuai dengan data yang diamati.  $R^2$  mengukur proporsi variabilitas dalam variabel dependen yang dapat dijelaskan oleh variabel independen yang ada dalam model. Secara sederhana, nilai  $R^2$  berkisar antara 0 hingga 1, di mana semakin dekat nilai tersebut ke 1, semakin baik model tersebut menjelaskan variasi dalam data. Misalnya, jika  $R^2$  adalah 0.8, itu berarti 80% variabilitas dalam variabel dependen dapat dijelaskan oleh variabel independen dalam model (James et al., 2021).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.14)$$

### 2.6.3 Mean Absolute Error (MAE)

*Mean Absolute Error* (MAE) adalah salah satu metrik evaluasi yang digunakan untuk mengukur kesalahan pada model prediktif, khususnya dalam konteks regresi. MAE mengukur rata-rata dari kesalahan absolut antara nilai yang diprediksi oleh model dan nilai sebenarnya. Berbeda dengan *Root Mean Squared Error* (RMSE), MAE tidak memberikan penalti yang lebih besar untuk kesalahan yang lebih besar, menjadikannya metrik yang lebih *robust* terhadap *outlier* (James et al., 2021).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.15)$$

#### 2.6.4 Mean Absolute Percentage Error (MAPE)

*Mean Absolute Percentage Error* (MAPE) adalah metrik evaluasi yang digunakan untuk mengukur kesalahan pada model prediktif, khususnya dalam konteks regresi. MAPE mengukur kesalahan prediksi sebagai persentase dari nilai aktual, sehingga memungkinkan untuk menilai akurasi model dalam skala relatif (James et al., 2021).

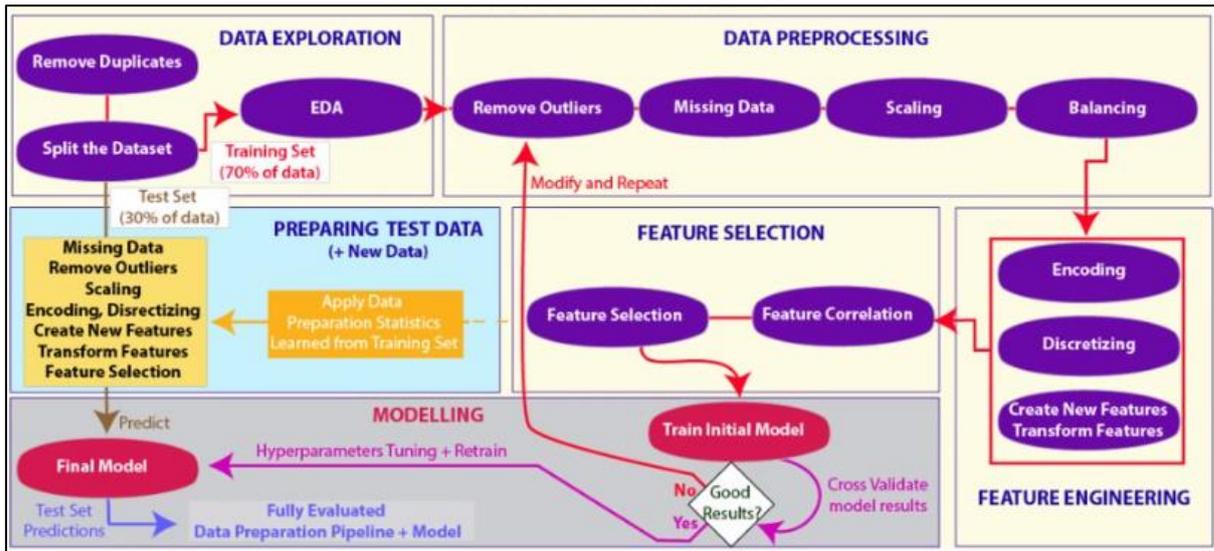
$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2.16)$$

**Tabel 2. 3** Interpretasi Nilai Mape (Lewis, 1982)

MAPE (%)	Interpretasi
<10	Prediksi yang sangat akurat
10-20	Prediksi yang baik
20-50	Prediksi yang dapat diterima
>50	Prediksi yang tidak akurat

## 2.7 Pra Pemrosesan Data

Proses pembersihan data adalah langkah penting dalam persiapan data sebelum digunakan untuk melatih (*training*) atau menguji (*testing*) model dalam *machine learning*. Tujuannya adalah untuk memastikan bahwa data yang digunakan untuk melatih model adalah data yang berkualitas tinggi, konsisten, dan representatif. Langkah-langkah pra pemrosesan dapat dilihat pada Gambar 2.9 dan dijabarkan sebagai berikut.



**Gambar 2. 9** Proses Persiapan Data (Cedric John, Imperial College London, 2022)

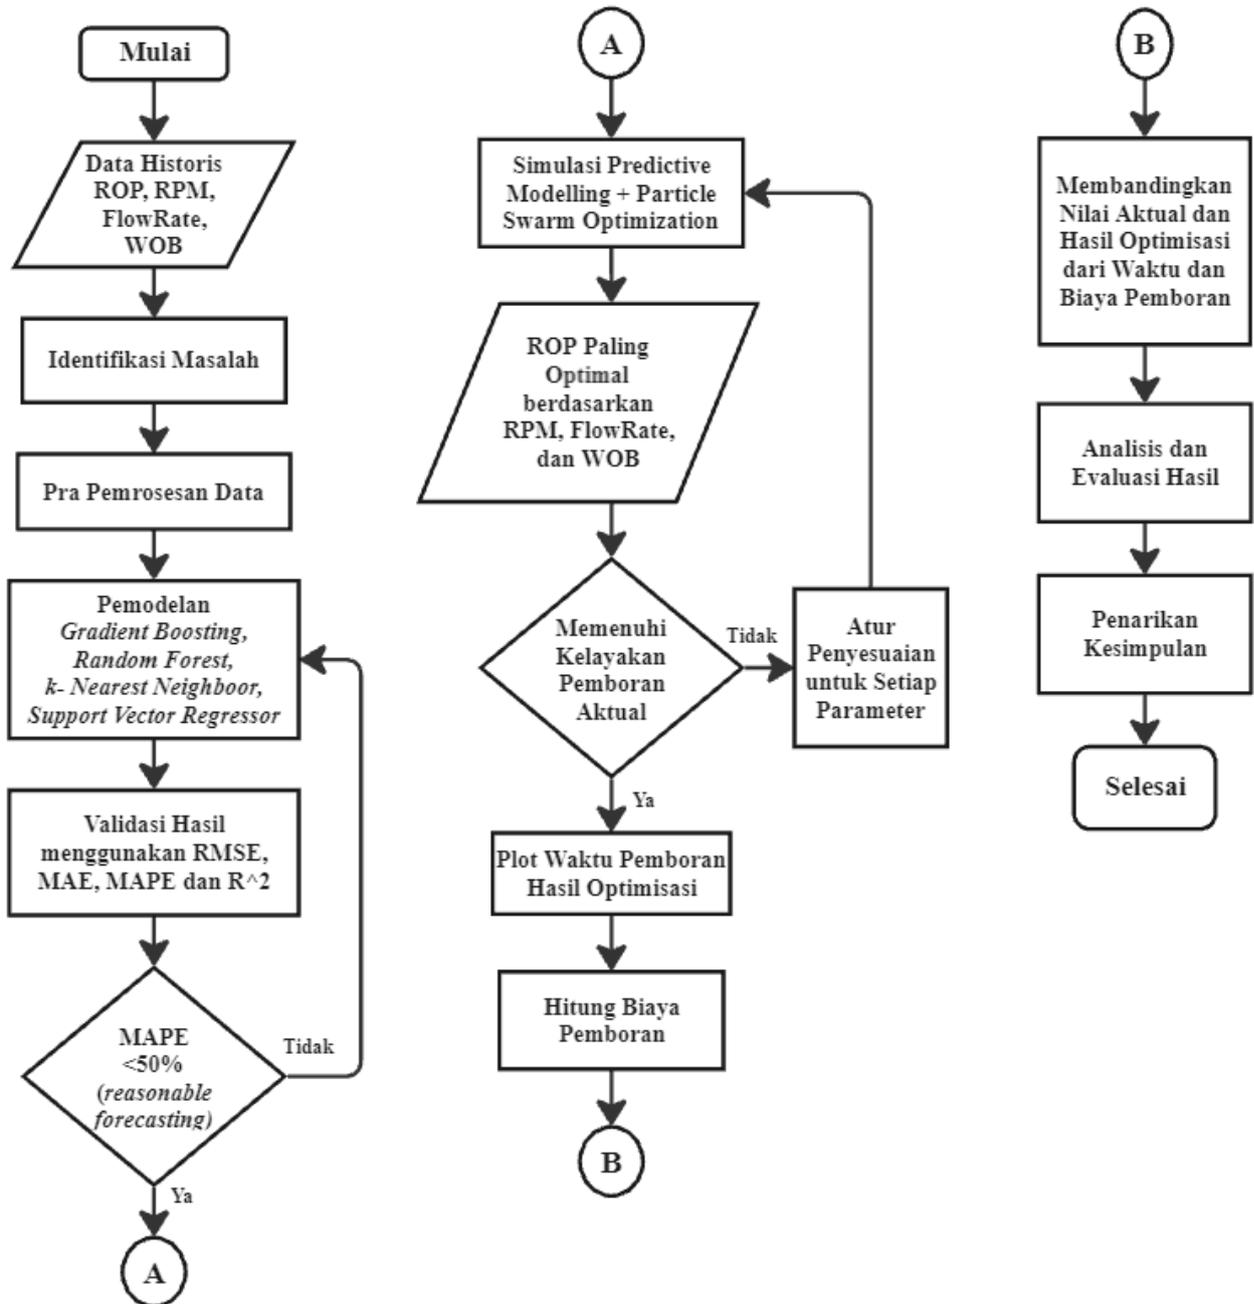
1. Pemahaman Data: Langkah pertama adalah memahami data yang tersedia. Langkah ini merupakan langkah yang melibatkan peninjauan terhadap struktur data, fitur-fitur yang ada, dan nilai-nilai yang mungkin tidak valid atau tidak lengkap.
2. Penanganan Data yang Hilang: Identifikasi dan penanganan nilai-nilai yang hilang atau tidak lengkap dalam dataset. Langkah ini dapat dilakukan dengan mengisi nilai yang hilang dengan nilai rata-rata, median, atau modus dari fitur yang sesuai, atau dengan menggunakan teknik lain seperti imputasi.
3. Pembersihan Data yang Tidak Valid: Mengidentifikasi dan memperbaiki data yang tidak valid atau tidak konsisten. Misalnya, memeriksa apakah ada entri data yang mengandung nilai yang tidak masuk akal atau ekstrem yang mungkin merupakan kesalahan input atau *outliers*. Pada penelitian ini, dilakukan pembersihan data pada keempat parameter, yaitu ROP, RPM, Flow Rate, dan WOB. Pada nilai-nilai yang sangat tinggi melebihi nilai yang biasa diaplikasikan di lapangan dan nilai-nilai yang terlalu rendah seperti nilai-nilai yang kurang dari 1 pada beberapa parameter.

4. Pemilihan Fitur: Memilih subset fitur yang paling relevan atau informatif untuk digunakan dalam pelatihan model. Ini dapat dilakukan berdasarkan analisis statistik, korelasi, atau dengan menggunakan teknik seleksi fitur.
5. Normalisasi atau Standarisasi: Normalisasi atau standarisasi data numerik untuk memastikan bahwa semua fitur memiliki skala yang seragam. Ini dapat membantu dalam meningkatkan kinerja model dan menghindari bias yang tidak diinginkan.
6. Pemisahan Data: Memisahkan dataset menjadi subset yang terpisah untuk digunakan dalam melatih model (*data train*) dan menguji model (*data test*). Biasanya, data diacak terlebih dahulu dan kemudian dipisahkan secara acak dalam proporsi yang sesuai.

### BAB III

## METODOLOGI PENELITIAN

Penelitian ini dilaksanakan dengan beberapa tahapan terstruktur. Gambar 3.1 merupakan diagram alir tahapan penyelesaian penelitian tugas akhir ini.



**Gambar 3. 1** Diagram Alir Penelitian

### 3.1 Pengumpulan Data Operasi Pemboran pada Sumur X Lapangan Mudi

Pada tahap ini, dilakukan perolehan data historis operasi pemboran pada Sumur X Lapangan Mudi. Data yang diperoleh merupakan data historis dari pemboran yang dilakukan oleh divisi *drilling* PT Pertamina EP Cepu. Penulis memperoleh data historis tersebut melalui program magang pada periode Maret sampai April 2024. Data historis yang diperoleh terdiri atas empat parameter, yaitu *Rate of Penetration* (ROP) (ft/hr), *Rotation per Minute* (RPM) (rpm), *Weight on Bit* (WOB) (klbs), dan *Flow rate* (gpm). Parameter ROP digunakan sebagai parameter utama yang akan dioptimasi, sedangkan parameter RPM, WOB, dan *Flow rate* dipilih karena ketiga parameter tersebut merupakan parameter yang bisa diatur di permukaan untuk mempengaruhi ROP dan merupakan tiga parameter utama dalam proses pemboran.

Data historis yang diperoleh merupakan data pada Sumur X Lapangan Mudi. Sumur X merupakan Sumur dengan kedalaman 9239 ftMD. Sumur ini dibagi menjadi empat pengaturan kedalaman *casing* (*casing setting depth*) dengan empat variasi diameter *casing*, yaitu 26", 17.5", 12.25", dan 8.5" yang selanjutnya disebut sebagai "bagian". Dengan bagian 26" memiliki kedalaman 332-2023 ftMD, bagian 17.5" memiliki kedalaman 1935-4495.5 ftMD, bagian 12.25" memiliki kedalaman 4420-7275 ftMD, dan bagian 8.5" memiliki kedalaman 8920-9239 ftMD. Data historis yang diperoleh untuk setiap parameter dimulai dari kedalaman 332 ftMD sampai 9239 ftMD dengan interval 0.5 ftMD untuk setiap data sehingga total data untuk setiap parameter berjumlah 14000 data atau 56000 data untuk keseluruhan dengan jumlah yang bervariasi pada setiap bagian. Bagian 26" memiliki jumlah data sebesar 2633 data untuk setiap parameter, bagian 17.5" sebanyak 4529 data, bagian 12.25" sebanyak 5312 data, dan bagian 8.5" sebanyak 596 data.

Selain pengumpulan data untuk empat parameter tersebut, diperoleh juga data pendukung berupa spesifikasi alat yang digunakan selama operasi pemboran seperti spesifikasi *Mud Pump*, hasil simulasi *buckling* untuk menentukan *Weight on Bit* (WOB) yang dapat diterapkan di keadaan aktual, waktu pemboran perencanaan dan aktual, serta biaya pemboran perencanaan dan aktual. Data-data pendukung tersebut digunakan dalam tahap uji kelayakan operasi pemboran aktual, perhitungan waktu dan biaya pemboran, serta perbandingan hasil perencanaan, aktual, dan hasil optimasi waktu dan biaya pemboran.

### 3.2 Identifikasi Masalah

Tahap kedua merupakan tahap mengidentifikasi dan menentukan masalah yang akan menjadi tujuan dari penelitian tugas akhir ini. Penentuan masalah dimulai dengan mengenali dan menganalisis permasalahan yang terjadi pada operasi pemboran di Sumur minyak dan gas. Permasalahan yang diangkat adalah adanya biaya pemboran yang memiliki persentase hingga 30% dari total biaya produksi pada Sumur minyak dan gas. Biaya pemboran memiliki hubungan yang erat dengan waktu pemboran, yang mana semakin singkat waktu pemboran, maka biaya pemboran akan semakin murah, dan begitu juga sebaliknya. Parameter utama yang mempengaruhi secara langsung waktu pemboran adalah *Rate of Penetration* (ROP). Semakin cepat ROP, maka semakin cepat waktu pemboran. Untuk itu, untuk memecahkan masalah biaya dan waktu pemboran, dilakukan penelitian untuk mengoptimasi ROP. Akan tetapi, terdapat tiga parameter utama (yang dapat diatur di permukaan) yang mempengaruhi nilai ROP. Ketiga parameter tersebut adalah *Rotation per Minute* (RPM), *Weight on Bit* (WOB), dan *Flow rate*.

Secara fisika, keempat parameter ini dapat direpresentasikan melalui beberapa pemodelan konvensional, yaitu Bingham Model, Motahhari Model, dan Hareland Model. Akan tetapi, menurut penelitian (Hedge et al., 2017), pemodelan-pemodelan tradisional tersebut dapat digantikan dengan metode berbasis data (*data-driven based*), yaitu dengan menggunakan *machine learning* atau yang lebih spesifik pada penelitian ini menggunakan algoritma *predictive modelling*. Metode ini terbukti memiliki akurasi, reliabilitas, serta keefektifan yang lebih baik dibandingkan dengan pemodelan tradisional. Hal ini juga berhubungan dengan adanya perbedaan keadaan formasi pada setiap kedalaman sumur yang akan dibor sehingga nilai ROP, WOB, RPM, dan *FlowRate* dapat berbeda-beda setiap 0.5 ft. Selain itu, data yang digunakan pada penelitian ini merupakan data historis pemboran pada sumur X lapangan mudi sehingga hubungan antara ROP, RPM, WOB, *Flow Rate* dan keadaan formasi untuk setiap kedalaman dapat lebih akurat. Oleh karena itu, digunakan metode *predictive modelling* dan *Particle Swarm Optimization* (PSO) untuk melakukan optimisasi ROP dengan mempertimbangkan hubungan ketiga parameter (RPM, WOB, dan *Flow rate*) dengan ROP.

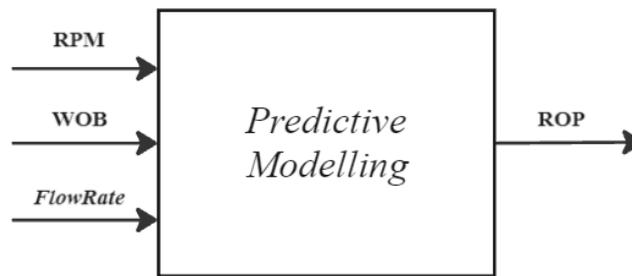
### 3.3 Pra Pemrosesan Data

Tahap ketiga ini merupakan tahap persiapan data atau disebut *pra-processing* dengan langkah-langkah yang sudah dijabarkan pada Sub Bab 2.7.

1. Pemahaman Data: Melakukan pemahaman terhadap data mentah yang diberikan. Data historis yang diberikan merupakan data ASCII (*American Standard Code for Information Interchange*) dari operasi pemboran pada Sumur X Lapangan Mudi. Data historis berisikan sepuluh parameter berdasarkan kedalamannya, tetapi yang akan digunakan pada penelitian ini hanya empat parameter (ROP, RPM, WOB, dan *flowrate*). Oleh karena itu dilakukan pemahaman data dengan meninjau parameter yang akan digunakan dan yang tidak digunakan.
2. Penanganan Data yang Hilang: Data historis memiliki total 14000 data untuk setiap parameter, tetapi pada beberapa kedalaman terdapat beberapa data yang hilang atau bernilai 0. Oleh karena itu dilakukan penanganan dengan mengisi data yang hilang tersebut dengan nilai mean, median, dan modus dari data pada tersebut.
3. Pembersihan Data yang Tidak Valid: Keempat parameter pada data historis tersebut memiliki nilai-nilai yang tidak valid. Data ROP menunjukkan data yang anomali atau bisa disebut *drilling break*, yaitu ketika ROP mengalami kenaikan yang sangat signifikan pada kedalaman tertentu. Oleh karena itu, data tidak valid tersebut dihapus supaya tidak merusak variabilitas yang terbaca dalam data.
4. Pemilihan Fitur: Berhubungan dengan langkah nomor 2, yaitu pemahaman data, pemilihan fitur, yaitu berupa pemilihan *predictor* dan target. Penelitian ini menggunakan tiga *predictor*, yaitu RPM, WOB, dan *flowrate*, serta targetnya adalah ROP.
5. Normalisasi atau Standarisasi: Langkah ini menggunakan fitur pada *library python*, yaitu untuk standarisasi menggunakan *StandardScaler* serta untuk normalisasi menggunakan *MinMaxScaler*.

### 3.4 Pemodelan dan Simulasi *Predictive Modelling*

Pada tahap ini, data yang sudah dibersihkan akan digunakan sebagai data uji dan data latih untuk simulasi *predictive modelling*. Proses simulasi *predictive modelling* ini memiliki tiga input, yaitu RPM, WOB, dan *flowrate* serta outputnya adalah hasil prediksi ROP seperti yang tertera pada diagram blok (Gambar 3.3) berikut.



**Gambar 3. 2** Diagram Blok *Predictive Modelling*

Terdapat beberapa langkah yang dilakukan dalam melakukan simulasi ini, yaitu sebagai berikut:

1. Memisahkan data setiap bagian pada 1 file excel sehingga diperoleh 4 file excel berisikan data historis masing-masing bagian.
2. Syntax dalam bahasa pemrograman python dipersiapkan untuk setiap algoritma yang akan disimulasikan, yaitu *Gradient Boosting Regression*, *Random Forest Regression*, *k-Nearest Neighbor Regression*, dan *Support Vector Regression*. Syntax dari setiap algoritma dapat dilihat pada lampiran.
3. Syntax dilengkapi dengan menampilkan hasil RMSE, MAE, MAPE dan  $R^2$
4. Syntax dilengkapi dengan grafik hasil plot antara *true values* dan *predictions*
5. Syntax dilengkapi dengan menyimpan Tabel hasil prediksi ROP ke dalam file excel
6. Data uji dan data latih dibagi menjadi 30% dan 70%
7. Inisialisasi model dilakukan untuk setiap algoritma dengan menggunakan metode *grid search* sebagai berikut.

#### ***Gradient Boosting Regression***

```

'n_estimators': [100, 200, 300],
'learning_rate': [0.01, 0.1, 0.2],
'max_depth': [3, 5, 7],
'min_samples_split': [2, 5, 10],
'min_samples_leaf': [1, 2, 4],
'loss': ['squared_error', 'absolute_error']
  
```

#### ***Random Forest Regression***

```

n_estimators': [100, 200, 300],
'max_depth': [None, 10, 20, 30],
'min_samples_split': [2, 5, 10],
  
```

'min\_samples\_leaf': [1, 2, 4],

'bootstrap': [True, False]

### ***k-Nearest Neighbors Regression***

'n\_neighbors': [3, 5, 7, 9, 11],

'weights': ['uniform', 'distance'],

'metric': ['euclidean', 'manhattan', 'minkowski'],

'algorithm': ['auto', 'ball\_tree', 'kd\_tree', 'brute'],

'leaf\_size': [20, 30, 40],

'p': [1, 2]

### ***Support Vector Regression***

'kernel': ['rbf', 'linear', 'poly'],

'C': [0.1, 1, 10, 100],

'gamma': ['scale', 'auto'],

'degree': [2, 3, 4]

8. Setiap algoritma dilakukan validasi hasil dengan syarat MAPE <50% atau termasuk ke dalam *reasonable forecasting* mengacu kepada Tabel 2.3
9. Simulasi untuk setiap algoritma dilakukan secara bergantian
10. Hasil simulasi berupa grafik plot *true values vs predictions*, RMSE,  $R^2$ , MAE, MAPE dan file excel berisi hasil prediksi ROP disimpan untuk kemudian dianalisis
11. Plot antara ROP aktual dan ROP prediksi dibuat untuk mempermudah proses analisis

## **3.2 Evaluasi Hasil dan Pemilihan *Predictive modelling***

Pada tahap ini, hasil simulasi akan dianalisis dan satu algoritma *predictive modelling* yang paling akurat akan dipilih untuk selanjutnya digunakan dalam proses optimasi menggunakan algoritma Particle Swarm Optimization (PSO). Evaluasi hasil dilakukan dengan membandingkan keempat algoritma *predictive modelling* yang memiliki nilai RMSE, MAE, MAPE paling rendah dan  $R^2$  paling tinggi atau paling mendekati nilai 1. Setelah dilakukan analisis perbandingan hasil, satu algoritma *predictive modelling* dipilih untuk selanjutnya dijadikan sebagai fungsi objektif pada algoritma optimasi PSO.

## **3.3 Simulasi *Predictive Modelling* dan PSO**

Setelah memperoleh satu algoritma *predictive modelling* yang paling akurat, proses optimasi dilakukan. Algoritma *predictive modelling* yang dipilih dijadikan sebagai fungsi objektif dalam algoritma PSO sebagai berikut.

```
# Definiskan fungsi f(X) untuk optimisasi
def f_group(X):
    return -model_rf.predict(X_df) # Tanda Minus untuk Mengoptimasi
```

Syntax di atas menunjukkan  $f(x)$  dari pemodelan PSO tersebut menggunakan model *Random Forest Regression* yang dituliskan dalam bentuk `-model_rf.predict(X_df)`. Penyesuaian syntax dapat dilakukan mengikuti algoritma *predictive modelling* yang dipilih dengan mengganti “`model_rf`”. Pemanggilan fungsi model dapat disesuaikan dengan inisialisasi yang dilakukan untuk setiap algoritma. Dalam syntax yang digunakan pada tugas akhir ini, Gradient Boosting dapat ditulis menjadi “`model_gb`”, kNN dapat ditulis menjadi “`model_knn`”, dan SVR dapat ditulis menjadi “`model_svr`”.

Selain mengganti fungsi objektif pada PSO menjadi salah satu *predictive modelling*, terdapat beberapa langkah untuk melakukan simulasi pada tahap ini sebagai berikut.

1. Data yang digunakan dalam simulasi optimasi dibagi berdasarkan diameter *casing* sehingga dibagi menjadi empat file excel, yaitu data pada diameter 26”, 17.5”, 12.25”, dan 8.5”
2. Pengaturan *hyperparameter* dilakukan sebagai berikut.
  - swarmsize = 200
  - omega = 0.3
  - phip = 0.5
  - phig = 0.5
  - maxiter = 200
3. Pengaturan *lower* dan *upper bound* juga dilakukan untuk setiap bagian dengan mengacu kepada data historis sebagai berikut

**Tabel 3. 1** *Lower-Upper Bound* berdasarkan Data Historis

Bagian	WOB (klbs)		RPM (rpm)		Flow rate (gpm)	
	<i>Lower</i>	<i>Upper</i>	<i>Lower</i>	<i>Upper</i>	<i>Lower</i>	<i>Upper</i>
26”	1	40	10	80	700	1200
17.5”	0.1	35	10	81	500	1200
12.25”	1.3	39	50	150	450	4300
8.5”	5	46	41	130	400	630

4. Simulasi untuk setiap bagian dilakukan secara bergantian
5. Hasil simulasi berupa file excel yang berisi nilai *Maximized* ROP, RPM, WOB, dan *Flow rate* kemudian diperoleh dan disimpan untuk dianalisis lebih lanjut

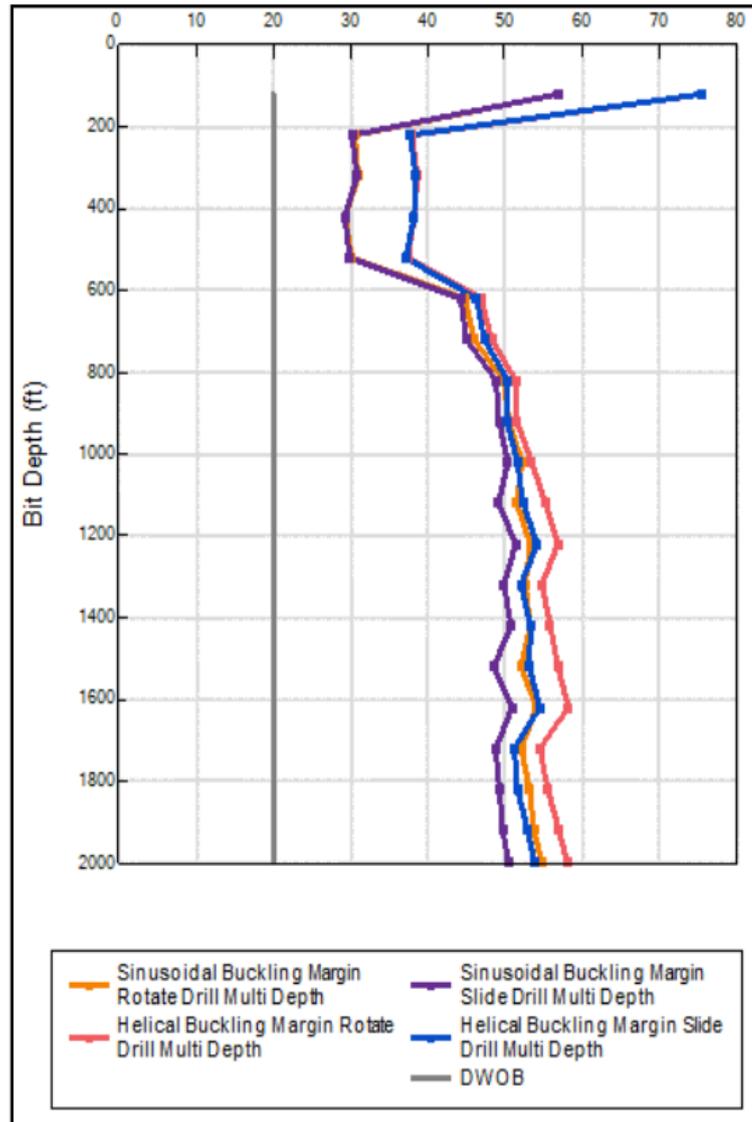
Setelah langkah-langkah tersebut dilakukan, proses uji kelayakan operasi pemboran aktual untuk parameter WOB, *Flow rate*, dan RPM dilakukan.

### 3.4 Uji Kelayakan Operasi Pemboran Aktual

Tahap ini merupakan tahap penentu apakah hasil dari optimasi yang dilakukan berupa nilai WOB, RPM, dan *Flow rate* dapat diterapkan pada kondisi aktual Sumur X atau tidak. Apabila hasil optimasi tervalidasi dapat diterapkan pada kondisi aktual Sumur X, maka tidak perlu dilakukan simulasi optimisasi ulang dan dapat dilanjutkan ke proses perhitungan waktu dan biaya pemboran. Apabila hasil optimasi tervalidasi tidak dapat diterapkan pada kondisi aktual Sumur X, maka diperlukan simulasi ulang dengan penyesuaian baru, yaitu pengaturan *lower* dan *upper bound* untuk setiap bagian dan ketiga parameter (WOB, RPM, dan *Flow rate*).

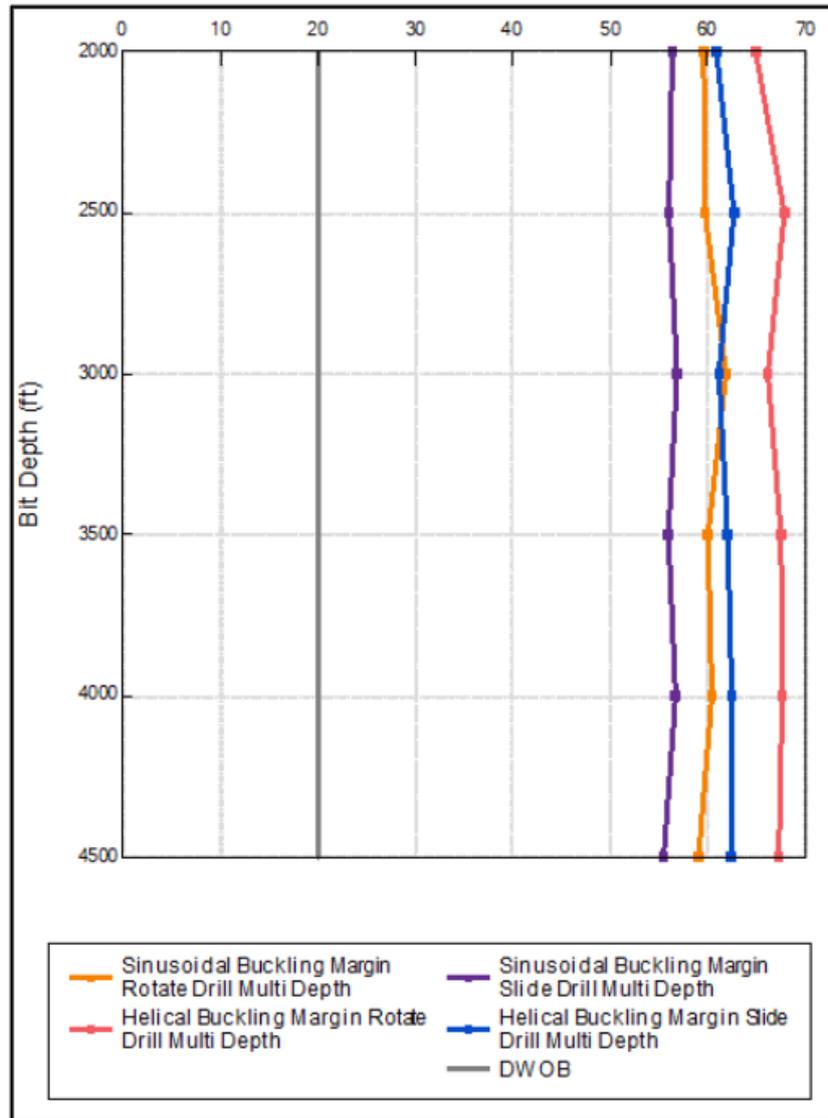
#### 3.4.1 *Weight on Bit* (WOB)

Uji kelayakan WOB dilakukan dengan meninjau hasil simulasi *buckling margin* pada setiap *casing setting depth*. Dalam melakukan operasi pemboran, *buckling margin* menjadi poin utama untuk menjadi acuan dalam menentukan WOB yang sesuai di setiap kedalaman Sumur. *Buckling* dapat terjadi ketika beban tekan pada suatu tabung melebihi nilai kritisnya sehingga tabung tersebut tidak lagi stabil dan berubah bentuk menjadi bentuk sinusoidal atau heliks (tekuk terbatas). Dalam hal ini, mengetahui *buckling margin* berarti mengetahui rentang WOB yang dapat diterapkan pada keadaan aktual pemboran di Sumur X. Hasil simulasinya dapat dilihat pada **Gambar 3.3**, **Gambar 3.4**, **Gambar 3.5**, dan **Gambar 3.6** sebagai berikut.



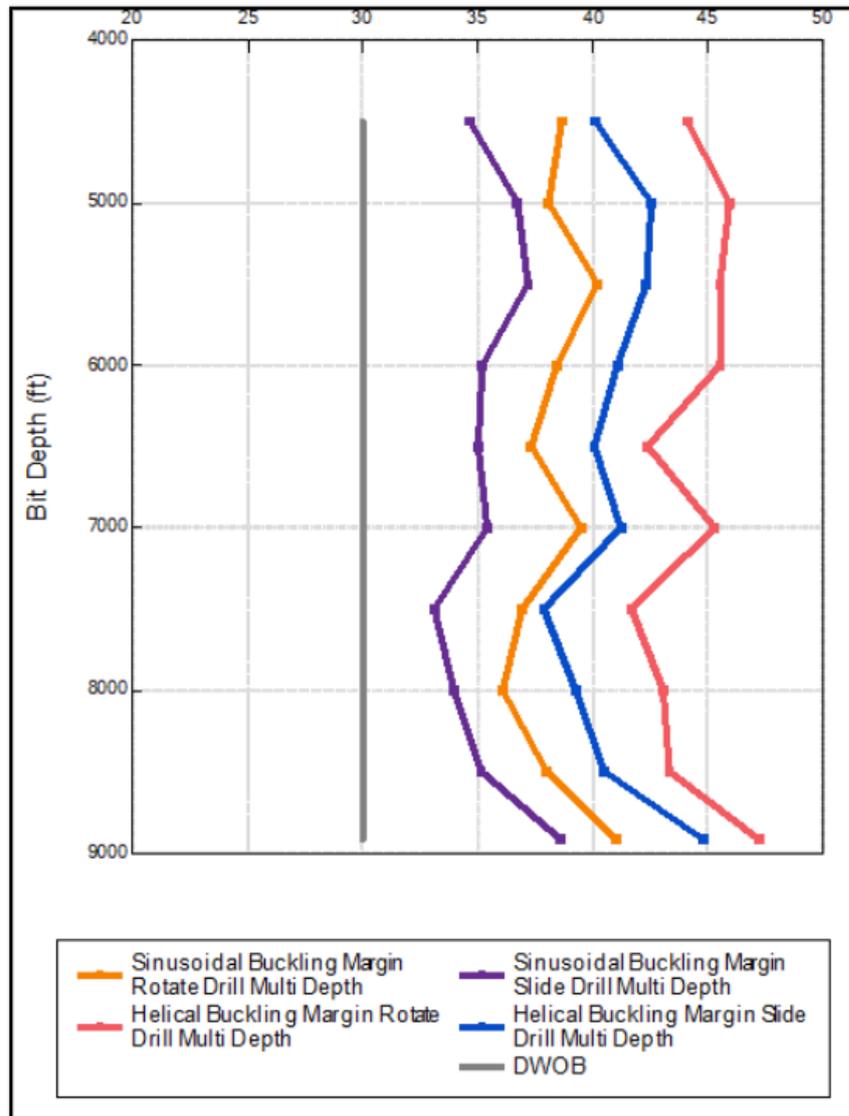
**Gambar 3. 3** Hasil Simulasi *Buckling* untuk Bagian 26''

**Gambar 3.3** menunjukkan hasil simulasi yang dilakukan pada kedalaman 100-2000 ftMD di Sumur X. Garis abu-abu menunjukkan WOB percobaan yang diberikan untuk mendapatkan hasil simulasi, yaitu sebesar 20 klbs. Hasil simulasi menunjukkan garis berwarna oranye, ungu, biru, dan merah yang merupakan margin untuk *sinusoidal* dan *helical buckling*. Dalam menentukan batas paling aman, maka diambil margin paling kiri sebagai batas maksimal WOB yang dapat diterapkan pada kedalaman tersebut. Batas maksimal yang dapat dibaca dari hasil simulasi tersebut adalah 28 klbs.



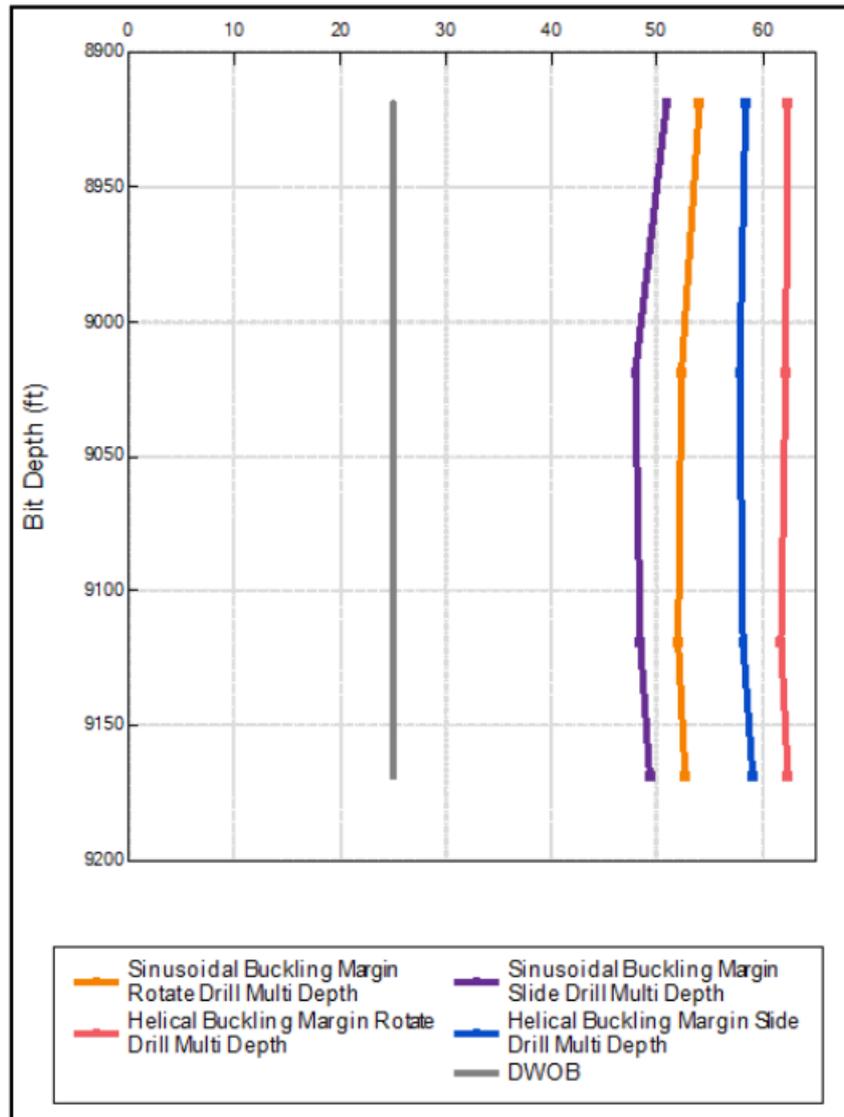
**Gambar 3. 4** Hasil Simulasi Buckling untuk Bagian 17.5”

Gambar 3.4 menunjukkan hasil simulasi yang dilakukan pada kedalaman 2000-4500 ftMD di Sumur X. Pembacaan yang dilakukan sama seperti yang dilakukan pada pembacaan hasil simulasi **Gambar 3.3**. WOB yang diterapkan untuk percobaan adalah 20 klbs. WOB maksimal yang dapat diterapkan pada kedalaman ini adalah 50 klbs.



**Gambar 3. 5** Hasil Simulasi Buckling untuk Bagian 12.25”

**Gambar 3.5** menunjukkan hasil simulasi yang dilakukan pada kedalaman 4500-9000 ftMD di Sumur X. WOB yang diterapkan untuk percobaan adalah 30 klbs. WOB maksimal yang dapat diterapkan pada kedalaman ini adalah 35 klbs.



**Gambar 3. 6** Hasil Simulasi Buckling untuk Bagian 8.5”

Gambar 3.6 menunjukkan hasil simulasi yang dilakukan pada kedalaman 8950-9170 ftMD di Sumur X. WOB yang diterapkan untuk percobaan adalah 25 klbs. WOB maksimal yang dapat diterapkan pada kedalaman ini adalah 48 klbs.

Untuk batas minimal WOB yang dapat diterapkan pada setiap kedalaman, penyesuaian dilakukan dengan praktik yang biasa dilakukan di lapangan, yaitu 5 klbs. Dari hasil simulasi *buckling margin* yang telah dianalisis, diperoleh *lower* dan *upper bound* untuk WOB pada setiap kedalaman yang telah tervalidasi dapat diterapkan pada keadaan aktual operasi pemboran Sumur X. Hasil *lower* dan *upper bound* tersebut dibandingkan dengan *lower* dan *upper bound* dari data historis yang digunakan untuk simulasi pada **langkah 3.8**. Hasil perbandingan tersebut dapat dilihat pada **Tabel 3.2** berikut.

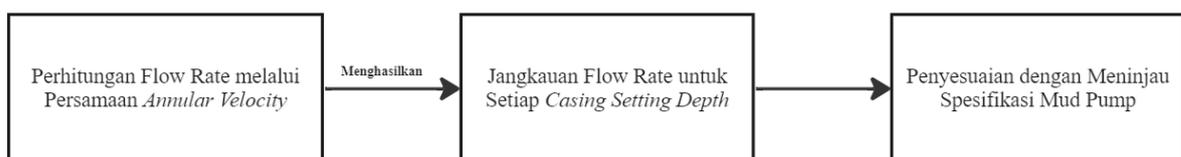
**Tabel 3. 2** Perbandingan *Lower-Upper Bound* WOB Data Historis dan Simulasi *Buckling*

Bagian	WOB (klbs) Data Historis		WOB (klbs) Simulasi <i>Buckling</i>	
	<i>Lower</i>	<i>Upper</i>	<i>Lower</i>	<i>Upper</i>
26"	1	40	5	28
17.5"	0.1	35	5	50
12.25"	1.3	39	5	35
8.5"	5	46	5	48

Dari **Tabel 3.2** dapat dilihat bahwa nilai *lower-upper bound* yang diperoleh dari data historis membutuhkan penyesuaian terutama untuk diameter *casing* 26", 17.5", dan 12.25". Dapat disimpulkan dari uji kelayakan yang dilakukan, untuk ketiga *casing setting depth* tersebut perlu dilakukan simulasi ulang dengan mengatur *lower-upper bound* dengan nilai yang tervalidasi.

### 3.4.2 *Flow rate*

Uji kelayakan *Flow rate* dilakukan dengan melakukan perhitungan *Flow rate* menggunakan persamaan *Annular Velocity* untuk setiap bagian. Dari hasil perhitungan tersebut, diperoleh jangkauan atau batas minimum dan batas maksimal *Flow rate* yang tervalidasi untuk diterapkan di Sumur X. Selain itu, dilakukan juga penyesuaian lanjutan dengan meninjau spesifikasi *Mud Pump*. Hal tersebut dilakukan untuk menyesuaikan kapasitas dan kapabilitas *Mud Pump* yang digunakan untuk operasi pemboran di Sumur X. Diagram blok berikut merupakan rangkuman dari langkah uji kelayakan yang dilakukan untuk *Flow rate*.

**Gambar 3. 7** Langkah Uji Kelayakan yang Dilakukan untuk *Flow rate*.

Perhitungan *flowrate* melalui persamaan *annular velocity* dapat menggunakan **Persamaan (2.1)** dan **(2.2)** serta **Tabel (2.2)**. Selain itu, terdapat pula spesifikasi *Mud Pump*

yang digunakan, yaitu *Mud Pump* HHF-1600 HL. Spesifikasinya dapat dilihat pada **Tabel 3.4** berikut.

**Tabel 3. 3** Spesifikasi *Mud Pump* HHF-1600HL

MUD PUMP HHF-1600HL												
Liner Size, in	7		6.75		6.5		6		5.5		5	
Max. Pressure, psi	3430		3690		3978		4668		5000		6714	
Max. Pop-off Valve, psi	3087		3321		3580.2		4201.2		4500		6042.6	
Gal/Stroke	6		5.58		5.17		4.41		3.7		3.06	
90% Eff. Vol/Stroke	5.4		5.022		4.653		3.969		3.33		2.754	
Amount of MP working	2	3	2	3	2	3	2	3	2	3	2	3
Stroke, spm	100	100	100	100	100	100	120	100	100	100	100	100
Max. Flow Rate, gpm	1080	1620	1004	1507	930.6	1396	952.6	1191	666	999	551	826

**Liner size** mengidentifikasi ukuran liner yang dapat digunakan. **Max. Pressure** mengidentifikasi tekanan maksimal yang dapat ditangani oleh *Mud Pump*. **Max. Pop-off valve** merupakan indikasi pressure maksimal dari *Mud Pump* yang dapat ditangani oleh *Pop-off valve*. *Valve* ini berfungsi sebagai katup yang akan membuka secara otomatis pada saat tekanan melebihi batas maksimal yang telah ditentukan. Tujuan dari *valve* ini adalah untuk mencegah terjadinya tekanan yang berlebihan dalam sistem, yang dapat menyebabkan kerusakan pada peralatan atau bahkan bahaya bagi keselamatan. **Gal/stroke** mengacu kepada seberapa banyak jumlah galon (GAL) dari cairan yang dapat dipompa oleh *Mud Pump* dalam setiap *stroke* (gerakan maju-mundur) pompa. **Eff. Vol/stroke** menunjukkan efisiensi volumetrik, yang merupakan persentase volume aktual yang dipindahkan oleh pompa dalam setiap *stroke* terhadap volume teoritis yang dapat dipindahkan. Angka **90%** mengidentifikasi efisiensi volumetrik dalam persentase 90%. **Amount of MP working** mengacu kepada jumlah *Mud Pump* yang digunakan. **Stroke, spm** memiliki arti *Stroke per Minute*, yaitu seberapa cepat piston atau *plunger* bergerak maju-mundur dalam satu menit. **Max. Flow rate** mengacu kepada nilai maksimal *flow rate* yang dapat dipompa oleh *Mud Pump*.

Dalam melakukan perhitungan *Flow rate*, diperlukan variasi nilai *Annular Velocity* untuk mendapat rentang nilai *Flow rate* yang dapat diterapkan pada setiap *casing setting depth*. Langkah-langkahnya dilakukan sebagai berikut.

1. Dimulai dengan menggunakan nilai AV terendah sampai tertinggi (berdasarkan aturan praktis), yaitu 100 ft/min, 150 ft/min, kemudian 200 ft/min.
2. Dilakukan analisis untuk hasil perhitungan *flow rate* dari setiap AV yang digunakan.

3. Dilakukan penyesuaian hasil perhitungan *flow rate* dengan spesifikasi *Mud Pump*, yaitu nilai *Max. Flow rate*.
4. Apabila nilai *flow rate* untuk setiap AV melebihi nilai *Max. Flow rate* untuk setiap ukuran liner pada spesifikasi *Mud Pump*, maka nilai *flow rate* pada kedalaman tersebut dapat dilakukan penyesuaian dengan kondisi aktual di lapangan.
5. Apabila nilai *flow rate* untuk setiap AV kurang dari atau masih dalam rentang kapasitas yang diperbolehkan, maka nilai AV dapat ditingkatkan lebih dari 200 ft/min.

Untuk penjabaran perhitungan *flow rate* pada setiap bagian dapat dilihat sebagai berikut.

**Tabel 3. 4** Perhitungan *Flow rate* untuk Bagian 26”

<b>Bagian 26”</b>		
<b>AV (ft/min)</b>	<b>Perhitungan</b>	<b>Flow rate (gpm)</b>
100	$Q = \frac{100(26^2 - 5^2)}{24.5}$	2657
150	$Q = \frac{150(26^2 - 5^2)}{24.5}$	3985
200	$Q = \frac{200(26^2 - 5^2)}{24.5}$	5314

Pada bagian 26”, hasil perhitungan *flow rate* untuk setiap nilai AV melampaui batas *Max. Flow rate* dari spesifikasi *Mud Pump* HHF-16000HL. Oleh karena itu, penyesuaian dengan kondisi aktual di lapangan diperlukan. Nilai *flow rate* yang tervalidasi dapat diterapkan pada bagian 26” adalah **1000-1300 gpm**.

**Tabel 3. 5** Perhitungan *Flow rate* untuk Bagian 17.5”

<b>Bagian 17.5”</b>		
<b>AV (ft/min)</b>	<b>Perhitungan</b>	<b>Flow rate (gpm)</b>
100	$Q = \frac{100(17.5^2 - 5^2)}{24.5}$	1148
150	$Q = \frac{150(17.5^2 - 5^2)}{24.5}$	1722

**Tabel 3. 5** Perhitungan *Flow rate* untuk Bagian 17.5”

Bagian 17.5”		
200	$Q = \frac{200(17.5^2 - 5^2)}{24.5}$	2238

Pada bagian 17.5”, hasil perhitungan *Flow rate* untuk nilai AV 150 ft/min dan 200 ft/min melampaui batas Max. *Flow rate* dari spesifikasi *Mud Pump* HHF-16000HL. Akan tetapi, untuk AV 100 ft/min masih dapat diaplikasikan. Untuk memperoleh rentang *Flow rate*, penyesuaian dengan kondisi aktual di lapangan diperlukan. Nilai *Flow rate* yang tervalidasi dapat diterapkan pada rentang ini adalah **1000-1200 gpm**.

**Tabel 3. 6** Perhitungan *Flow rate* untuk Bagian 12.25”

Bagian 12.25”		
AV (ft/min)	Perhitungan	<i>Flow rate</i> (gpm)
100	$Q = \frac{100(12.25^2 - 5^2)}{24.5}$	510.5
150	$Q = \frac{150(12.25^2 - 5^2)}{24.5}$	765.7
200	$Q = \frac{200(12.25^2 - 5^2)}{24.5}$	1000

Pada bagian 12.25”, hasil perhitungan *flow rate* untuk semua nilai AV kurang dari atau masih dalam batas Max. *Flow rate* dari spesifikasi *Mud Pump* HHF-16000HL. Nilai *flow rate* yang tervalidasi dapat diterapkan pada rentang ini adalah **750-1000 gpm**.

**Tabel 3. 7** Perhitungan *Flow rate* untuk Bagian 8.5"

Bagian 8.5"		
AV (ft/min)	Perhitungan	Flow rate (gpm)
100	$Q = \frac{100(8.5^2 - 5^2)}{24.5}$	193
150	$Q = \frac{150(8.5^2 - 5^2)}{24.5}$	289.3
200	$Q = \frac{200(8.5^2 - 5^2)}{24.5}$	385.6
300	$Q = \frac{300(8.5^2 - 5^2)}{24.5}$	578.6
350	$Q = \frac{350(8.5^2 - 5^2)}{24.5}$	650

Pada bagian 8.5", hasil perhitungan *flow rate* untuk semua nilai AV kurang dari atau masih dalam batas *Max. Flow rate* dari spesifikasi *Mud Pump* HHF-16000HL. Pada nilai AV = 200 ft/min, nilai *flow rate* masih jauh dari batas maksimal yang diperbolehkan sehingga diterapkan nilai AV lebih dari 200 ft/min atau sampai dengan 350 ft/min. Nilai *flow rate* yang tervalidasi dapat diterapkan pada rentang ini adalah **400-650 gpm**.

**Tabel 3. 8** Perbandingan Nilai *FlowRate* Data Historis dan *FlowRate* Hasil Uji Kelayakan

Bagian	Flow rate (gpm) Data Historis		Flow rate (gpm) Hasil Uji kelayakan	
	Lower	Upper	Lower	Upper
26"	700	1200	1000	1300
17.5"	500	1200	1000	1200
12.25"	450	4300	750	1000
8.5"	400	630	400	650

Dari hasil perbandingan pada **Tabel 3.8** dapat disimpulkan bahwa untuk *flow rate* pada setiap bagian diperlukan penyesuaian baru sesuai dengan hasil uji kelayakan.

### 3.4.3 *Rotation per Minute (RPM)*

Uji kelayakan yang dilakukan untuk parameter RPM dilakukan dengan menyesuaikan aturan praktis (*rule of thumb*) yang berlaku seperti yang tertera pada **Tabel 2.1** Setelah itu, dilakukan perbandingan antara RPM data historis dan RPM secara aturan praktis.

**Tabel 3. 9** Perbandingan Nilai RPM Data Historis dan RPM secara Aturan Praktis

Bagian	RPM (rpm) Data Historis		RPM (rpm) Aturan Praktis	
	<i>Lower</i>	<i>Upper</i>	<i>Lower</i>	<i>Upper</i>
26"	10	80	180	190
17.5"	10	81	180	190
12.25"	50	150	120	190
8.5"	41	130	120	190

\*Nilai *upper bound* ditentukan berdasarkan keadaan operasi aktual di Sumur X

Dari hasil perbandingan pada **Tabel 3.11** dapat disimpulkan bahwa untuk RPM pada setiap bagian diperlukan penyesuaian baru sesuai dengan aturan praktis yang berlaku.

### 3.5 Simulasi *Predictive modelling* dan PSO dengan Penyesuaian Hasil Uji Kelayakan

Tahap ini merupakan tahap yang dilakukan pada parameter yang tervalidasi tidak dapat diterapkan pada kondisi aktual operasi pemboran di Sumur X setelah dilakukan uji kelayakan. Dari hasil uji kelayakan yang telah dilakukan, terdapat penyesuaian yang harus dilakukan pada parameter WOB, RPM, dan *flow rate*. Langkah-langkah yang dilakukan pada tahap ini merupakan langkah yang sama yang dilakukan pada **tahap 3.8**. Akan tetapi, terdapat penyesuaian *lower-upper bound* sebagai berikut.

**Tabel 3. 10** *Lower-upper bound* Hasil Validasi Uji Kelayakan

Bagian	WOB (klbs)		RPM (rpm)		Flow rate (gpm)	
	<i>Lower</i>	<i>Upper</i>	<i>Lower</i>	<i>Upper</i>	<i>Lower</i>	<i>Upper</i>
26"	5	28	180	190	1000	1300
17.5"	5	50	180	190	1000	1200
12.25"	5	35	120	190	750	1000
8.5"	5	48	120	190	400	650

### 3.6 Perhitungan Waktu Pemboran Hasil Optimisasi

Perhitungan waktu pemboran dilakukan dengan meninjau data historis dari perencanaan dan hasil aktual operasi pemboran pada Sumur X Lapangan Mudi. Dalam meninjau keseluruhan waktu pemboran, terdapat empat konsep yang diperhatikan, yaitu waktu putar (*rotating time*), waktu perjalanan (*trip time*), waktu koneksi (*connection time*), dan ROP (ft/hr). Untuk melakukan perbandingan hasil optimisasi dengan hasil aktual, waktu perjalanan dan waktu koneksi menyesuaikan dengan data historis waktu pemboran sesuai dengan keadaan aktual operasi pemboran di Sumur X Lapangan Mudi. Sedangkan, waktu putar dan, ROP (ft/hr) akan disesuaikan dengan hasil optimisasi ROP.

Langkah-langkah yang dilakukan dalam perhitungan waktu pemboran adalah sebagai berikut.

1. Data historis waktu pemboran perencanaan dan aktual Sumur X Lapangan Mudi ditinjau dan dianalisis
2. Data waktu perjalanan dan waktu koneksi disesuaikan dengan keadaan aktual dari operasi pemboran Sumur X Lapangan Mudi
3. Dilakukan perhitungan waktu pemboran dengan menggunakan ROP hasil optimisasi. Perhitungannya dapat dilakukan melalui persamaan berikut.

$$Drilling\ Time\ (days) = \frac{ROP\ \left(\frac{ft}{hr}\right)}{depth\ (ft)} \times \frac{1}{24\ hour}$$

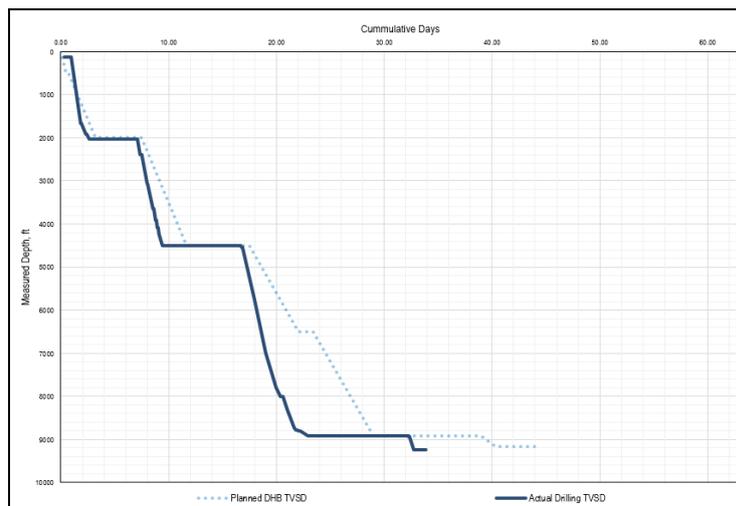
4. Diperoleh total hari yang dihabiskan untuk melakukan pemboran dengan menggunakan ROP hasil optimisasi

5. Dilakukan perbandingan waktu pemboran antara perencanaan, aktual, dan hasil optimisasi

Ringkasan dan deskripsi dari waktu pemboran perencanaan dan aktual dari Sumur X Lapangan Mudi dapat dilihat pada **Tabel 3.13** berikut. Waktu pemboran perencanaan menghabiskan sebanyak 60 hari, sedangkan waktu pemboran aktual menghabiskan sebanyak 34 hari, atau keadaan aktual lebih cepat 26 hari dari waktu pemboran yang direncanakan.

**Tabel 3. 11** Ringkasan Waktu Pemboran Perencanaan dan Aktual Sumur X Lapangan Mudi

NO	SECTION	PLAN				ACTUAL			
		HOURS	DAYS	CUM. DAYS	DEPTH	HOURS	DAYS	CUM. DAYS	DEPTH
1	PRE-SPUD	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
2	26 in HOLE SECTION	161.5	6.7	6.7	2000.0	147.0	6.1	6.1	2023.0
3	17-1/2 in HOLE SECTION	238.6	9.9	16.7	4500.0	216.0	9.0	15.1	4500.0
4	12-1/4 in HOLE SECTION	438.9	18.3	35.0	8919.0	316.0	13.2	28.3	8928.0
5	8-1/2 in HOLE SECTION	230.3	9.6	44.6	9169.0	134.0	5.6	33.9	9239.0



**Gambar 3. 8** Grafik Perbandingan Waktu Pemboran Perencanaan dan Aktual Sumur X Lapangan Mudi

### 3.7 Perhitungan Biaya Pemboran Hasil Optimisasi

Perhitungan biaya pemboran dilakukan dengan meninjau data historis dari perencanaan dan hasil aktual operasi pemboran pada Sumur X Lapangan Mudi. Perhitungan ditinjau dari biaya nyata (*tangible drilling cost*) dan biaya tidak berwujud (*intangibile drilling cost*). Dalam hal ini, *tangible cost* merupakan biaya material dari operasi pemboran, sedangkan *intangibile cost* merupakan biaya-biaya yang timbul dalam persiapan dan pemboran Sumur yang tidak

dapat diselamatkan. Dalam proses pemboran Sumur X Lapangan Mudi, berikut disajikan Tabel mengenai perincian *tangible drilling cost* dan *intangible drilling cost*.

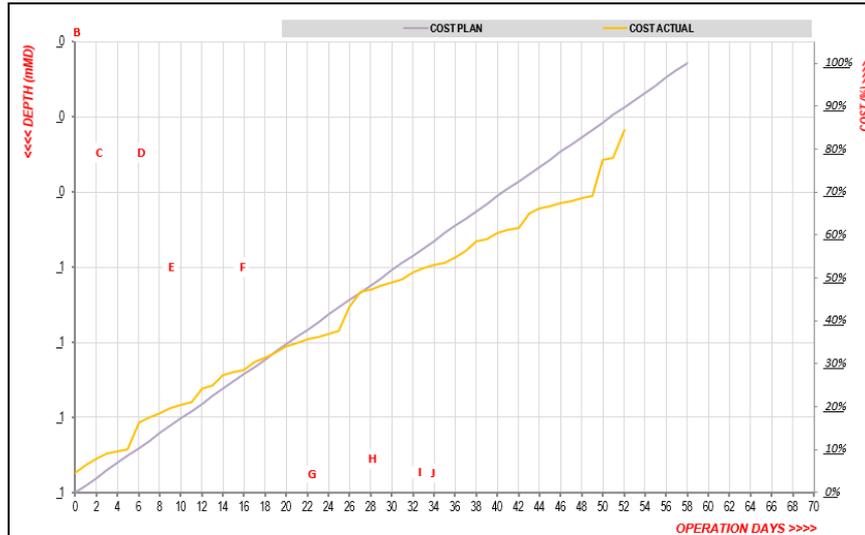
**Tabel 3. 12** *Tangible Drilling Cost (TDC) and Intangible Drilling Cost (IDC)*

<i>Tangible Cost</i>	<i>Intangible Drilling Cost</i>
<i>Casing</i>	<i>Preparation and Termination</i>
<i>Casing Accessories</i>	<i>Drilling/ Workover Operations</i>
<i>Tubing</i>	
<i>Sumur Equipment Surface</i>	
<i>Sumur Equipment Subsurface</i>	

Untuk perencanaan pemboran Sumur X, memiliki *tangible cost* dan *intangible cost* sebesar **Rp2,069,355.00** dan **Rp9.953,411.00** dengan total biaya sebesar **Rp12,022,766.00**. Untuk keadaan aktual pemboran Sumur X, memiliki *tangible cost* dan *intangible cost* sebesar **Rp1,387,795.00** dan **Rp10,018,862.00** dengan total biaya sebesar **Rp11,406,657.00**. Dari total biaya perencanaan dan keadaan aktual pemboran didapat **selisih** sebesar **Rp616,109.00** atau keadaan aktual **5.12% lebih murah** dibandingkan biaya perencanaan. Untuk melakukan perhitungan biaya pemboran menggunakan hasil ROP yang telah dioptimisasi, mengacu kepada *tangible cost* dan *intangible cost* dari biaya aktual pemboran. *Intangible cost* sebagai biaya yang berpengaruh terhadap waktu pemboran akan mengalami penyesuaian yang disesuaikan dengan waktu pemboran menggunakan hasil ROP optimisasi. Biaya pemboran memiliki hubungan yang erat dengan waktu pemboran. Semakin cepat waktu pemboran, maka semakin kecil biaya yang dikeluarkan. Sebaliknya, semakin lama waktu pemboran, maka semakin besar biaya yang dikeluarkan. Perbandingan antara biaya pemboran perencanaan dan aktual dapat dilihat pada **Gambar 3.10**. Hubungan dari waktu pemboran dan biaya pemboran dapat dituliskan sebagai berikut.

$$\text{Total Biaya Pemboran (Rp)} = \text{Total Waktu Pemboran (hari)} \times \text{Biaya Pemboran/ Hari (Rp)}$$

Setelah mendapat biaya pemboran dan *intangible cost* baru berdasarkan perhitungan dari ROP hasil optimisasi, total biaya pemboran hasil otpimisasi merupakan penjumlahan dari *tangible cost* (aktual) dengan *intangible cost* (hasil otpimisasi).



**Gambar 3. 9** Grafik Perbandingan Perencanaan dan Aktual Biaya Pemboran Sumur X Lapangan Mudi

### 3.11 Analisis dan Evaluasi Hasil

Setelah memperoleh hasil optimisasi untuk parameter ROP, RPM, WOB, dan *FlowRate*, waktu pemboran, dan biaya pemboran, dilakukan analisis dan evaluasi hasil. Analisis dan evaluasi dilakukan dengan membandingkan antara perencanaan, keadaan aktual, dan hasil optimisasi operasi pemboran di Sumur X Lapangan Mudi. Dari hasil tersebut dapat dilihat seberapa efektif metode penelitian tugas akhir ini untuk diterapkan di lapangan dan seberapa signifikan hasil yang dapat diperoleh dari menerapkan metode pada penelitian tugas akhir ini.

### 3.12 Penarikan Kesimpulan

Dari hasil analisis dan evaluasi yang dilakukan, penulis menarik kesimpulan yang dihasilkan dari penelitian ini serta saran yang dapat diberikan untuk penelitian selanjutnya atau evaluasi terhadap penelitian yang telah dilakukan

## BAB IV

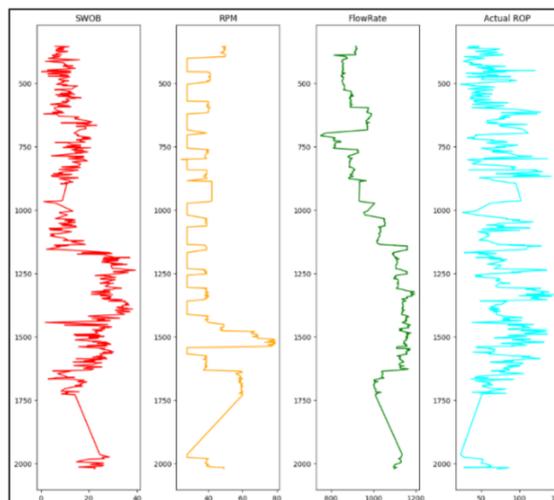
### HASIL DAN PEMBAHASAN

#### 4.1 Hasil Simulasi Model ROP

Simulasi *Predictive modelling* dilakukan menggunakan empat algoritma, yaitu *Gradient Boosting Regression*, *Random Forest Regression*, *k-Nearest Neighbor Regression*, dan *Support Vector Regression*. Selain itu, terdapat simulasi yang menggunakan model ROP tradisional, yaitu Model Bingham. Simulasi dilakukan untuk keempat bagian, yaitu 26”, 17.5”, 12.25”, dan 8.5”. Pada setiap bagian disajikan data berupa plot data aktual keempat parameter (WOB, RPM, *Flow rate*) berdasarkan kedalamannya, grafik *true values vs predictions*, nilai MSE dan  $R^2$  dari masing-masing model dan bagian, serta plot hasil *actual* dan *predicted* ROP yang memudahkan pembacaan data untuk kemudian dibandingkan dan dianalisis hasilnya. Dari setiap bagian, dipilih satu algoritma yang paling akurat sehingga diperoleh kesimpulan algoritma *predictive modelling* yang paling akurat dengan pembuktian dari setiap simulasi pada setiap bagian. Simulasi dilakukan untuk masing-masing bagian dengan tujuan untuk memperoleh validasi yang lebih akurat terkait pemilihan satu algoritma *predictive modelling* karena setiap bagian memiliki jumlah data dan variasi data yang berbeda-beda.

##### 4.1.1 Bagian 26”

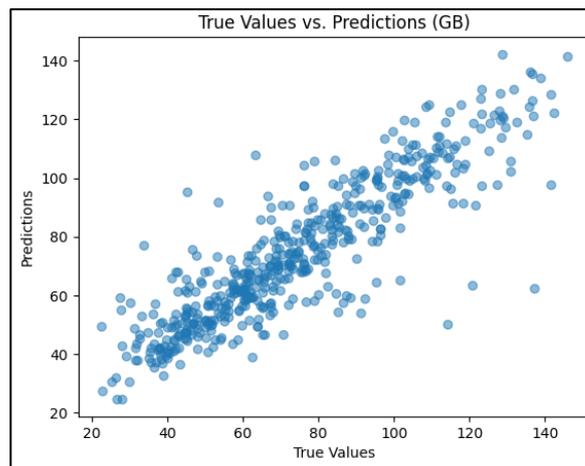
Pada **Gambar 4.1** disajikan plot data keseluruhan keempat parameter pada kedalaman 332-2023 ftMD. Rentang data untuk setiap parameternya, yaitu WOB = 1-40 klbs, RPM = 10-80 rpm, dan *Flow rate* = 700-1200 gpm.



**Gambar 4. 1** Plot Data Aktual Bagian 26”

### a. Gradient Boosting Regression

Hasil simulasi dari *Gradient Boosting Regression* ditampilkan pada grafik *true values vs. predictions* **Gambar 4.2**. Setiap titik pada plot tersebut mewakili satu sampel dari data. Pada grafik tersebut, data pada sumbu X merupakan nilai sebenarnya (*true values*) sedangkan sumbu Y merupakan nilai prediksi (*predictions*). Penyebaran titik yang terjadi pada grafik tersebut menggambarkan seberapa sempurna model dalam melakukan prediksi. Apabila model melakukan prediksi dengan sempurna, semua titik akan berada pada garis  $y = x$  (garis diagonal dari kiri bawah ke kanan atas), yang menggambarkan nilai prediksi sama dengan nilai sebenarnya. Titik-titik di atas garis menunjukkan bahwa model memprediksi nilai yang lebih tinggi dari nilai sebenarnya (*overestimation*), sedangkan titik-titik di bawah garis menunjukkan bahwa model memprediksi nilai yang lebih rendah dari nilai sebenarnya (*underestimation*). Model *Gradient Boosting Regression*, seperti yang tertera pada **Gambar 4.2** merupakan model yang cukup akurat atau baik dalam melakukan prediksi karena persebaran data masih berada di sekitar garis diagonal. Pada **Tabel 4.1** berikut dapat dilihat contoh data sebenarnya dan data prediksi yang dihasilkan pada bagian 26”.



**Gambar 4. 2** Grafik *True values Vs Predictions* Gradient Boosting 26”

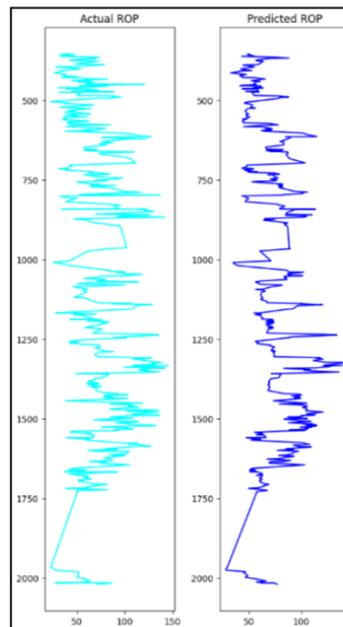
**Tabel 4. 1** Hasil Prediksi Model Gradient Boosting pada Bagian 26”

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi (ft/hr)
394.5	50	55
431	58	59
441.5	65	60
442.5	51	55
460	55	58

**Tabel 4. 1** Hasil Prediksi Model Gradient Boosting pada Bagian 26"

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi (ft/hr)
465	53	59
471	58	58
472.5	45	47
476	54	53
485	50	55

Dari **Tabel 4.1** dapat dilihat perbandingan nilai ROP aktual dan ROP prediksi. Pada kedalaman 394.5 ftMD, ROP prediksi memiliki nilai lebih tinggi daripada ROP aktual atau dianggap sebagai *overestimation* dan titik data pada grafik berada di atas garis diagonal. Pada kedalaman 441.5 ftMD, ROP prediksi memiliki nilai lebih rendah daripada nilai ROP aktual atau dianggap sebagai *underestimation* dan titik data pada grafik berada di bawah garis diagonal. Rata-rata selisih antara ROP hasil prediksi dan ROP aktual adalah sebesar 3.5 ft/hr. Pada kedalaman 471 ftMD, nilai ROP prediksi sama dengan nilai ROP aktual atau dianggap sebagai prediksi sempurna dan titik data pada grafik berada tepat di garis diagonal ( $y=x$ ). **Gambar 4.3** di bawah ini merepresentasikan nilai ROP aktual dan ROP prediksi pada setiap kedalaman pada bagian 26".

**Gambar 4. 3** Plot Perbandingan Nilai *Actual* dan *Predicted* ROP GB 26"

Dari **Gambar 4.3** dapat dilihat bahwa hasil prediksi ROP terhadap ROP aktual cukup dekat untuk setiap kedalaman. Untuk mengetahui seberapa akurat model *Gradient Boosting Regression* dapat dilihat melalui kriteria evaluasi, yaitu RMSE,  $R^2$ , MSE, dan MAPE seperti pada **Tabel 4.2** berikut.

**Tabel 4. 2** Kriteria Evaluasi Gradient Boosting untuk Bagian 26"

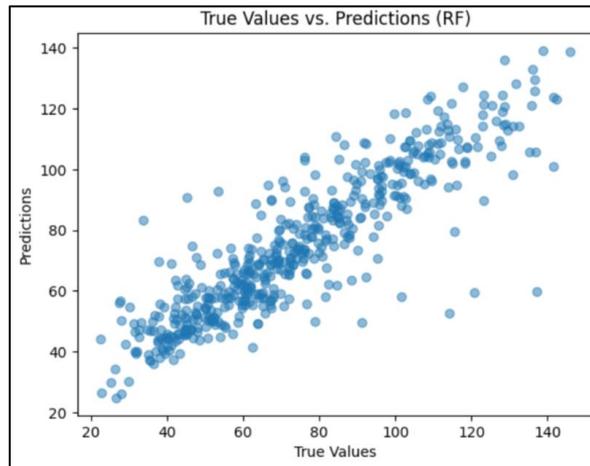
KRITERIA EVALUASI	
$R^2$	0.78
Root Mean Squared Error (RMSE)	12.53
Mean Absolute Error (MAE)	8.60
Mean Absolute Percentage Error (MAPE)	13.17

Pada Gradient Boosting, terdapat pengaturan *hyperparameter* seperti yang telah dijelaskan pada **tahap 3.5** Bab III Metodologi. *Hyperparameter* terbaik dipilih melalui metode *grid search*, yaitu  $learning\_rate = 0.1$ ,  $loss = squared\_error$ ,  $max\_depth = 7$ ,  $min\_samples\_leaf = 1$ ,  $min\_samples\_split = 5$ ,  $n\_estimators = 300$ .  $N\_estimators = 300$  atau jumlah estimator (pohon) dalam *ensemble* model berjumlah 300, memiliki relasi dengan nilai  $R^2$  yang dihasilkan.  $R^2$  sebesar 0.76, memiliki arti bahwa model mampu menjelaskan 78% variabilitas dalam data target, tetapi masih terdapat 22% variabilitas yang tidak dijelaskan oleh model.  $Learning\_rate = 0.1$  atau tingkat pembelajaran yang mengontrol seberapa besar kontribusi setiap pohon terhadap model akhir adalah 0.1, memiliki relasi dengan nilai RMSE, MAE, dan MAPE yang dihasilkan. RMSE sebesar 12.53 dan MAE sebesar 8.60 menunjukkan bahwa model memiliki kesalahan prediksi yang moderat, serta MAPE sebesar 13.17 yang menunjukkan kesalahan prediksi rata-rata dalam presentase, yang menunjukkan bahwa model memprediksi nilai dengan kesalahan 13.17% dari nilai sebenarnya dan kesalahan tersebut tergolong sebagai *good forecasting* mengacu kepada **Tabel 2.3**, tetapi masih dapat ditingkatkan dengan pengaturan *learning rate* yang lebih halus.

#### **b. Random Forest Regression**

Model *Random Forest Regression*, seperti yang tertera pada **Gambar 4.4** merupakan model yang lebih akurat atau lebih baik dalam melakukan prediksi karena persebaran data masih di sekitar garis diagonal. Pada **Gambar 4.4**, hasil persebaran data membentuk garis diagonal lebih jelas. Sama seperti penjelasan grafik pada Gradient Boosting, *Random Forest Regression* memiliki nilai *overestimation* dan *underestimation* yang lebih sedikit dibandingkan algoritma lainnya atau model mampu menghasilkan lebih banyak nilai prediksi

yang sama dengan nilai sebenarnya. Pada **Tabel 4.1** berikut dapat dilihat contoh data sebenarnya dan data prediksi yang dihasilkan pada bagian 26”.



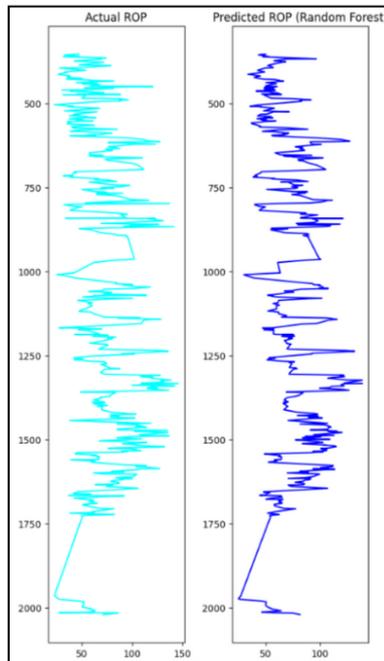
**Gambar 4. 4** Grafik *True values Vs Predictions* Random Forest 26”

**Tabel 4. 3** Hasil Prediksi Random Forest pada Bagian 26"

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi(ft/hr)
354.5	47	50
365.5	74	74
368.5	69	69
423	35	39
431	58	60
460	55	49
465	53	53
472.5	45	46
539.5	55	55
629.5	77	77

Dari **Tabel 4.3** dapat dilihat perbandingan nilai ROP aktual dan ROP prediksi. Pada kedalaman 365.5 ftMD, 398.5 ftMD, 465 ftMD, 539.5 ftMD, dan 629.5 ftMD, terlihat bahwa nilai prediksi sama dengan nilai sebenarnya. Dari 10 sampel data yang diambil, terdapat 5 variasi kedalaman yang memiliki ROP prediksi sama dengan ROP aktual atau memiliki arti model dapat dengan sempurna memprediksi nilai ROP dengan membaca inputan yang diberikan (WOB, RPM, dan *flowrate*). Pada hasil prediksi masih terdapat beberapa nilai yang *overestimation* dan *underestimation*, akan tetapi perbedaan nilai tidak signifikan atau hasil

prediksi tidak jauh berbeda dengan nilai sebenarnya. Rata-rata selisih antara ROP hasil prediksi dan ROP aktual adalah sebesar 3.2 ft/hr. **Gambar 4.5** di bawah ini merepresentasikan nilai ROP aktual dan ROP prediksi pada setiap kedalaman pada bagian 26”.



**Gambar 4.5** Plot Perbandingan Nilai *Actual* dan *Predicted* ROP RF 26”

Dari **Gambar 4.5** dapat dilihat bahwa hasil prediksi ROP terhadap ROP aktual tidak berbeda secara signifikan untuk setiap kedalaman. Untuk mengetahui seberapa akurat model *Random Forest Regression* dapat dilihat melalui kriteria evaluasi, yaitu RMSE,  $R^2$ , MSE, dan MAPE seperti pada **Tabel 4.4** berikut.

**Tabel 4.4** Kriteria Evaluasi Random Forest untuk Bagian 26”

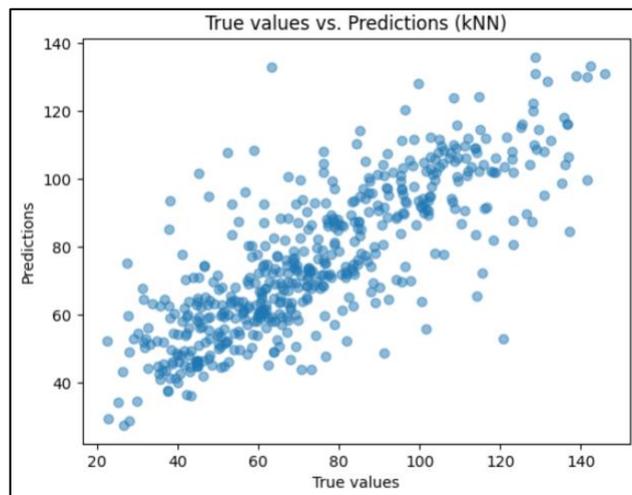
KRITERIA EVALUASI	
$R^2$	0.79
Root Mean Squared Error (RMSE)	12.43
Mean Absolute Error (MAE)	8.43
Mean Absolute Percentage Error (MAPE)	12.99

Pada *Random Forest Regression*, terdapat pengaturan *hyperparameter* seperti yang telah dijelaskan pada **tahap 3.5** Bab III Metodologi. Pengaturan ini berlaku untuk semua bagian, yaitu 26”, 17.5”, 12.25”, dan 8.5”. Untuk  $n\_estimators = 100$  atau menggambarkan jumlah pohon adalah 100, memiliki relasi dengan nilai  $R^2$ , RMSE, MAE, dan MAPE. Nilai  $R^2$

sebesar 0.79 merepresentasikan bahwa model mampu menjelaskan 79% variabilitas dalam data target. Hasil tersebut telah menunjukkan kinerja model yang baik dengan  $n\_estimators$  yang dipilih telah membantu model mengenali dan menangkap pola dalam data dengan baik tanpa *overfitting* (model terlalu kompleks atau *ensemble* menangkap *noise* dan detail yang tidak relevan dalam data). Nilai RMSE sebesar 12.43 dan MAE sebesar 8.43 menunjukkan nilai kesalahan yang moderat atau model cukup baik dalam prediksi. Nilai MAPE 12.99 memiliki arti bahwa model memiliki kesalahan memprediksi sekitar 12.99% dari nilai sebenarnya, angka ini tergolong ke dalam *good forecasting* mengacu kepada **Tabel 2.3**.

### c. *k-Nearest Neighbor Regression*

Model *k-Nearest Neighbor Regression*, seperti yang tertera pada **Gambar 4.6** merupakan model yang cukup akurat atau baik dalam melakukan prediksi karena persebaran data masih di sekitar garis diagonal. Pada **Tabel 4.5** berikut dapat dilihat contoh data sebenarnya dan data prediksi yang dihasilkan pada bagian 26”.



**Gambar 4. 6** Grafik *True values Vs Predictions k-Nearest Neighbor 26”*

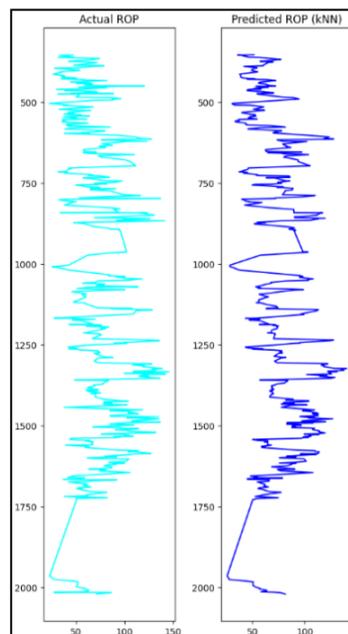
**Tabel 4. 5** Hasil Prediksi kNN pada Bagian 26”

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi (ft/hr)
354.5	47	52
355	40	40
356	33	40
361.5	48	48
365.5	74	67
394.5	50	55

**Tabel 4. 5** Hasil Prediksi kNN pada Bagian 26"

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi (ft/hr)
402	54	49
423	35	35
432	57	67
448.5	59	66

Dari **Tabel 4.5** dapat dilihat perbandingan nilai ROP aktual dan ROP prediksi. Dari sepuluh sampel yang diambil, terdapat tiga variasi kedalaman yang memiliki nilai ROP prediksi sama dengan nilai ROP sebenarnya, yaitu pada kedalaman 355 ftMD, 361.5 ftMD, dan 423 ftMD. Sedangkan, untuk kedalaman lainnya masih tergolong *overestimation* dan *underestimation* dengan rata-rata selisih sebesar 6.57 ft/hr.

**Gambar 4.7** Plot Perbandingan Nilai *Actual* dan *Predicted* ROP KNN 26"

Dari **Gambar 4.7** hasil prediksi ROP terhadap ROP aktual tidak berbeda secara signifikan untuk setiap kedalaman. Untuk mengetahui seberapa akurat model *k-Nearest Neighbor Regression*, dapat dilihat melalui kriteria evaluasi, yaitu RMSE,  $R^2$ , MSE, dan MAPE seperti pada **Tabel 4.6** berikut.

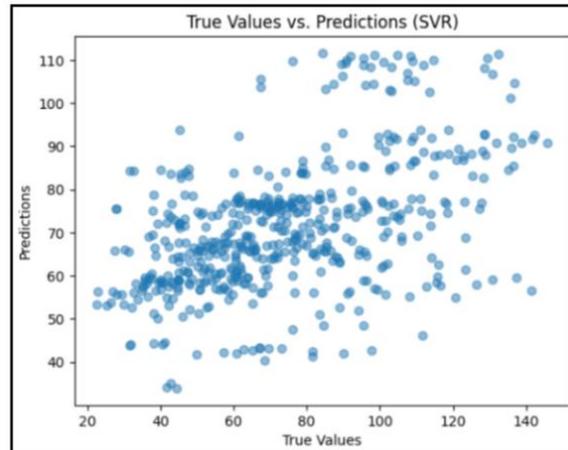
**Tabel 4. 6** Kriteria Evaluasi kNN untuk Bagian 26"

KRITERIA EVALUASI	
R <sup>2</sup>	0.64
Root Mean Squared Error (RMSE)	16.45
Mean Absolute Error (MAE)	11.88
Mean Absolute Percentage Error (MAPE)	18.87

Pada k-Nearest Neighbor, terdapat pengaturan *hyperparameter* seperti yang telah dijelaskan pada **tahap 3.5** Bab III Metodologi. *Hyperparameter* terbaik yang diperoleh melalui metode *grid search* adalah *leaf\_size = 20*, *metric = manhattan*, *n\_neighbors = 11*, *p = 1*, *weights = distance*. Hasil kriteria evaluasi pada **Tabel 4.6** menunjukkan nilai R<sup>2</sup> yang dihasilkan, yaitu 0.63 yang menggambarkan bahwa model mampu menjelaskan 63% variabilitas dalam data target. Hal tersebut memiliki arti bahwa pemilihan 11 tetangga terdekat pada model mampu menangkap sebagian besar pola dalam data, jumlah tetangga ini memberikan keseimbangan yang baik antara bias dan varians. Nilai RMSE sebesar 16.45 dan MAE sebesar 11.88, menunjukkan bahwa nilai MAE lebih rendah daripada RMSE, yang menggambarkan bahwa kesalahan rata-rata cukup kecil, tetapi terdapat beberapa prediksi yang memiliki kesalahan besar (*outliers*) yang mempengaruhi nilai RMSE. Selanjutnya, nilai MAPE sebesar 18.87 menunjukkan kesalahan prediksi rata-rata dari model adalah 18.87% atau masih tergolong sebagai *good forecasting* mengacu kepada **Tabel 2.3**.

#### d. *Support Vector Regression*

Model *Support Vector Regression*, seperti yang tertera pada **Gambar 4.8** merupakan model yang tidak akurat atau buruk dalam melakukan prediksi karena persebaran data sangat acak dan tidak membentuk garis diagonal. Pada **Tabel 4.7** berikut dapat dilihat contoh data sebenarnya dan data prediksi yang dihasilkan pada bagian 26".

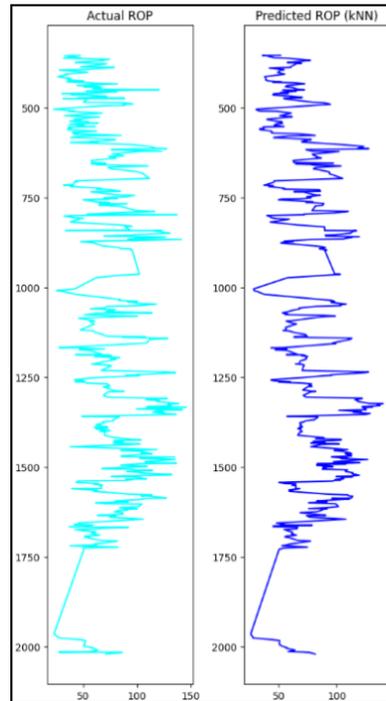


**Gambar 4. 8** Grafik *True values Vs Predictions Support Vector Regression 26"*

**Tabel 4. 7** Hasil Prediksi SVR pada Bagian 26"

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi (ft/hr)
354.5	47	84
355	40	85
356	33	84
361.5	48	85
362	32	84
365.5	74	84
368	66	85
368.5	69	83
373.5	45	83
374.5	43	84

Pada **Tabel 4.7**, perbandingan beberapa nilai ROP aktual dan ROP prediksi dapat dianalisis. Untuk setiap kedalaman, model tidak mampu melakukan prediksi dengan sempurna, hasil prediksi cenderung *overestimation* dan *underestimation*. Perbedaan yang signifikan antara ROP aktual dan ROP prediksi juga menggambarkan bahwa model memiliki keakuratan yang rendah serta error yang besar. Rata-rata selisih perbedaannya adalah sebesar 34.4 ft/hr.



**Gambar 4. 9** Plot Perbandingan Nilai *Actual* dan *Predicted* ROP SVR 26”

Plot perbandingan antara ROP aktual dan ROP prediksi untuk setiap kedalaman pada bagian 26” dapat terlihat pada **Gambar 4.9**. Meskipun bentuk plot terlihat tidak berbeda signifikan, akan tetapi skala hasil berbeda jauh. Pada plot grafik sebelah kiri (ROP aktual), skala hasil kurang dari 150, sedangkan pada plot grafik sebelah kanan (ROP prediksi), skala hasil mencapai nilai lebih dari 200. Selanjutnya, disajikan pula beberapa kriteria evaluasi seperti yang tertera pada **Tabel 4.8** berikut.

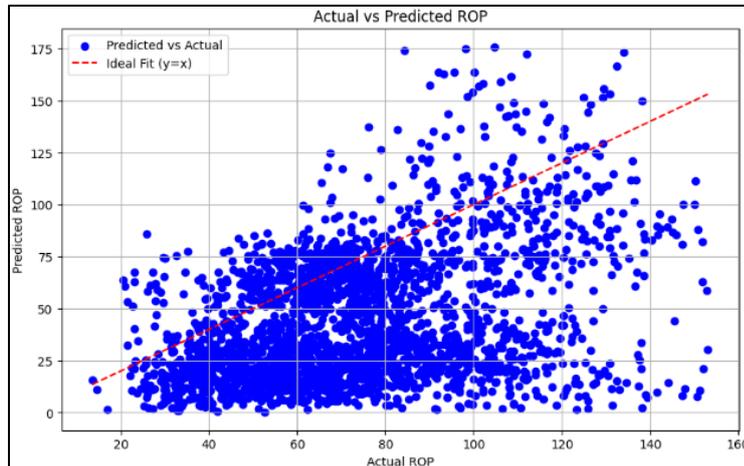
**Tabel 4. 8** Kriteria Evaluasi SVR untuk Bagian 26”

<b>KRITERIA EVALUASI</b>	
R <sup>2</sup>	0.23
Root Mean Squared Error (RMSE)	23.86
Mean Absolute Error (MAE)	18.53
Mean Absolute Percentage Error (MAPE)	35.27

Nilai R<sup>2</sup> sebesar 0.23 menunjukkan bahwa model hanya mampu menjelaskan 23% variabilitas, tetapi tidak mampu menjelaskan 77% variabilitas lainnya. Nilai RMSE sebesar 23.86 dan MAE sebesar 18.53 tergolong ke dalam kesalahan yang moderat. Selanjutnya, nilai MAPE sebesar 35.27 menunjukkan kesalahan prediksi sebesar 35.27%, angka ini tergolong sebagai *reasonable forecasting* mengacu kepada **Tabel 2.3**.

### e. Model Bingham

Model Bingham, seperti yang tertera pada **Gambar 4.10** merupakan model yang tidak akurat atau buruk dalam melakukan prediksi karena persebaran data sangat acak dan tidak membentuk garis diagonal. Selanjutnya, disajikan pula beberapa kriteria evaluasi seperti yang tertera pada **Tabel 4.9** berikut.



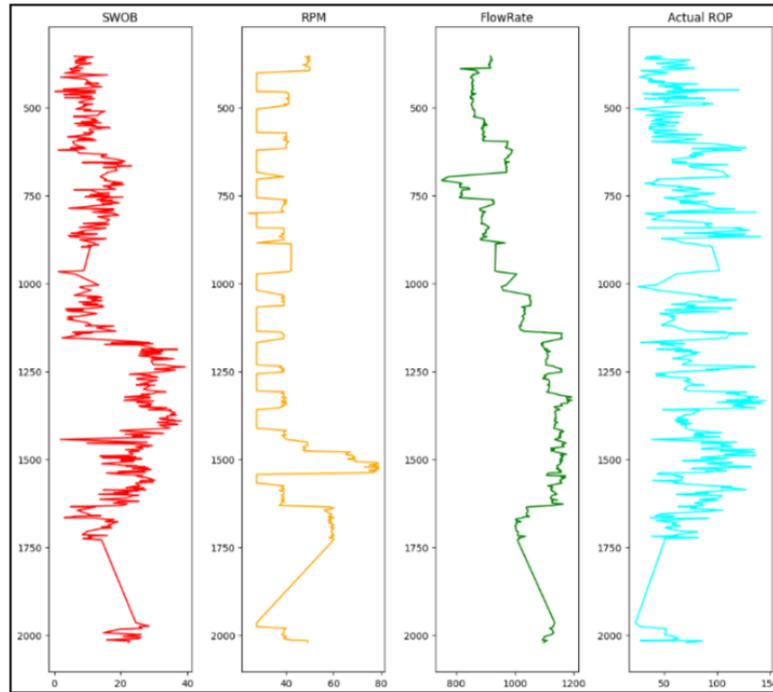
**Gambar 4.10** Grafik *True Values Vs Predictions* Bingham 26"

**Tabel 4.9** Kriteria Evaluasi Bingham untuk Bagian 26"

KRITERIA EVALUASI	
$R^2$	-1.63
Root Mean Squared Error (RMSE)	43.02
Mean Absolute Error (MAE)	34.37
Mean Absolute Percentage Error (MAPE)	46.88

Nilai  $R^2$  sebesar -1.63 menunjukkan bahwa model tidak valid atau tidak akurat dalam melakukan prediksi. Hasil prediksi yang buruk tersebut dapat terjadi karena adanya konstanta  $a$  dan  $k$  (konstanta formasi batuan) yang tidak dilakukan *update* pada setiap kedalamannya. Hal tersebut dapat terjadi karena tidak adanya data formasi batuan yang lengkap yang dapat menunjang keberhasilan model tersebut.

#### 4.1.2 Bagian 17.5"



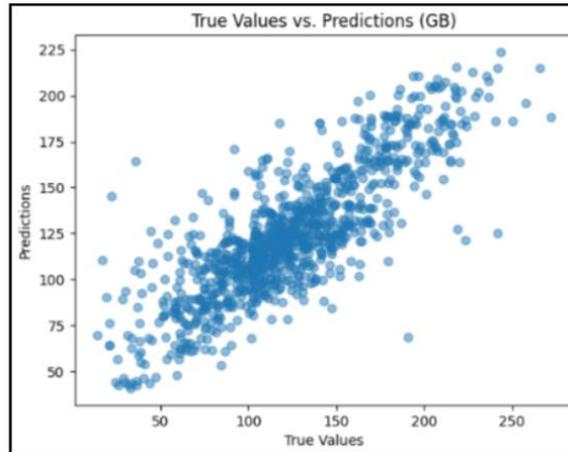
**Gambar 4. 11** Plot Data Aktual Bagian 17.5"

Dari **Gambar 4.12** dapat dilihat data keempat parameter pada kedalaman 1935-4495.5 ftMD. Rentang data untuk setiap parameternya, yaitu sebagai berikut:

- WOB : 0.1-35 klbs
- RPM : 10-81 rpm
- *Flow rate* : 500-1200 gpm

##### a. *Gradient Boosting Regression*

Hasil simulasi *Gradient Boosting Regression* untuk bagian 17.5" dapat dilihat pada **Gambar 4.13**. *Hyperparameter* terbaik dipilih melalui metode *grid search*, yaitu  $learning\_rate = 0.2$ ,  $loss = squared\_error$ ,  $max\_depth = 5$ ,  $min\_samples\_leaf = 4$ ,  $min\_samples\_split = 2$ ,  $n\_estimators = 300$ . Grafik pada Gambar 4.11 menggambarkan bahwa model cukup akurat atau baik dalam melakukan prediksi karena persebaran data masih berada di sekitar dan membentuk garis diagonal. Pada **Tabel 4.10** berikut, dapat dilihat contoh ROP aktual dan ROP prediksi yang dihasilkan pada bagian 17.5".

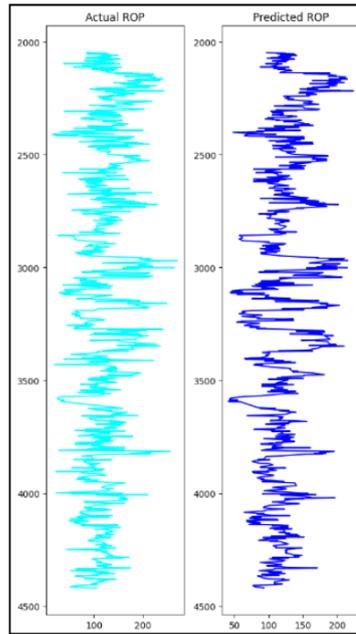


**Gambar 4. 12** Grafik *True values Vs Predictions Gradient Boosting 17.5*”

**Tabel 4. 10** Hasil Prediksi GB pada Bagian 17.5”

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi (ft/hr)
2050	127	124
2052.5	112	112
2055.5	132	138
2057	116	117
2060	149	141
2063	124	128
2063.5	116	115
2068	133	132
2076	121	125
2088	119	115

Pada **Tabel 4.10**, dapat dilihat contoh beberapa kedalaman yang dapat dijadikan bahan analisis untuk perbandingan nilai ROP aktual dan ROP prediksi. Terdapat hasil yang sesuai dengan ROP aktual, yaitu pada kedalaman 2052.5 ft/hr. Hasil prediksi yang tergolong *overestimation* 2055.5 ft/hr, 2057 ft/hr, 2063 ft/hr, dan 2076 ft/hr. Selain itu, untuk hasil yang tergolong *underestimation*, yaitu pada kedalaman 2050 ft/hr, 2060 ft/hr, 2063.5 ft/hr, 2068 ft/hr, dan 2088 ft/hr. Rata-rata selisih nilai antara ROP hasil prediksi dan ROP aktual adalah sebesar 3.56 ft/hr. **Gambar 4.14** di bawah ini merepresentasikan nilai ROP aktual dan ROP prediksi pada setiap kedalaman pada bagian 17.5”.



**Gambar 4. 13** Plot Perbandingan Nilai *Actual* dan *Predicted* ROP GB 17.5”

Hasil plot seperti pada **Gambar 4.14**, menunjukkan bahwa pada setiap kedalaman, model mampu memprediksinya dengan baik. Hasil simulasi kemudian dilengkapi dengan beberapa kriteria evaluasi, yaitu RMSE,  $R^2$ , MSE, dan MAPE seperti pada **Tabel 4.11**.

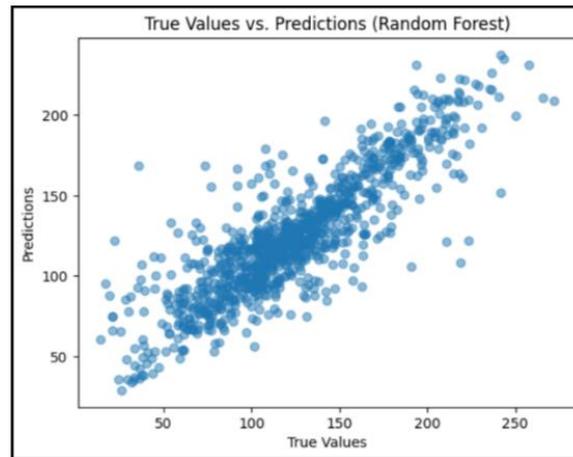
**Tabel 4. 11** Kriteria Evaluasi Gradient Boosting untuk Bagian 17.5”

<b>KRITERIA EVALUASI</b>	
$R^2$	0.72
Root Mean Squared Error (RMSE)	23.73
Mean Absolute Error (MAE)	16.58
Mean Absolute Percentage Error (MAPE)	18.57

Nilai  $R^2$  sebesar 0.72 menggambarkan bahwa model mampu menjelaskan 72% variabilitas dalam data target, tetapi masih terdapat 28% variabilitas yang tidak mampu dijelaskan oleh model. RMSE sebesar 23.73 dan MAE sebesar 16.58 menunjukkan bahwa model memiliki kesalahan prediksi yang moderat, serta MAPE sebesar 18.57 yang menunjukkan kesalahan prediksi rata-rata dalam presentase, yang menunjukkan bahwa model memprediksi nilai dengan kesalahan 18.57% dari nilai sebenarnya dan kesalahan tersebut tergolong sebagai *good forecasting* mengacu kepada **Tabel 2.3**, tetapi masih dapat ditingkatkan dengan pengaturan *learning rate* yang lebih halus.

### b. *Random Forest Regression*

Hasil simulasi *Random Forest Regression* untuk bagian 17.5” dapat dilihat pada **Gambar 4.15**. Dari grafik tersebut, ditunjukkan bahwa penyebaran data berada di sekitar atau membentuk garis diagonal dengan jelas, membuktikan bahwa model cukup akurat dalam memprediksi nilai prediksi. Selain itu, pada **Tabel 4.12** dapat dilihat contoh perbandingan nilai ROP aktual dan ROP prediksi pada beberapa kedalaman.



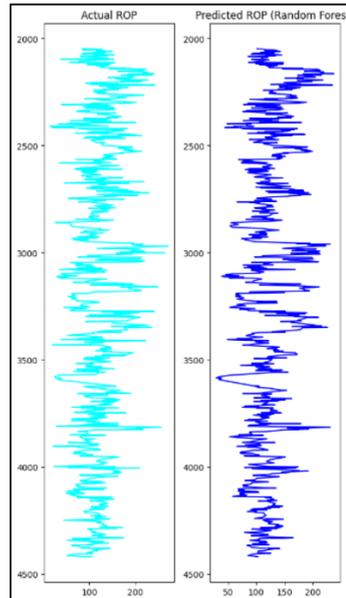
**Gambar 4. 14** Grafik *True values Vs Predictions* Random Forest 17.5”

**Tabel 4. 12** Hasil Prediksi RF pada Bagian 17.5”

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi (ft/hr)
2055.5	132	137
2057	116	115
2064	108	108
2068	133	133
2068.5	103	106
2072.5	93	96
2075	139	137
2076	121	117
2076.5	112	119
2077	126	126

Pada **Tabel 4.12**, terdapat beberapa nilai yang terprediksi dengan sempurna, yaitu pada kedalaman 2064 ftMD, 2068 ftMD, dan 2077 ftMD. Pada kedalaman lain, terdapat variasi nilai yang tergolong *overestimation* dan *underestimation*. Meskipun tidak terprediksi

dengan sempurna, hasil prediksi yang tidak sesuai dengan nilai sebenarnya, tidak menunjukkan perbedaan yang signifikan atau memiliki rata-rata selisih sebesar 3.57 ft/hr. Pada **Gambar 4.16** berikut, dapat dilihat plot perbandingan ROP aktual dan ROP hasil prediksi pada bagian 17.5”.



**Gambar 4. 15** Plot Perbandingan Nilai *Actual* dan *Predicted* ROP RF 17.5”

Pada **Gambar 4.16**, plot menunjukkan keakuratan model yang baik dalam memprediksi ROP pada setiap kedalamannya. Hasil simulasi kemudian dilengkapi dengan beberapa kriteria evaluasi, yaitu RMSE,  $R^2$ , MSE, dan MAPE seperti pada **Tabel 4.13** berikut.

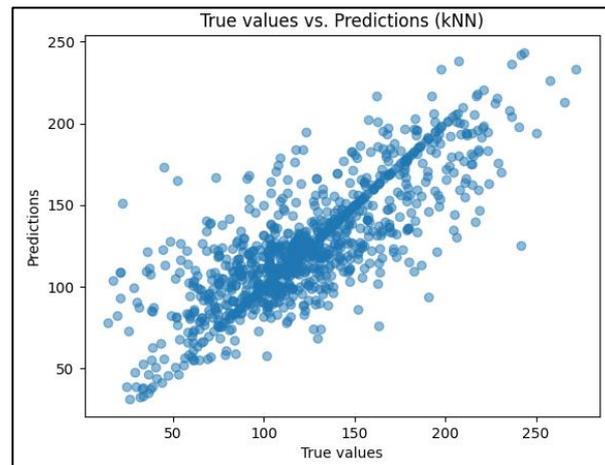
**Tabel 4. 13** Kriteria Evaluasi Random Forest untuk Bagian 17.5”

KRITERIA EVALUASI	
$R^2$	0.74
Root Mean Squared Error (RMSE)	23.09
Mean Absolute Error (MAE)	15.98
Mean Absolute Percentage Error (MAPE)	18.24

Nilai  $R^2$  sebesar 0.74 menggambarkan bahwa model mampu menjelaskan 74% variabilitas, tetapi tidak mampu menjelaskan 26% variabilitas lainnya. Nilai RMSE sebesar 23.09 dan MAE sebesar 15.98 tergolong ke dalam kesalahan yang moderat. Selanjutnya, nilai MAPE sebesar 18.24 menunjukkan kesalahan prediksi sebesar 18.24%, angka ini masih tergolong sebagai *good forecasting* mengacu kepada **Tabel 2.3**.

**c. *k*-Nearest Neighbor Regression**

Hasil simulasi kNN Regression dapat dilihat oada **Gambar 4.17**. Hyperparamter terbaik yang digunakan adalah  $leaf\_size = 20$ ,  $metric = manhattan$ ,  $n\_neighbors = 11$ ,  $p = 1$ ,  $weights = distance$ . Model mampu memprediksi dengan cukup baik dilihat dari persebaran data yang berada di sekitar dan membentuk garis diagonal, meskipun tidak sebaik hasil grafik *Random Forest Regression* (**Gambar 4.15**). Selanjutnya, pada **Tabel 4.14** disajikan contoh perbandingan ROP aktual dan ROP prediksi pada beberapa kedalaman.



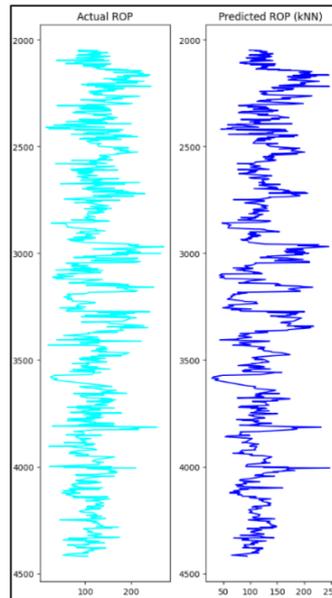
**Gambar 4. 16** Grafik *True values Vs Predictions k-Nearest Neighbor 17.5*”

**Tabel 4. 14** Hasil Prediksi kNN pada Bagian 17.5”

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi (ft/hr)
2048	85	98
2050	127	121
2052.5	112	110
2055.5	132	132
2057	116	122
2059	117	119
2070.5	96	112
2071.5	108	112
2072.5	93	98
2078.5	122	125

Dari beberapa contoh hasil simulasi yang diambil seperti pada **Tabel 4.14**, hanya terdapat satu hasil prediksi yang sesuai dengan nilai sebenarnya, yaitu pada kedalaman 2055.5

ftMD. Pada kedalaman lain, hasil prediksi tergolong *overestimation* dan *underestimation*, tetapi selisih perbedaannya tidak signifikan. Berikut disajikan plot perbandingan ROP aktual dan ROP prediksi pada setiap kedalaman pada **Gambar 4.18**.



**Gambar 4. 17** Plot Perbandingan Nilai *Actual* dan *Predicted* ROP KNN 17.5”

Plot pada **Gambar 4.18** menunjukkan hasil yang cukup baik pada setiap kedalamannya. Hasil simulasi kemudian dilengkapi dengan beberapa kriteria evaluasi, yaitu RMSE,  $R^2$ , MSE, dan MAPE seperti pada **Tabel 4.15**.

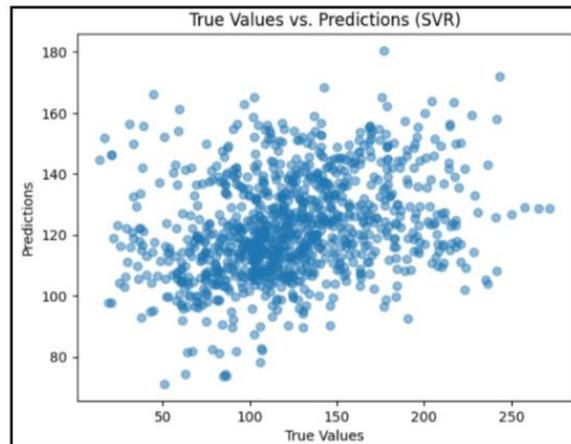
**Tabel 4. 15** Kriteria Evaluasi kNN untuk Bagian 17.5”

<b>KRITERIA EVALUASI</b>	
$R^2$	0.63
Root Mean Squared Error (RMSE)	27.33
Mean Absolute Error (MAE)	18.70
Mean Absolute Percentage Error (MAPE)	21.52

Nilai  $R^2$  sebesar 0.63 menunjukkan bahwa model mampu menjelaskan 63% variabilitas, tetapi tidak mampu menjelaskan 37% variabilitas lainnya. Nilai RMSE sebesar 27.33 dan MAE sebesar 18.70 tergolong ke dalam kesalahan yang moderat. Selanjutnya, nilai MAPE sebesar 21.52 menunjukkan kesalahan prediksi sebesar 21.52%, angka ini masih tergolong sebagai *good forecasting* mengacu kepada **Tabel 2.3**.

#### d. Support Vector Regression

Hasil simulasi SVR pada bagian 17.5 dapat dilihat pada **Gambar 4.19** berikut. Model SVR merupakan model yang tidak akurat atau buruk dalam melakukan prediksi karena persebaran data sangat acak dan tidak membentuk garis diagonal. Pada **Tabel 4.16** berikut dapat dilihat contoh ROP sebenarnya dan ROP prediksi yang dihasilkan pada bagian 17.5”.



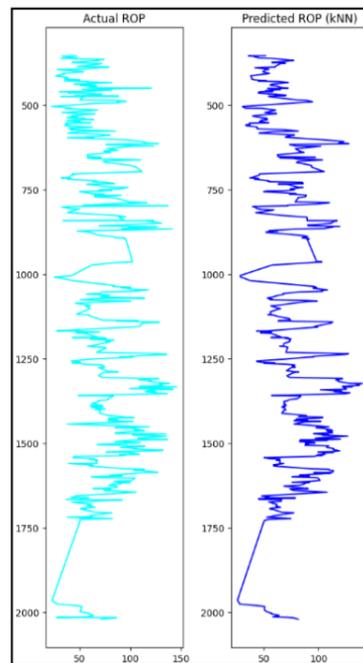
**Gambar 4. 18** Grafik *True values Vs Predictions Support Vector Regression 17.5”*

**Tabel 4. 16** Hasil Prediksi SVR pada Bagian 17.5”

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi (ft/hr)
2048	85	138
2050	127	135
2052.5	112	144
2053.5	85	146
2055.5	132	143
2057	116	133
2059	117	151
2060	149	140
2063	124	143
2063.5	116	148

Pada **Tabel 4.16**, disajikan perbandingan beberapa nilai ROP aktual dan ROP prediksi. Untuk setiap kedalaman, model tidak mampu melakukan prediksi dengan sempurna, hasil prediksi cenderung *overestimation* dan *underestimation*. Perbedaan yang signifikan

dengan rata-rata sebesar 27.6 ft/hr antara ROP aktual dan ROP prediksi juga menggambarkan bahwa model memiliki keakuratan yang rendah serta error yang besar.



**Gambar 4. 19** Plot Perbandingan Nilai *Actual* dan *Predicted* ROP SVR 26”

Plot perbandingan antara ROP aktual dan ROP prediksi untuk setiap kedalaman pada bagian 17.5” dapat terlihat pada **Gambar 4.20**. Meskipun bentuk plot terlihat tidak berbeda signifikan, tetapi skala hasil berbeda jauh. Pada plot grafik sebelah kiri (ROP aktual), skala hasil kurang dari 150, sedangkan pada plot grafik sebelah kanan (ROP prediksi), skala hasil mencapai nilai lebih dari 200. Hasil simulasi kemudian dilengkapi dengan beberapa kriteria evaluasi, yaitu RMSE,  $R^2$ , MSE, dan MAPE seperti pada **Tabel 4.17** berikut.

**Tabel 4. 17** Kriteria Evaluasi SVR untuk Bagian 17.5”

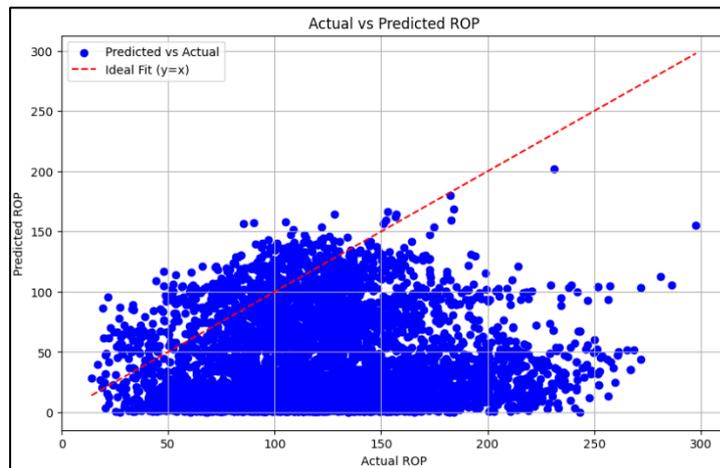
KRITERIA EVALUASI	
$R^2$	0.08
Root Mean Squared Error (RMSE)	43.26
Mean Absolute Error (MAE)	33.06
Mean Absolute Percentage Error (MAPE)	37.69

Nilai  $R^2$  sebesar 0.08 menunjukkan bahwa model hanya mampu menjelaskan 8% variabilitas, tetapi tidak mampu menjelaskan 92% variabilitas lainnya. Nilai RMSE sebesar 43.26 dan MAE sebesar 33.06 tergolong ke dalam kesalahan yang moderat. Selanjutnya, nilai

MAPE sebesar 37.69 menunjukkan kesalahan prediksi sebesar 37.69%, angka ini tergolong sebagai *reasonable forecasting* mengacu kepada **Tabel 2.3**.

#### e. Model Bingham

Model Bingham, seperti yang tertera pada Gambar 4.21 merupakan model yang tidak akurat atau buruk dalam melakukan prediksi karena persebaran data sangat acak dan tidak membentuk garis diagonal. Selanjutnya, disajikan pula beberapa kriteria evaluasi seperti yang tertera pada Tabel 4.19 berikut.



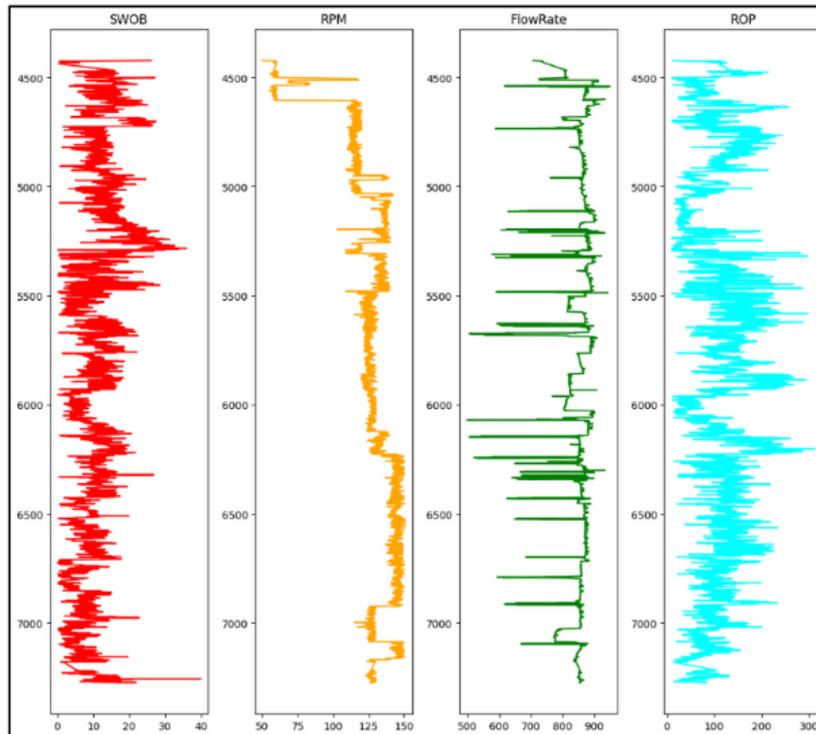
**Gambar 4. 20** Grafik *True values Vs Predictions* Bingham 17.5”

**Tabel 4. 18** Kriteria Evaluasi Bingham untuk Bagian 17.5”

KRITERIA EVALUASI	
$R^2$	-3.64
Root Mean Squared Error (RMSE)	98.99
Mean Absolute Error (MAE)	83.08
Mean Absolute Percentage Error (MAPE)	64.67

Nilai  $R^2$  sebesar -3.64 menunjukkan bahwa model tidak valid atau tidak akurat dalam melakukan prediksi. Hasil prediksi yang buruk tersebut dapat terjadi karena adanya konstanta  $a$  dan  $k$  (konstanta formasi batuan) yang tidak dilakukan update pada setiap kedalamannya. Hal tersebut dapat terjadi karena tidak adanya data formasi batuan yang lengkap yang dapat menunjang keberhasilan model tersebut.

### 4.1.3 Bagian 12.25"



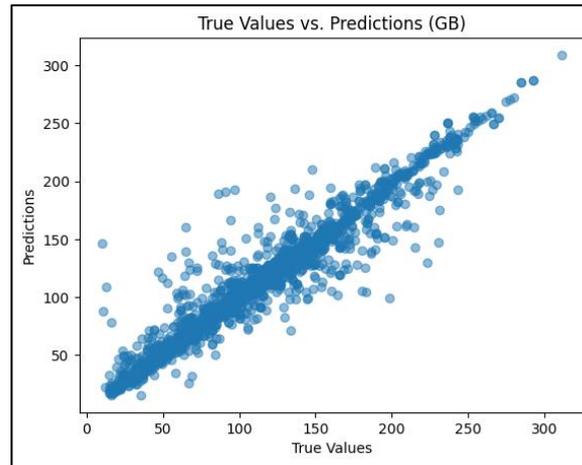
**Gambar 4. 21** Plot Data Aktual Bagian 12.25"

Dari **Gambar 4.19** dapat dilihat data keempat parameter pada kedalaman 4420-7275 ftMD. Rentang data untuk setiap parameternya, yaitu sebagai berikut:

- WOB : 1.3-39 klbs
- RPM : 50-150 rpm
- *Flow rate* : 450-4300 gpm

#### a. *Gradient Boosting Regression*

Hasil simulasi dari model *Gradient Boosting Regression* untuk bagian 12.25" dapat dilihat pada **Gambar 4.24**. *Hyperparameter* terbaik yang digunakan, yaitu  $learning\_rate = 0.2$ ,  $loss = squared\_error$ ,  $max\_depth = 7$ ,  $min\_samples\_leaf = 2$ ,  $min\_samples\_split = 5$ ,  $n\_estimators = 300$ . Persebaran data cukup baik karena garis diagonal terbentuk cukup jelas sehingga menunjukkan bahwa model memiliki kemampuan memprediksi dengan baik dan akurat. Selanjutnya, pada **Tabel 4.20** disajikan perbandingan nilai ROP aktual dan ROP prediksi pada beberapa kedalaman.

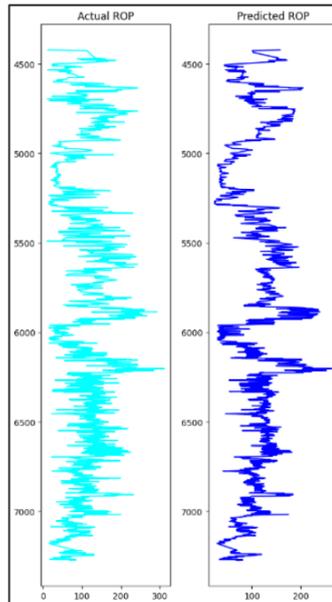


**Gambar 4. 22** Grafik *True values Vs Predictions Gradient Boosting Regression 12.25*”

**Tabel 4. 19** Hasil Prediksi GB pada Bagian 12.25"

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi (ft/hr)
4469.5	151	151
4474	160	151
4478	167	167
4480	167	170
4482	138	135
4487.5	146	147
4494	106	111
4512.5	69	68
4525.5	66	67
4559	81	82

Pada **Tabel 4.20**, terdapat dua hasil prediksi yang sama dengan nilai sebenarnya, yaitu pada kedalaman 4469.5 ftMD dan 4478 ftMD. Untuk kedalaman lainnya, hasil prediksi masih tergolong *overestimation* dan *underestimation*. Akan tetapi, selisih nilai antara ROP prediksi dan ROP aktual tidak berbeda signifikan, dengan rata-rata sebesar 3 ft/hr. Selanjutnya, untuk melihat hasil perbandingan secara keseluruhan untuk setiap kedalaman, disajikan plot grafik pada **Gambar 4.25**.



**Gambar 4. 23** Plot Perbandingan Nilai *Actual* dan *Predicted* ROP GB 12.25”

Dari **Gambar 4.25**, dapat dilihat bahwa model cukup akurat dalam memprediksi nilai ROP untuk setiap kedalamannya. Hasil kriteria evaluasi model GB bagian 12.25 disajikan pada **Tabel 4.21** berikut.

**Tabel 4. 20** Kriteria Evaluasi GB untuk Bagian 12.25”

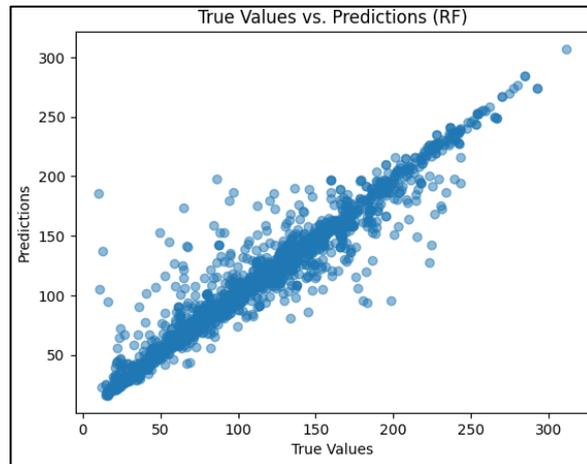
KRITERIA EVALUASI	
R <sup>2</sup>	0.91
Root Mean Squared Error (RMSE)	14.97
Mean Absolute Error (MAE)	8.28
Mean Absolute Percentage Error (MAPE)	10.53

Nilai R<sup>2</sup> sebesar 0.91 menunjukkan bahwa model mampu menjelaskan 91% variabilitas, tetapi tidak mampu menjelaskan 19% variabilitas lainnya. Nilai RMSE sebesar 14.97 dan MAE sebesar 8.28 tergolong ke dalam kesalahan yang moderat. Selanjutnya, nilai MAPE sebesar 10.53 menunjukkan kesalahan prediksi sebesar 10.53%, angka ini tergolong sebagai *reasonable forecasting* mengacu kepada **Tabel 2.3**.

#### **b. Random Forest Regression**

Hasil simulasi model RFR pada bagian 12.25” dapat dilihat pada **Gambar 4.26**. *Hyperparameter* terbaik yang diperoleh dari metode *grid search*, yaitu  $n\_estimators = 300$ ,  $min\_samples\_split = 2$ ,  $min\_samples\_leaf = 1$ ,  $max\_depth = 30$ ,  $bootstrap = true$ . Dari grafik dapat dianalisis bahwa model RFR sangat baik dalam memprediksi nilai ROP. Persebaran

data yang dihasilkan membentuk garis diagonal yang jelas, meskipun terdapat beberapa data yang masih tersebar di sekitar garis diagonal. Model terbukti dalam memprediksi data dengan cukup sempurna, atau menghasilkan banyak nilai prediksi yang sama dengan nilai sebenarnya. Untuk melihat data pada beberapa kedalaman, disajikan pada **Tabel 4.22**.

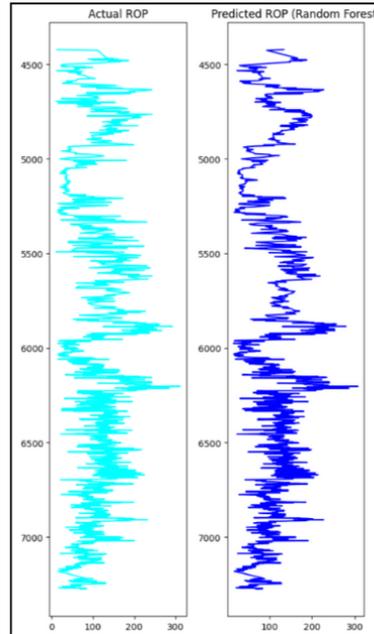


**Gambar 4. 24** Grafik *True values Vs Predictions* Random Forest 12.25”

**Tabel 4. 21** Hasil Prediksi RF pada Bagian 12.25”

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi (ft/hr)
4469.5	151	151
4474	160	157
4479	183	183
4487.5	146	149
4494	106	106
4510	37	37
4513.5	80	80
4519.5	74	70
4520	55	52
4559	81	81

Hasil pada **Tabel 4.22** menunjukkan pada enam kedalaman, ROP berhasil diprediksi sesuai dengan nilai sebenarnya, yaitu pada kedalaman 4469.5 ftMD, 4479 ftMD, 4494 ftMD, 4510 ftMD, 4513.5 ftMD, dan 4559 ftMD. Empat kedalaman lainnya tidak terprediksi secara sempurna (*overestimation* dan *underestimation*) dengan selisih rata-rata 3.75 ft/hr. Hasil prediksi untuk setiap kedalaman dapat dilihat pada **Gambar 4.27** berikut.



**Gambar 4.25** Plot Perbandingan Nilai *Actual* dan *Predicted* ROP RF 12.25”

Pada **Gambar 4.27**, plot perbandingan untuk ROP aktual dan ROP prediksi pada setiap kedalaman, memiliki hasil yang cukup akurat. Hasil simulasi kemudian dilengkapi dengan beberapa kriteria evaluasi, yaitu RMSE,  $R^2$ , MSE, dan MAPE seperti pada **Tabel 4.23** di bawah ini.

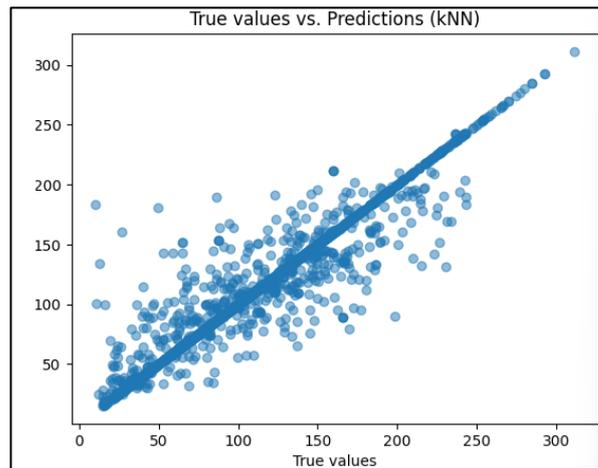
**Tabel 4. 22** Kriteria Evaluasi RF untuk Bagian 12.25”

<b>KRITERIA EVALUASI</b>	
$R^2$	0.92
Root Mean Squared Error (RMSE)	15.51
Mean Absolute Error (MAE)	7.92
Mean Absolute Percentage Error (MAPE)	10.58

Nilai  $R^2$  sebesar 0.92 menunjukkan bahwa model mampu menjelaskan 92% variabilitas, tetapi tidak mampu menjelaskan 8% variabilitas lainnya. Hal ini membuktikan bahwa kemampuan model dalam memprediksi sangat baik atau mendekati sempurna. Nilai RMSE sebesar 15.51 dan MAE sebesar 7.92 tergolong ke dalam kesalahan yang baik. Selanjutnya, nilai MAPE sebesar 10.58 menunjukkan kesalahan prediksi sebesar 10.58%, angka ini tergolong sebagai *good forecasting* atau mendekati *highly accurate forecasting* mengacu kepada **Tabel 2.3**.

**c. *k*-Nearest Neighbor Regression**

Hasil simulasi kNN pada bagian 12.25" dapat dilihat pada **Gambar 4.28**. *Hyperparameter* terbaik yang digunakan adalah  $leaf\_size = 20$ ,  $metric = manhattan$ ,  $n\_neighbors = 11$ ,  $p = 1$ ,  $weights = distance$ . Model ini memiliki kemampuan cukup baik dalam memprediksi nilai ROP, dilihat dari persebaran data yang membentuk garis diagonal, meskipun tidak sebaik model RFR pada **Gambar 4.25**. Disajikan pula data hasil prediksi pada beberapa kedalaman seperti pada **Tabel 4.24** berikut.



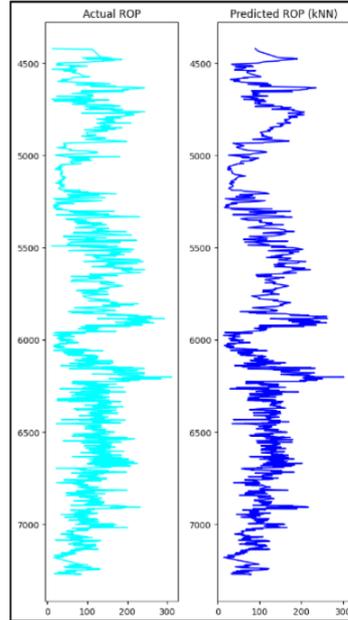
**Gambar 4.26** Grafik *True values Vs Predictions k-Nearest Neighbor 12.25"*

**Tabel 4.23** Hasil Prediksi kNN pada Bagian 12.25"

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi (ft/hr)
4479	183	182
4494	106	108
4513.5	80	81
4519	82	85
4525.5	66	68
4545	70	71
4550	69	70
4551	62	70
4559	81	80
4574.5	106	104

Hasil yang disajikan pada **Tabel 4.21** tidak menunjukkan adanya hasil prediksi ROP yang sama dengan nilai sebenarnya untuk sepuluh kedalaman tersebut. Hasil prediksi

tergolong *overestimation* dan *underestimation* dengan perbedaan yang tidak signifikan atau memiliki selisih rata-rata sebesar 2.2 ft/hr. **Gambar 4.29** di bawah merepresentasikan plot perbandingan hasil ROP aktual dan ROP prediksi untuk setiap kedalaman.



**Gambar 4. 27** Plot Perbandingan Nilai *Actual* dan *Predicted* ROP KNN 12.25"

Pada **Gambar 4.29** plot perbandingan menunjukkan hasil yang cukup akurat. Selanjutnya, kriteria evaluasi berupa  $R^2$ , RMSE, MAE, dan MAPE disajikan pada **Tabel 4.25** untuk mengetahui keakuratan model lebih mendalam.

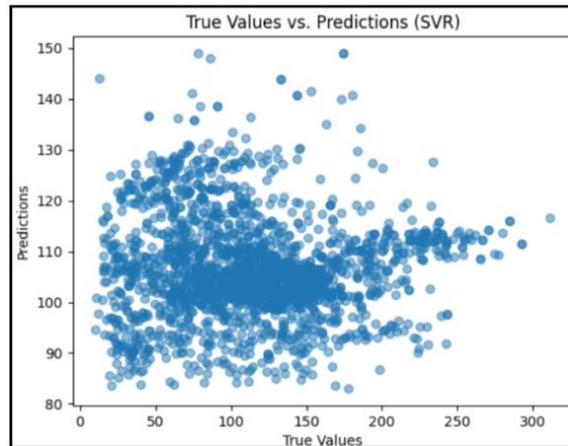
**Tabel 4. 24** Kriteria Evaluasi kNN untuk Bagian 12.25"

KRITERIA EVALUASI	
$R^2$	0.89
Root Mean Squared Error (RMSE)	17.12
Mean Absolute Error (MAE)	6.45
Mean Absolute Percentage Error (MAPE)	9.35

Nilai  $R^2$  sebesar 0.89 menunjukkan bahwa model mampu menjelaskan 89% variabilitas, tetapi tidak mampu menjelaskan 11% variabilitas lainnya. Presentase yang tinggi tersebut menggambarkan bahwa model sangat baik dalam melakukan prediksi. Nilai RMSE sebesar 17.12 dan MAE sebesar 6.45 tergolong ke dalam kesalahan yang moderat. Selanjutnya, nilai MAPE sebesar 9.35 menunjukkan kesalahan prediksi sebesar 9.35%, angka ini tergolong sebagai *good forecasting* mengacu kepada **Tabel 2.3**.

#### d. *Support Vector Regression*

Model SVR untuk bagian 12.25", seperti yang tertera pada **Gambar 4.30** merupakan model yang tidak akurat atau buruk dalam melakukan prediksi karena persebaran data sangat acak dan tidak membentuk garis diagonal. Pada **Tabel 4.26** berikut dapat dilihat beberapa hasil perbandingan antara ROP sebenarnya dan ROP prediksi yang dihasilkan pada bagian 12.25".



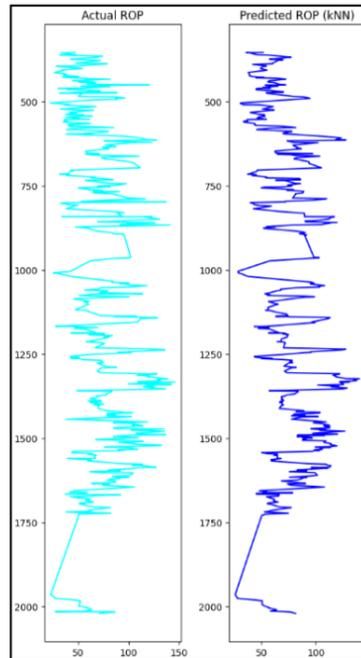
**Gambar 4. 28** Grafik *True values Vs Predictions Support Vector Regression 12.25"*

**Tabel 4. 25** Hasil Prediksi SVR pada Bagian 12.25"

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi (ft/hr)
4426	112	115
4436	117	114
4467.5	133	120
4469.5	151	117
4472	88	117
4474	160	117
4477	97	118
4478	167	116
4479	183	119
4480	167	120

Pada **Tabel 4.26**, dapat ditinjau bahwa untuk setiap kedalaman, model tidak mampu melakukan prediksi dengan sempurna, hasil prediksi cenderung *overestimation* dan

*underestimation*. Perbedaan yang signifikan dengan rata-rata selisih sebesar 30.8 ft/hr juga menggambarkan bahwa model memiliki keakuratan yang rendah serta error yang besar.



**Gambar 4. 29** Plot Perbandingan Nilai *Actual* dan *Predicted* ROP SVR 12.25”

Pada **Gambar 4.31**, dapat dilihat plot perbandingan antara ROP aktual dan ROP prediksi untuk setiap kedalaman pada bagian 12.25”. Meskipun bentuk plot terlihat tidak berbeda signifikan, tetapi skala hasil berbeda jauh. Pada plot grafik sebelah kiri (ROP aktual), skala hasil kurang dari 150, sedangkan pada plot grafik sebelah kanan (ROP prediksi), skala hasil mencapai nilai lebih dari 200. Selanjutnya, disajikan pula beberapa kriteria evaluasi seperti yang tertera pada **Tabel 4.27** berikut.

**Tabel 4. 26** Kriteria Evaluasi SVR untuk Bagian 12.25”

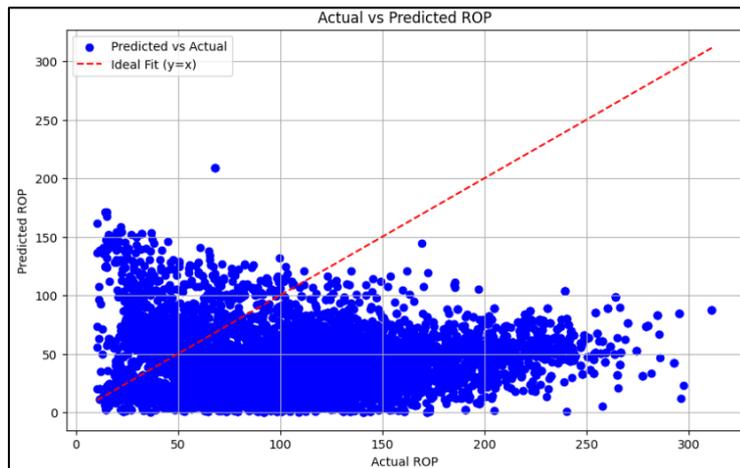
KRITERIA EVALUASI	
$R^2$	-0.05
Root Mean Squared Error (RMSE)	55.04
Mean Absolute Error (MAE)	44.27
Mean Absolute Percentage Error (MAPE)	60.80

Nilai  $R^2$  sebesar -0.05 menunjukkan bahwa model tidak mampu menjelaskan variabilitas pada dataset. Nilai RMSE sebesar 55.04 dan MAE sebesar 44.27 tergolong ke dalam kesalahan yang buruk. Selanjutnya, nilai MAPE sebesar 60.80 menunjukkan kesalahan

prediksi sebesar 60.80%, angka ini tergolong sebagai *innacurate forecasting* mengacu kepada **Tabel 2.3.**

#### e. Model Bingham

Model Bingham, seperti yang tertera pada Gambar 4.32 merupakan model yang tidak akurat atau buruk dalam melakukan prediksi karena persebaran data sangat acak dan tidak membentuk garis diagonal. Selanjutnya, disajikan pula beberapa kriteria evaluasi seperti yang tertera pada Tabel 4.28 berikut.



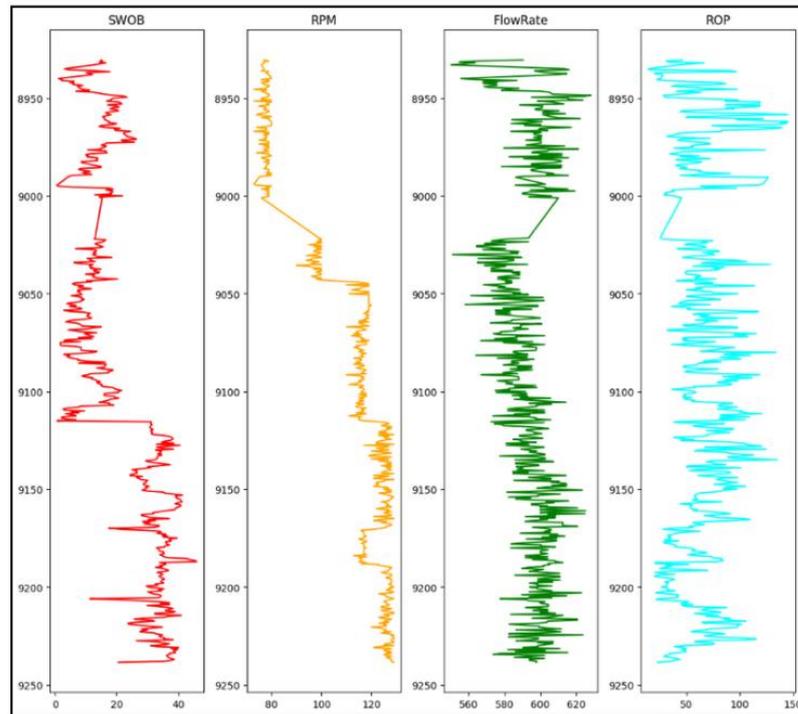
**Gambar 4. 30** Grafik *True values Vs Predictions* Bingham 17.5”

**Tabel 4. 27** Kriteria Evaluasi Bingham untuk Bagian 17.5”

KRITERIA EVALUASI	
$R^2$	-1.90
Root Mean Squared Error (RMSE)	89.42
Mean Absolute Error (MAE)	76.68
Mean Absolute Percentage Error (MAPE)	70.62

Nilai  $R^2$  sebesar -1.90 menunjukkan bahwa model tidak valid atau tidak akurat dalam melakukan prediksi. Hasil prediksi yang buruk tersebut dapat terjadi karena adanya konstanta  $a$  dan  $k$  (konstanta formasi batuan) yang tidak dilakukan update pada setiap kedalamannya. Hal tersebut dapat terjadi karena tidak adanya data formasi batuan yang lengkap yang dapat menunjang keberhasilan model tersebut.

#### 4.1.4 Bagian 8.5"



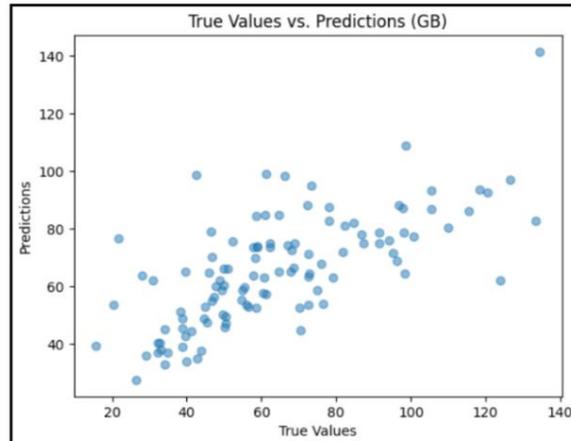
**Gambar 4. 31** Plot Data Aktual Bagian 8.5"

Dari **Gambar 4.28** dapat dilihat data keempat parameter pada kedalaman 8920-9239 ftMD. Rentang data untuk setiap parameternya, yaitu sebagai berikut:

- WOB : 1.3-39 klbs
- RPM : 50-150 rpm
- *Flow rate* : 450-4300 gpm

##### a. *Gradient Boosting Regression*

Hasil untuk model *Gradient Boosting Regression* pada bagian 8.5", disajikan pada **Gambar 4.35**. *Hyperparameter* terbaik yang digunakan adalah  $learning\_rate = 0.1$ ,  $loss = squared\_error$ ,  $max\_depth = 7$ ,  $min\_samples\_leaf = 2$ ,  $min\_samples\_split = 2$ ,  $n\_estimators = 200$ . Pada bagian ini, jumlah data jauh lebih sedikit dibandingkan bagian 26", 17.5", dan 12.25" sehingga gambaran persebaran data tidak memiliki bentuk yang signifikan apabila dibandingkan dengan grafik persebaran data pada ketiga bagian lainnya. Akan tetapi, untuk model *Gradient Boosting*, persebaran data masih membentuk garis diagonal, atau dapat disimpulkan model cukup baik melakukan prediksi dengan data yang sedikit. Untuk melihat hasil prediksi pada beberapa kedalaman, dapat dilihat pada **Tabel 4.30** di bawah ini.

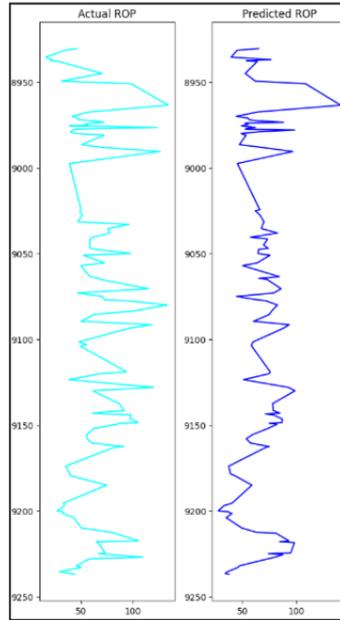


**Gambar 4. 32** Grafik *True values Vs Predictions* Gradient Boosting 8.5”

**Tabel 4. 28** Hasil Prediksi GB pada Bagian 8.5”

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi (ft/hr)
8970	41	44
8974	59	53
8974.5	55	55
8975	56	53
8980	45	49
8986.5	51	47
9040.5	61	57
9047.5	65	65
9057	50	50
9064.5	68	65

Pada **Tabel 4.30**, terdapat tiga hasil prediksi yang sama dengan nilai sebenarnya, yaitu pada kedalaman 8974.5 ftMD, 9047.5 ftMD, serta 9057 ftMD. Untuk kedalaman lainnya, hasil prediksi tergolong *overestimation* atau *underestimation* dengan rata-rata selisih sebesar 3.86 ft/hr. Hasil plot perbandingan ROP aktual dan ROP prediksi disajikan pada **Gambar 4.36** berikut.



**Gambar 4. 33** Plot Perbandingan Nilai *Actual* dan *Predicted* ROP GB 8.5”

Kriteria evaluasi berupa  $R^2$ , RMSE, MAE, dan MAPE disajikan pada **Tabel 4.31** berikut.

**Tabel 4. 29** Kriteria Evaluasi GB untuk Bagian 8.5”

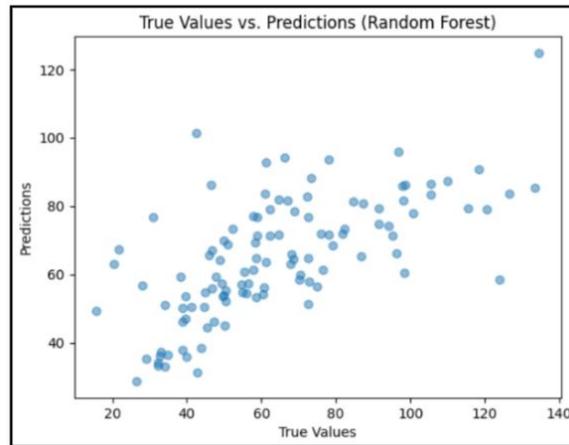
<b>KRITERIA EVALUASI</b>	
$R^2$	0.37
Root Mean Squared Error (RMSE)	20.84
Mean Absolute Error (MAE)	15.68
Mean Absolute Percentage Error (MAPE)	29.38

Nilai  $R^2$  sebesar 0.37 menunjukkan bahwa model hanya mampu menjelaskan 37% variabilitas, tetapi tidak mampu menjelaskan 63% variabilitas lainnya. Nilai RMSE sebesar 20.84 dan MAE sebesar 15.68 tergolong ke dalam kesalahan yang moderat. Selanjutnya, nilai MAPE sebesar 29.38 menunjukkan kesalahan prediksi sebesar 29.38%, angka ini tergolong sebagai *reasonable forecasting* mengacu kepada **Tabel 2.3**.

#### **b. Random Forest Regression**

Hasil simulasi dari RFR untuk bagian 8.5” dapat dilihat pada **Gambar 4.37**. *Hyperparamter* terbaik yang digunakan adalah *bootstrap = True*, *max\_depth = None*, *min\_samples\_leaf = 1*, *min\_samples\_split = 2*, *n\_estimators = 300*. Serupa dengan hasil dari simulasi GBR, penyebaran data pada grafik tidak terlihat membentuk garis diagonal yang signifikan karena jumlah data yang jauh lebih sedikit apabila dibandingkan dengan ketiga

bagian lainnya (26", 17.5", dan 12.25"). **Tabel 4.32** menyajikan perbandingan hasil ROP aktual dan ROP sebenarnya pada beberapa kedalaman.



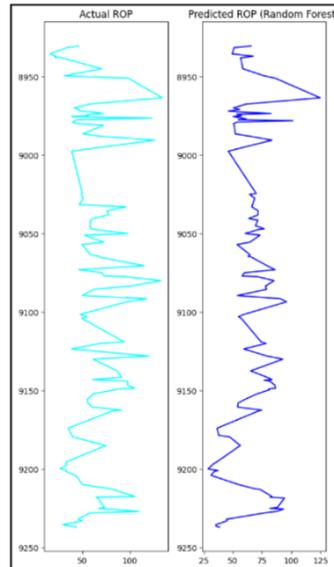
**Gambar 4. 34** Grafik *True values Vs Predictions* Random Forest 8.5"

**Tabel 4. 30** Hasil Prediksi RF pada Bagian 8.5"

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi (ft/hr)
8972	47	46
8974.5	55	57
8975	56	57
8986.5	51	52
9103	55	55
9178.5	39	38
9200.5	32	32
9201.5	32	34
9232	46	44
9236.5	40	36

Hasil simulasi yang disajikan pada **Tabel 4.32** menunjukkan bahwa model mampu memberikan hasil prediksi yang sesuai dengan nilai sebenarnya, yaitu pada kedalaman 9103 ftMD dan 9200.5 ftMD. Hasil prediksi yang tergolong *overestimation*, yaitu pada kedalaman 8947.5 ftMD, 8986.5 ftMD, dan 9201.5 ftMD. Hasil prediksi yang tergolong *underestimation*, yaitu pada kedalaman 8972 ftMD, 9178.5 ftMD, 9232 ftMD, dan 9236.5. Akan tetapi, untuk hasil prediksi yang tidak sesuai dengan nilai sebenarnya, hanya memilih rata-rata selisih sebesar 1.75 ft/hr. Rata-rata selisih ini merupakan selisih yang lebih sedikit apabila

dibandingkan dengan hasil simulasi pada model lain. Selanjutnya, untuk melihat gambaran perbandingan antara ROP hasil prediksi dan ROP aktual untuk setiap kedalaman dapat dilihat pada **Gambar 4.38** berikut.



**Gambar 4. 35** Plot Perbandingan Nilai *Actual* dan *Predicted* ROP RF 8.5”

Dari plot pada **Gambar 4.38**, secara keseluruhan, bentuk plot dari ROP hasil prediksi menyerupai plot dari ROP aktual untuk setiap kedalaman pada bagian 8.5”. Akan tetapi, adanya pengaruh jumlah data yang lebih sedikit dibandingkan ketiga bagian lain, membuat hasil prediksi tidak cukup akurat. Untuk meninjau keakuratan dari model ini lebih dalam, disajikan beberapa kriteria evaluasi, yaitu RMSE,  $R^2$ , MSE, dan MAPE seperti pada **Tabel 4.33** berikut ini.

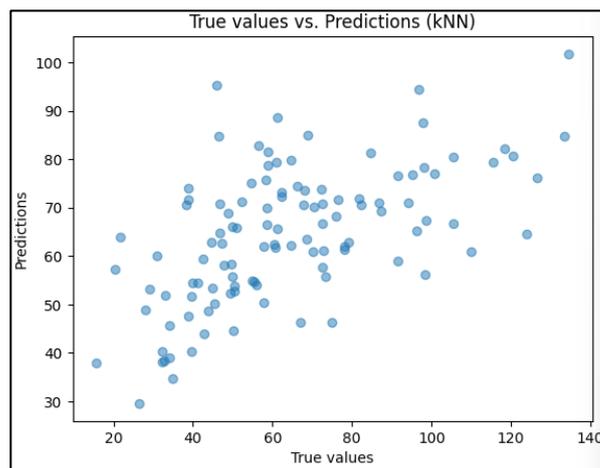
**Tabel 4. 31** Kriteria Evaluasi RF untuk Bagian 8.5”

KRITERIA EVALUASI	
$R^2$	0.43
Root Mean Squared Error (RMSE)	19.84
Mean Absolute Error (MAE)	14.64
Mean Absolute Percentage Error (MAPE)	27.36

Nilai  $R^2$  sebesar 0.43 menunjukkan bahwa model hanya mampu menjelaskan 43% variabilitas, tetapi tidak mampu menjelaskan 57% variabilitas lainnya. Nilai RMSE sebesar 19.84 dan MAE sebesar 14.64 tergolong ke dalam kesalahan yang moderat. Selanjutnya, nilai MAPE sebesar 27.36 menunjukkan kesalahan prediksi sebesar 27.36%, angka ini tergolong sebagai *reasonable forecasting* mengacu kepada **Tabel 2.3**.

**c. *k*-Nearest Neighbor Regression**

Hasil simulasi kNN untuk bagian 8.5” disajikan pada **Gambar 4.39** berikut. *Hyperparameter* terbaik yang digunakan adalah  $leaf\_size = 20$ ,  $metric = manhattan$ ,  $n\_neighbors = 7$ ,  $p = 1$ ,  $weights = distance$ . Penyebaran data yang terlihat pada grafik tersebut, megindikasikan bahwa model tidak cukup baik dalam melakukan prediksi. Untuk melihat perbandingan ROP hasil prediksi dan ROP aktual pada beberapa kedalaman dapat dilihat pada **Tabel 4.34**.



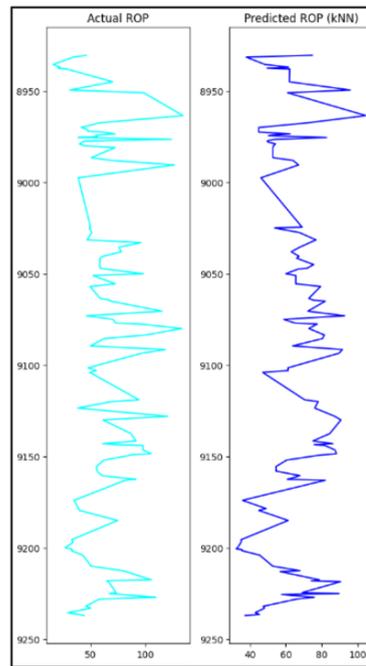
**Gambar 4. 36** Grafik *True values Vs Predictions k-Nearest Neighbor 8.5”*

**Tabel 4. 32** Hasil Prediksi kNN pada Bagian 8.5”

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi (ft/hr)
8931.5	34	38
8970	41	45
8971	47	45
8972	47	45
8974	59	54
8974.5	55	50
8977.5	45	50
8978	42	50
9040.5	61	67
9047.5	65	67

Mengacu kepada **Tabel 4.34**, untuk sepuluh kedalaman yang diambil sebagai sampel, tidak terdapat hasil prediksi yang sama dengan hasil sebenarnya. Hasil prediksi tergolong

*overestimation* dan *underestimation* dengan rata-rata selisih sebesar 4.3 ft/hr. Selanjutnya, plot ROP hasil prediksi dan ROP aktual pada setiap kedalaman disajikan pada **Gambar 4.40**.



**Gambar 4. 37** Plot Perbandingan Nilai *Actual* dan *Predicted* ROP KNN 8.5”

Pada **Gambar 4.40**, plot ROP hasil prediksi memiliki perbedaan yang signifikan dibandingkan dengan plot ROP aktual. Hasil simulasi kemudian dilengkapi dengan beberapa kriteria evaluasi, yaitu RMSE,  $R^2$ , MSE, dan MAPE seperti pada **Tabel 4.35**.

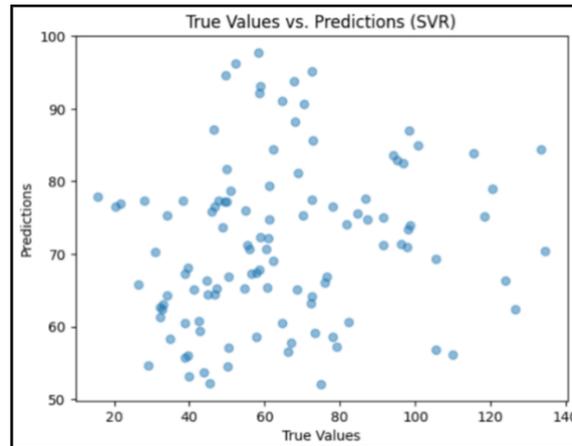
**Tabel 4. 33** Kriteria Evaluasi kNN untuk Bagian 8.5”

<b>KRITERIA EVALUASI</b>	
$R^2$	0.33
Root Mean Squared Error (RMSE)	21.43
Mean Absolute Error (MAE)	16.77
Mean Absolute Percentage Error (MAPE)	30.16

Dari hasil kriteria evaluasi pada **Tabel 4.35**, nilai  $R^2$  sebesar 0.33 menunjukkan bahwa model hanya mampu menjelaskan 33% variabilitas, tetapi tidak mampu menjelaskan 67% variabilitas lainnya. Presentase 33% menggambarkan bahwa kemampuan model dalam melakukan prediksi sangat kecil atau tidak akurat. Selanjutnya, nilai RMSE sebesar 21.43 dan MAE sebesar 16.77 tergolong ke dalam kesalahan yang moderat. Selanjutnya, nilai MAPE sebesar 30.16 menunjukkan kesalahan prediksi sebesar 30.16%, angka ini tergolong sebagai *reasonable forecasting* mengacu kepada **Tabel 2.3**.

#### d. Support Vector Regression

Pada bagian 8.5” ini, model SVR menunjukkan bahwa model tidak akurat atau buruk dalam melakukan prediksi karena persebaran data sangat acak dan tidak membentuk garis diagonal seperti yang tertera pada **Gambar 4.41**. Pada **Tabel 4.36** berikut dapat dilihat perbandingan beberapa nilai ROP aktual dan ROP prediksi yang dihasilkan pada bagian 8.5”.



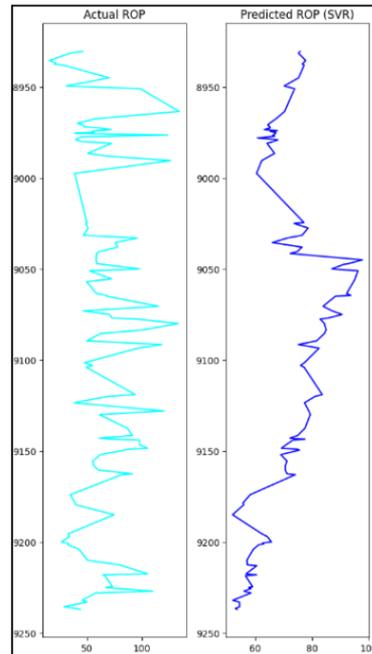
**Gambar 4. 38** Grafik *True values Vs Predictions Support Vector Regression 8.5”*

**Tabel 4. 34** Hasil Prediksi SVR pada Bagian 8.5”

Kedalaman (ftMD)	ROP Aktual (ft/hr)	ROP Prediksi (ft/hr)
8930.5	46	76
8931.5	34	75
8935.5	16	78
8937	22	77
8937.5	20	77
8938	28	77
8945	70	75
8949.5	31	70
8951	99	74
8963.5	135	70

Pada **Tabel 4.36**, untuk setiap kedalaman model tidak mampu melakukan prediksi dengan sempurna, hasil prediksi tergolong *overestimation* dan *underestimation*. Rata-rata selisih sebesar 42.8 ft/hr menunjukkan perbedaan yang signifikan antara ROP aktual dan ROP

prediksi. Hal tersebut menggambarkan bahwa model memiliki keakuratan yang rendah serta error yang besar.



**Gambar 4. 39** Plot Perbandingan Nilai *Actual* dan *Predicted* ROP SVR 8.5”

Plot perbandingan antara ROP aktual dan ROP prediksi untuk setiap kedalaman pada bagian 8.5” dapat terlihat pada **Gambar 4.42**. Nilai ROP aktual dan ROP prediksi pada grafik memiliki bentuk yang berbeda secara signifikan untuk keseluruhan kedalaman. Selanjutnya, disajikan pula beberapa kriteria evaluasi seperti yang tertera pada **Tabel 4.37** berikut.

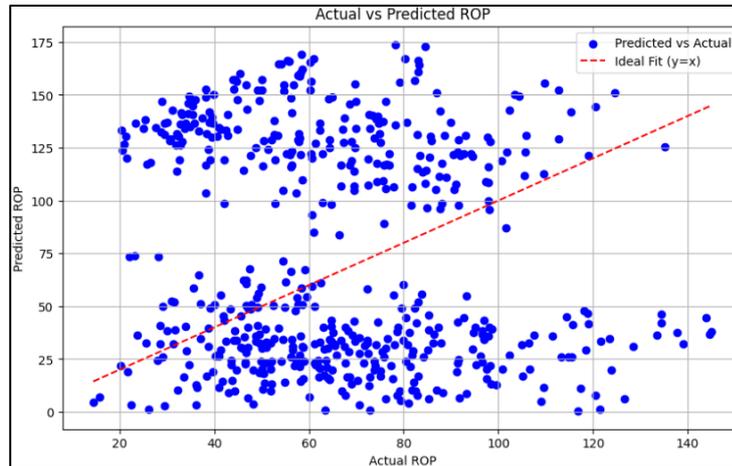
**Tabel 4. 35** Kriteria Evaluasi SVR untuk Bagian 8.5”

KRITERIA EVALUASI	
R <sup>2</sup>	-0.11
Root Mean Squared Error (RMSE)	27.61
Mean Absolute Error (MAE)	23.34
Mean Absolute Percentage Error (MAPE)	47.57

Nilai R<sup>2</sup> sebesar -0.11 menunjukkan bahwa model tidak mampu menjelaskan variabilitas pada dataset. Nilai RMSE sebesar 27.61 dan MAE sebesar 23.34 tergolong ke dalam kesalahan yang buruk. Selanjutnya, nilai MAPE sebesar 47.57 menunjukkan kesalahan prediksi sebesar 47.57%, angka ini tergolong sebagai *reasonable forecasting* dan mendekati *inaccurate forecasting* mengacu kepada **Tabel 2.3**.

### e. Model Bingham

Model Bingham, seperti yang tertera pada Gambar 4.43 merupakan model yang tidak akurat atau buruk dalam melakukan prediksi karena persebaran data sangat acak dan tidak membentuk garis diagonal. Selanjutnya, disajikan pula beberapa kriteria evaluasi seperti yang tertera pada Tabel 4.38 berikut.



**Gambar 4. 40** Grafik *True values Vs Predictions* Bingham 8.5”

**Tabel 4. 38** Kriteria Evaluasi Bingham untuk Bagian 8.5”

KRITERIA EVALUASI	
$R^2$	-4.68
Root Mean Squared Error (RMSE)	61.72
Mean Absolute Error (MAE)	52.21
Mean Absolute Percentage Error (MAPE)	95.46

Nilai  $R^2$  sebesar -4.68 menunjukkan bahwa model tidak valid atau tidak akurat dalam melakukan prediksi. Hasil prediksi yang buruk tersebut dapat terjadi karena adanya konstanta  $a$  dan  $k$  (konstanta formasi batuan) yang tidak dilakukan update pada setiap kedalamannya. Hal tersebut dapat terjadi karena tidak adanya data formasi batuan yang lengkap yang dapat menunjang keberhasilan model tersebut.

#### 4.1.5 Pemilihan Model ROP

Simulasi dari keempat algoritma *predictive modelling*, yaitu *Random Forest Regression*, *Gradient Boosting Regression*, *k-Nearest Neighbor Regression*, dan *Support Vector Regression* telah dilakukan untuk setiap bagian (26", 17.5", 12.25", dan 8.5"). Selanjutnya, dilakukan pemilihan satu algoritma *predictive modelling* yang paling akurat dalam memprediksi nilai ROP. *Predictive modelling* yang dipilih merupakan model yang memiliki nilai  $R^2$  paling besar atau mendekati 1 dan memiliki RMSE, MAE, dan MAPE paling kecil. Berikut disajikan hasil kriteria evaluasi keempat model pada setiap bagian.

**Tabel 4.36** Hasil Kriteria Evaluasi Kelima Model pada Bagian 26"

Hasil Kriteria Evaluasi pada Bagian 26"				
Model	$R^2$	RMSE	MAE	MAPE
GB	0.78	12.53	8.61	13.17
RF	0.79	12.39	8.43	12.99
k-NN	0.64	16.45	11.88	18.87
SVR	0.23	23.86	18.53	35.27
Bingham	-1.64	43.02	34.37	46.88

**Tabel 4.37** Hasil Kriteria Evaluasi Kelima Model pada Bagian 17.5"

Hasil Kriteria Evaluasi pada Bagian 17.5"				
Model	$R^2$	RMSE	MAE	MAPE
GB	0.72	23.73	16.57	18.57
RF	0.74	23.09	15.97	18.24
k-NN	0.63	27.33	18.70	21.52
SVR	0.08	43.26	33.07	37.69
Bingham	-3.64	98.99	83.08	64.67

**Tabel 4.38** Hasil Kriteria Evaluasi Kelima Model pada Bagian 12.25"

Hasil Kriteria Evaluasi pada Bagian 12.25"				
Model	$R^2$	RMSE	MAE	MAPE
GB	0.80	23.72	17.46	21.87
RF	0.92	14.97	8.28	10.52
k-NN	0.84	21.24	14.43	17.37

**Tabel 4.38** Hasil Kriteria Evaluasi Kelima Model pada Bagian 12.25"

<b>Hasil Kriteria Evaluasi pada Bagian 12.25"</b>				
<b>SVR</b>	-0.05	55.04	44.27	60.8
<b>Bingham</b>	-1.91	89.42	76.68	70.62

**Tabel 4.39** Hasil Kriteria Evaluasi Kelima Model pada Bagian 8.5"

<b>Hasil Kriteria Evaluasi pada Bagian 8.5"</b>				
<b>Model</b>	<b>R<sup>2</sup></b>	<b>RMSE</b>	<b>MAE</b>	<b>MAPE</b>
<b>GB</b>	0.41	19.72	14.34	26.41
<b>RF</b>	0.43	19.84	14.64	27.36
<b>k-NN</b>	0.31	21.74	15.98	28.83
<b>SVR</b>	0.15	28.63	24.45	39.20
<b>Bingham</b>	-4.68	61.72	52.21	95.46

Dengan meninjau hasil pada **Tabel 3.33**, **Tabel 3.34**, **Tabel 3.35**, dan **Tabel 3.36**, untuk setiap bagian, algoritma yang paling akurat adalah model *Random Forest Regression*. Pada setiap bagian, model ini memiliki nilai  $R^2$  paling tinggi dan RMSE, MAE, dan MAPE paling rendah apabila dibandingkan dengan ketiga algoritma lainnya. Dengan nilai  $R^2$  paling tinggi adalah 0.92 dan paling rendah adalah 0.46. Perbedaan nilai  $R^2$  yang cukup signifikan ini terjadi karena adanya perbedaan jumlah dan variasi data pada setiap bagiannya. Untuk setiap bagian, jumlah datanya adalah sebagai berikut, bagian 26" = 2633 data, bagian 17.5" = 4529 data, bagian 12.25" = 5312 data, dan bagian 8.5" = 596 data. Bagian 12.25", dengan data terbanyak, terbukti memiliki nilai akurasi paling tinggi. Bagian 8.5", dengan data paling sedikit, terbukti memiliki nilai akurasi paling rendah. Hal ini sesuai dengan teori yang menyatakan pentingnya dataset dalam meningkatkan akurasi model.

Berdasarkan teori yang berlaku, lebih banyak dataset, maka resiko *overfitting* dapat dikurangi. *Overfitting* merupakan keadaan yang dapat terjadi ketika model terlalu spesifik pada data pelatihan dan gagal menggeneralisasi pada data-data baru. Dataset yang besar memungkinkan model untuk menangkap pola yang lebih kompleks yang mungkin tidak terlihat atau tidak dapat diidentifikasi dengan dataset yang lebih kecil. Hal tersebut juga sesuai dengan Prinsip Emiris, yang menyatakan bahwa untuk banyak algoritma pembelajaran mesin, performa akan terus meningkat seiring dengan meningkatnya jumlah dataset. Selain itu, berdasarkan praktik-praktik yang telah berlaku, algoritma sederhana yang dilatih dengan

dataset besar sering kali mengalahkan algoritma kompleks yang dilatih dengan dataset yang lebih kecil (Domingos, 2012).

## 4.2 Hasil Optimisasi sebelum Uji Kelayakan

Optimisasi pertama yang dilakukan merupakan simulasi dengan menggunakan *lower-upper bound* dari data historis. Nilai *lower-upper bound* untuk ketiga parameter (RPM, WOB, *Flow rate*) tersebut merupakan nilai yang belum tervalidasi secara ilmu pemboran dan keadaan aktual operasi pemboran. Optimisasi dilakukan pada setiap bagian, yaitu 26”, 17.5”, 12.25”, dan 8.5” . Hasil yang disajikan berupa data *head* (beberapa baris pertama pada dataset) hasil optimisasi dari masing-masing bagian yang berisikan nilai WOB, RPM, *Flow rate*, dan ROP. Disajikan pula plot hasil optimisasi untuk setiap parameter berdasarkan kedalamannya.

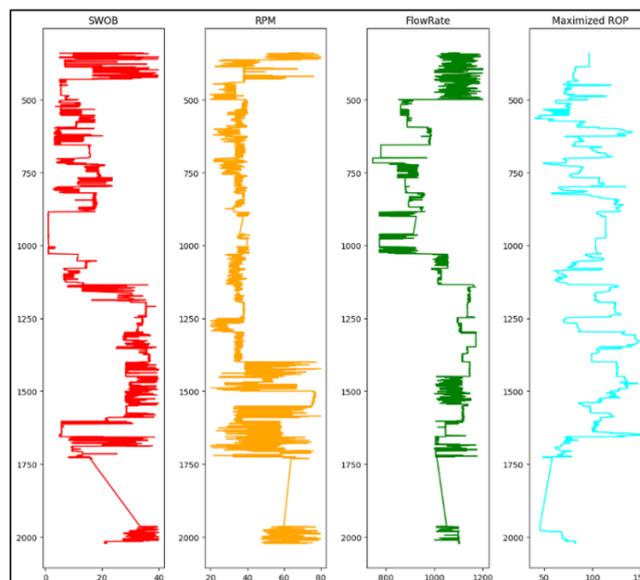
### 4.2.1 Bagian 26”

Pada **Tabel 4.37** berikut, disajikan hasil optimisasi untuk lima belas kedalaman pertama pada bagian 26”. Optimisasi yang dilakukan sebelum uji kelayakan menggunakan *lower-upper bound* berdasarkan data historis seperti yang tertera pada **Tabel 3.1**. **Tabel 4. 40** Data *Head* Hasil Optimisasi sebelum Uji Kelayakan Bagian 26”

Kedalaman (ftMD)	WOB (klbs)	RPM (rpm)	FlowRate (gpm)	ROP (ft/hr)
340	10	68	1058	97
340.5	35	63	1103	97
341	5	77	1068	97
341.5	24	69	1104	97
342	36	51	1079	97
342.5	21	51	1026	97
343	24	70	1061	97
343.5	27	51	1182	97
344	10	71	1055	97
344.5	10	52	1039	97
345	10	55	1133	97
345.5	10	54	1188	97
346	10	67	1030	97
346.5	10	59	1049	97

Kedalaman (ftMD)	WOB (klbs)	RPM (rpm)	FlowRate (gpm)	ROP (ft/hr)
347	23	79	1074	97

Hasil yang disajikan pada **Tabel 4.37** memberikan rentang angka yang bervariasi untuk ketiga parameter, yaitu WOB, RPM, dan *flowrate*. Meskipun formasi batuan pada kedalaman ini secara keseluruhan berjenis sama (claystone), tetapi nilai keempat parameter dapat memiliki perbedaan di setiap rentang kedalaman 0.5 ftMD. Perbedaan yang cukup signifikan dapat terlihat pada parameter WOB di kedalaman 340.5 ftMD dan 341 ftMD dengan nilai WOB sebesar 35 klbs dan 5 klbs. Hal tersebut dapat terjadi karena adanya variabilitas sifat formasi pada skala mikro, seperti kekerasan, kepadatan, dan komposisi mineral yang dapat menyebabkan perbedaan signifikan dalam parameter pemboran, bahkan dalam formasi yang tampaknya homogen (Wu et al., 2023). Selain itu, dengan metode yang digunakan, yaitu kombinasi antara *Random Forest Regression* dan *Particle Swarm Optimization*, yang memungkinkan model untuk tidak hanya menangkap variasi kecil dalam data, tetapi juga untuk beradaptasi dengan cepat terhadap perubahan kondisi formasi. Variasi besar dalam WOB pada kedalaman yang berdekatan mencerminkan sensitivitas model terhadap perubahan mikro dalam properti formasi, yang mungkin tidak terlihat pada skala makro tetapi ada secara mikroskopis (Lashari et al., 2019). Selanjutnya, untuk plot hasil keseluruhan pada setiap kedalaman dapat dilihat pada **Gambar 4.37**



**Gambar 4. 41** Plot Data Hasil Optimisasi Pertama Bagian 26”

Rentang hasil yang disajikan pada **Tabel 4.38** berikut merupakan hasil yang akan dijadikan acuan pada uji kelayakan untuk menyesuaikan setiap parameter dengan keadaan

ideal aktual pemboran Sumur X Lapangan Mudi. Setelah melakukan langkah-langkah seperti yang telah dijabarkan pada **tahap 3.8**, dilakukan perbandingan terhadap rentang nilai parameter hasil optimisasi dan hasil uji kelayakan sehingga diperoleh perbandingan seperti pada **Tabel 4.39**. Hasil uji kelayakan membuktikan bahwa untuk keempat parameter diperlukan penyesuaian baru sehingga diperlukan simulasi optimisasi menggunakan *lower-upper bound* hasil uji kelayakan.

**Tabel 4. 41** Hasil Optimisasi sebelum Uji Kelayakan 26"

Hasil Optimisasi sebelum Uji Kelayakan 26"	
Weight on Bit (WOB)	1-40 klbs
Rotation per Minute (RPM)	20-80 rpm
FlowRate	745-1200 gpm
ROP	83-236 ft/hr

**Tabel 4. 42** Perbandingan Hasil Optimisasi dan Hasil Uji Kelayakan bagian 26"

Perbandingan Hasil Optimisasi dan Hasil Uji Kelayakan bagian 26"		
Parameter	Hasil Optimisasi	Hasil Uji Kelayakan
Weight on Bit (WOB)	1-40 klbs	5-28 klbs
Rotation per Minute (RPM)	20-80 rpm	180-190 rpm
FlowRate	745-1200 gpm	1000-1300 gpm

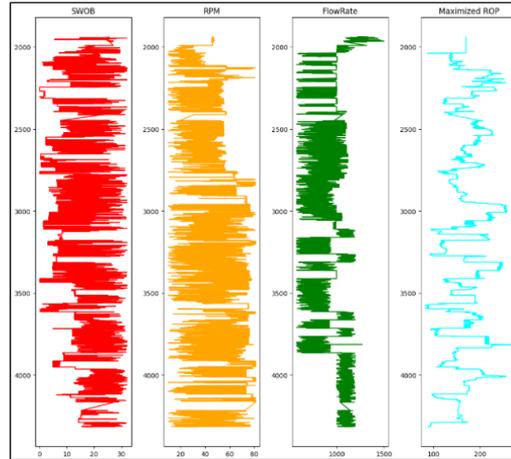
#### 4.2.2 Bagian 17.5"

Pada **Tabel 4.40** berikut, disajikan hasil optimisasi untuk lima belas kedalaman pertama pada bagian 17.5". Optimisasi yang dilakukan sebelum uji kelayakan menggunakan *lower-upper bound* berdasarkan data historis seperti yang tertera pada **Tabel 3.1**.

**Tabel 4. 40** *Data Head Hasil Optimisasi Pertama Bagian 17.5”*

<b>Kedalaman (ftMD)</b>	<b>SWOB (klbs)</b>	<b>RPM (rpm)</b>	<b>FlowRate (gpm)</b>	<b>ROP (ft/hr)</b>
1939	25	46	1329	170
1939.5	25	46	1222	170
1940	25	46	1297	170
1941.5	25	47	1147	170
1942	25	47	1401	170
1942.5	25	46	1363	170
1943.5	25	46	1172	170
1944	25	46	1208	170
1945	25	47	1337	170
1945.5	25	47	1098	170
1946.5	32	47	1196	170
1947.5	25	47	1438	170
1948	28	46	1292	170
1950	24	47	1116	170
1951	25	47	1133	170

Hasil yang ditampilkan pada **Tabel 4.40** tidak menunjukkan perbedaan yang signifikan untuk ketiga parameter pada setiap kedalamannya. Formasi batuan pada kedalaman ini adalah *claystone* dan *limestone*. Tidak adanya perbedaan signifikan pada parameter pemboran yang dihasilkan tersebut terjadi karena pada 15 kedalaman pertama yang ditampilkan tidak ada variabilitas sifat formasi pada skala mikro seperti yang terjadi pada bagian 26”. Akan tetapi, apabila meninjau secara keseluruhan pada bagian 17.5”, ketiga nilai parameter juga memiliki variabilitas yang beragam seperti yang tampak pada **Gambar 4.38** berikut.



**Gambar 4. 42** Plot Data Hasil Optimisasi Pertama Bagian 17.5”

Hasil yang disajikan dalam **Tabel 4.40** digunakan sebagai referensi untuk uji kelayakan dalam menyesuaikan parameter-parameter pengeboran dengan kondisi ideal pada Sumur X di Lapangan Mudi. Setelah mengikuti langkah-langkah yang dijelaskan pada **tahap 3.8**, dilakukan perbandingan antara rentang nilai parameter hasil optimisasi dan hasil uji kelayakan. Perbandingan ini tercantum dalam **Tabel 4.41**. Hasil dari uji kelayakan menunjukkan bahwa ketiga parameter memerlukan penyesuaian baru. Oleh karena itu, diperlukan simulasi optimisasi tambahan menggunakan batas bawah dan batas atas yang diperoleh dari hasil uji kelayakan tersebut.

**Tabel 4. 43** Hasil Optimisasi sebelum Uji Kelayakan 17.5”

Hasil Optimisasi sebelum Uji Kelayakan 17.5”	
Weight on Bit (WOB)	0.1-32 klbs
Rotation per Minute (RPM)	10-81 rpm
FlowRate	584-1948 gpm
ROP	83-268 ft/hr

**Tabel 4. 44** Perbandingan Hasil Optimisasi dan Hasil Uji Kelayakan bagian 17.5”

Perbandingan Hasil Optimisasi dan Hasil Uji Kelayakan bagian 17.5”		
Parameter	Hasil Optimisasi	Hasil Uji Kelayakan
Weight on Bit (WOB)	0.1-32 klbs	5-50 klbs
Rotation per Minute (RPM)	10-81 rpm	180-190 rpm
FlowRate	584-1948 gpm	1000-1200 gpm

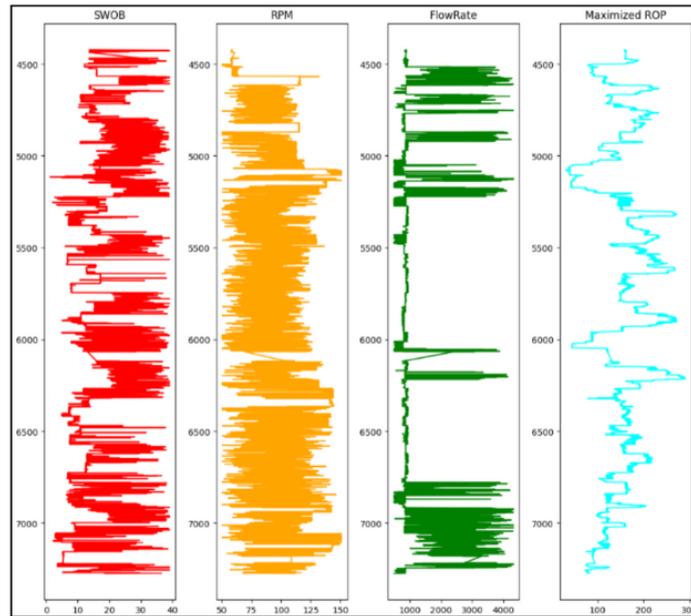
### 4.2.3 Bagian 12.25"

Pada **Tabel 4.42** berikut, disajikan hasil optimisasi untuk lima belas kedalaman pertama pada bagian 12.25". Optimisasi yang dilakukan sebelum uji kelayakan menggunakan *lower-upper bound* berdasarkan data historis seperti yang tertera pada **Tabel 3.1**.

**Tabel 4. 45** Data *Head* Hasil Optimisasi Pertama Bagian 12.25"

Kedalaman (ftMD)	SWOB (klbs)	RPM (rpm)	FlowRate (gpm)	ROP (ft/hr)
4422	14	58	873	159
4425	39	58	882	157
4425.5	21	58	843	160
4426	14	58	853	162
4427	39	58	910	160
4431	23	58	877	160
4431.5	14	58	852	162
4432	26	58	839	160
4436	14	58	898	162
4436.5	14	61	890	162
4467.5	30	58	853	160
4468	14	64	857	162
4468.5	14	58	896	162
4469	35	58	865	160
4469.5	14	61	903	161

Untuk bagian 12.25", seperti yang disajikan pada **Tabel 4.42**, parameter WOB memiliki variabilitas nilai yang beragam. Hal ini memiliki permasalahan yang sama dengan yang terjadi pada bagian 26", yaitu adanya variabilitas sifat formasi pada skala mikro, seperti kekerasan, kepadatan, dan komposisi mineral yang dapat menyebabkan perbedaan signifikan dalam parameter pemboran, bahkan dalam formasi yang tampaknya homogen (Wu et al., 2023). Formasi pada bagian ini secara keseluruhan berjenis sama, yaitu *claystone* dan *limestone*. Selanjutnya, untuk plot hasil keseluruhan pada setiap kedalaman dapat dilihat pada **Gambar 4.39** berikut.



**Gambar 4. 43** Plot Data Hasil Optimisasi Pertama Bagian 12.25”

Selanjutnya, terdapat rentang hasil optimisasi untuk keempat parameter yang disajikan dalam **Tabel 4.43**. Hasil ini digunakan sebagai referensi untuk uji kelayakan dalam menyesuaikan parameter-parameter pemboran dengan kondisi ideal pada Sumur X di Lapangan Mudi. Setelah mengikuti langkah-langkah yang dijelaskan pada **tahap 3.8**, dilakukan perbandingan antara rentang nilai parameter hasil optimisasi dan hasil uji kelayakan. Perbandingan ini tercantum dalam **Tabel 4.44**. Hasil dari uji kelayakan menunjukkan bahwa ketiga parameter memerlukan penyesuaian baru. Oleh karena itu, diperlukan simulasi optimisasi tambahan menggunakan batas bawah dan batas atas yang diperoleh dari hasil uji kelayakan tersebut.

**Tabel 4. 46** Hasil Optimisasi sebelum Uji Kelayakan 12.25”

<b>Hasil Optimisasi sebelum Uji Kelayakan 12.25”</b>	
Weight on Bit (WOB)	1.2-39 klbs
Rotation per Minute (RPM)	50-151 rpm
FlowRate	498-4317 gpm
Maximized ROP	31.4-290 ft/hr

**Tabel 4. 47** Perbandingan Hasil Optimisasi dan Hasil Uji Kelayakan bagian 12.25”

Perbandingan Hasil Optimisasi dan Hasil Uji Kelayakan bagian 12.25”		
Parameter	Hasil Optimisasi	Hasil Uji Kelayakan
Weight on Bit (WOB)	1.2-39 klbs	5-35 klbs
Rotation per Minute (RPM)	50-151 rpm	120-190 rpm
FlowRate	498-4317 gpm	750-1000 gpm

#### 4.2.4 Bagian 8.5”

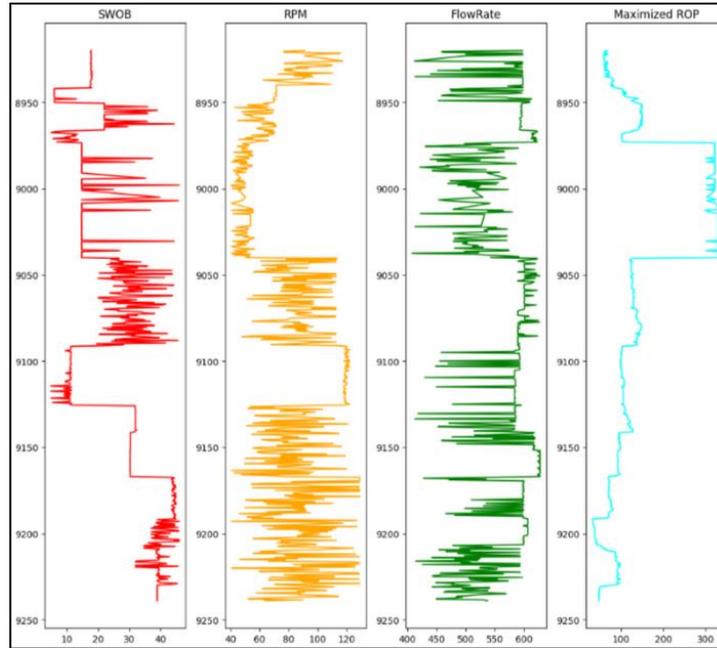
Pada **Tabel 4.45** berikut, disajikan hasil optimisasi untuk lima belas kedalaman pertama pada bagian 8.5”. Optimisasi yang dilakukan sebelum uji kelayakan menggunakan *lower-upper bound* berdasarkan data historis seperti yang tertera pada **Tabel 3.1**.

**Tabel 4. 48** Data Head Hasil Optimisasi Pertama Bagian 8.5”

Kedalaman (ftMD)	SWOB (klbs)	RPM (rpm)	FlowRate (gpm)	ROP (ft/hr)
8920	18	91	598	68
8920.5	20	77	459	61
8921	19	77	461	61
8921.5	22	116	598	68
8922	18	103	500	59
8922.5	17	96	598	68
8923	23	91	500	59
8926	24	117	412	60
8926.5	16	94	598	68
8927	18	83	598	68
8927.5	17	77	567	59
8928	19	107	597	68
8928.5	18	110	585	61
8929	20	106	584	61
8929.5	18	85	598	68

Sama seperti bagian 17.5”, hasil yang ditampilkan pada **Tabel 4.45** tidak menunjukkan perbedaan yang signifikan untuk ketiga parameter pada setiap kedalamannya, terutama WOB. Formasi batuan pada kedalaman ini adalah claystone dan limestone. Tidak

adanya perbedaan signifikan pada parameter pemboran yang dihasilkan tersebut terjadi karena pada 15 kedalaman pertama yang ditampilkan tidak ada variabilitas sifat formasi pada skala mikro seperti yang terjadi pada bagian 26”. Akan tetapi, apabila meninjau secara keseluruhan pada bagian 8.5”, ketiga nilai parameter juga memiliki variabilitas yang beragam seperti yang tampak pada **Gambar 4.40** berikut.



**Gambar 4. 44** Plot Data Hasil Optimisasi Pertama Bagian 8.5”

Selanjutnya, terdapat rentang hasil optimisasi untuk keempat parameter yang disajikan dalam **Tabel 4.46**. Hasil ini digunakan sebagai referensi untuk uji kelayakan dalam menyesuaikan parameter-parameter pemboran dengan kondisi ideal pada Sumur X di Lapangan Mudi. Setelah mengikuti langkah-langkah yang dijelaskan pada **tahap 3.8**, dilakukan perbandingan antara rentang nilai parameter hasil optimisasi dan hasil uji kelayakan. Perbandingan ini tercantum dalam **Tabel 4.47**. Hasil dari uji kelayakan menunjukkan bahwa ketiga parameter memerlukan penyesuaian baru. Oleh karena itu, diperlukan simulasi optimisasi tambahan menggunakan batas bawah dan batas atas yang diperoleh dari hasil uji kelayakan tersebut.

**Tabel 4.49** Hasil Optimisasi sebelum Uji Kelayakan 8.5”

Hasil Optimisasi sebelum Uji Kelayakan 8.5”	
Weight on Bit (WOB)	5-46 klbs
Rotation per Minute (RPM)	41-129 rpm
FlowRate	408-628 gpm
Maximized ROP	33-335 ft/hr

**Tabel 4. 50** Perbandingan Hasil Optimisasi dan Hasil Uji Kelayakan bagian 8.5”

Perbandingan Hasil Optimisasi dan Hasil Uji Kelayakan bagian 8.5”		
Parameter	Hasil Optimisasi	Hasil Uji Kelayakan
Weight on Bit (WOB)	5-46 klbs	5-48 klbs
Rotation per Minute (RPM)	41-129 rpm	120-190 rpm
FlowRate	408-628 gpm	400-650 gpm

### 4.3 Hasil Optimisasi Setelah Uji Kelayakan

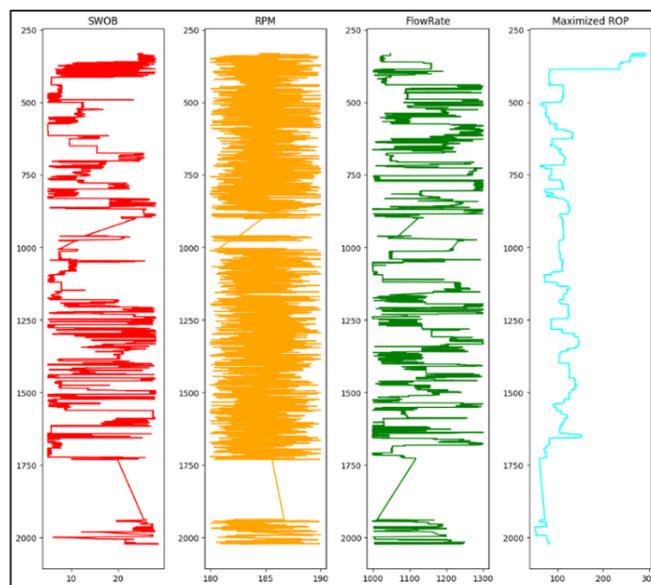
Hasil optimisasi pada tahap ini merupakan hasil simulasi optimisasi yang dilakukan setelah mendapat validasi hasil dari uji kelayakan. Hasil dari uji kelayakan operasi pemboran aktual terhadap hasil optimisasi pertama menunjukkan adanya keharusan penyesuaian terhadap *lower-upper bound* yang layak diterapkan secara perhitungan, teori, maupun keadaan aktual operasi pemboran (seperti spesifikasi alat). Dari perbandingan hasil optimisasi pertama dan hasil uji kelayakan, penyesuaian harus dilakukan pada ketiga parameter, yaitu WOB, RPM, dan *Flow rate*. Optimisasi dilakukan pada setiap bagian, yaitu 26”, 17.5”, 12.25”, dan 8.5” . Hasil yang disajikan berupa data *head* hasil optimisasi dari masing-masing bagian yang berisikan nilai WOB, RPM, *Flow rate*, dan ROP. Disajikan pula plot hasil optimisasi untuk setiap parameter berdasarkan kedalamannya.

#### 4.3.1 Bagian 26”

Pada **Tabel 4.48** berikut, disajikan hasil optimisasi untuk lima belas kedalaman pertama pada bagian 26”. Optimisasi yang dilakukan setelah uji kelayakan menggunakan *lower-upper bound* berdasarkan hasil uji kelayakan seperti yang tertera pada **Tabel 4.39**.

**Tabel 4. 51** Data Head Hasil Optimisasi Kedua Bagian 26''

Kedalaman (ftMD)	WOB (klbs)	RPM (rpm)	FlowRate (gpm)	ROP (ft/hr)
332	25	185	1048	292
333	24	186	1048	268
335	25	185	1048	262
335	24	184	1048	262
337	25	189	1048	262
340	28	189	1049	262
340	24	188	1025	292
341	26	182	1026	268
341	25	186	1027	262
342	26	188	1029	262
342	26	181	1023	261
343	28	182	1023	260
343	25	190	1024	259
344	24	187	1022	259
344	26	186	1028	259

**Gambar 4. 45** Plot Data Hasil Optimisasi Kedua Bagian 26''

Optimisasi setelah uji kelayakan memiliki rentang hasil untuk keempat parameter seperti pada **Tabel 4.49** berikut. Rentang hasil yang dihasilkan sudah sesuai dengan hasil uji kelayakan sehingga hasil optimisasi ini layak atau dapat diaplikasikan di lapangan. Selain itu,

nilai ROP yang dihasilkan dapat digunakan untuk perhitungan waktu dan biaya pemboran selanjutnya.

**Tabel 4. 52** Hasil Optimisasi setelah Uji Kelayakan 26”

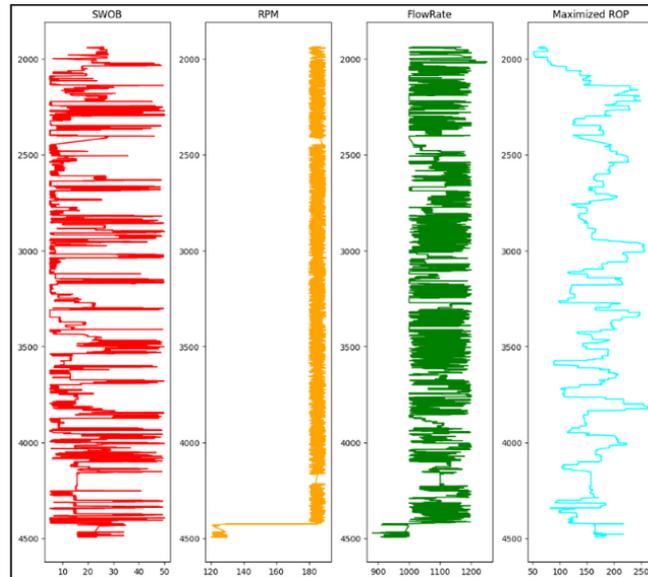
<b>Hasil Optimisasi setelah Uji Kelayakan 26”</b>	
Weight on Bit (WOB)	5-28 klbs
Rotation per Minute (RPM)	180-190 rpm
FlowRate	1000-1300 gpm
Maximized ROP	51-292 ft/hr

### 4.3.2 Bagian 17.5”

Pada **Tabel 4.50** berikut, disajikan hasil optimisasi untuk lima belas kedalaman pertama pada bagian 17.5”. Optimisasi yang dilakukan setelah uji kelayakan menggunakan *lower-upper bound* berdasarkan hasil uji kelayakan seperti yang tertera pada **Tabel 4.41**.

**Tabel 4. 53** Data Head Hasil Optimisasi Kedua Bagian 17.5”

<b>Kedalaman (ftMD)</b>	<b>WOB (klbs)</b>	<b>RPM (rpm)</b>	<b>FlowRate (gpm)</b>	<b>ROP (ft/hr)</b>
1939	26	187	1012	73
1939	26	182	1099	66
1940	26	187	1100	63
1940	26	184	1167	61
1942	20	181	1009	61
1942	20	187	1048	61
1943	20	182	1001	61
1943	20	189	1072	61
1944	20	186	1120	61
1944	20	180	1000	61
1945	25	190	1121	61
1946	24	187	1117	61
1947	26	186	1113	75
1948	26	184	1148	75
1948	26	181	1151	75



**Gambar 4. 46** Plot Data Hasil Optimisasi Kedua Bagian 17.5”

Pada bagian 17.5”, rentang hasil optimisasi untuk keempat parameter dapat dilihat seperti pada **Tabel 4.51** berikut. Rentang hasil untuk keempat parameter ini sudah sesuai dengan hasil uji kelayakan yang telah dilakukan sehingga hasil optimisasi dapat diaplikasikan untuk perencanaan pemboran pada sumur terdekat atau sumur dengan kondisi formasi yang serupa dengan Sumur X Lapangan Mudi ini. Selain itu, ROP yang dihasilkan akan mempengaruhi perhitungan waktu dan biaya pemboran.

**Tabel 4. 54** Hasil Optimisasi setelah Uji Kelayakan 17.5”

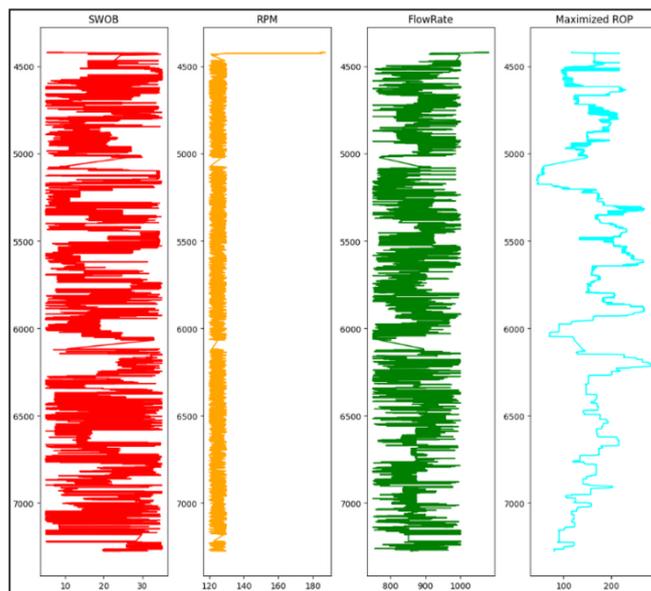
<b>Hasil Optimisasi setelah Uji Kelayakan 17.5”</b>	
Weight on Bit (WOB)	5-50 klbs
Rotation per Minute (RPM)	120-190 rpm
FlowRate	882-1200 gpm
Maximized ROP	51-263 ft/hr

#### 4.3.3 Bagian 12.25”

Pada **Tabel 4.52** berikut, disajikan hasil optimisasi untuk lima belas kedalaman pertama pada bagian 12.25”. Optimisasi yang dilakukan setelah uji kelayakan menggunakan *lower-upper bound* berdasarkan hasil uji kelayakan seperti yang tertera pada **Tabel 4.43**.

**Tabel 4. 55** Data Head Hasil Optimisasi Kedua Bagian 12.25

Kedalaman (ftMD)	WOB (klbs)	RPM (rpm)	FlowRate (gpm)	ROP (ft/hr)
4420	9	184	1041	117
4421	5	187	1079	118
4421	5	185	1081	118
4422	11	187	1062	117
4425	33	183	993	165
4426	28	129	915	218
4426	34	185	993	165
4427	30	129	996	165
4431	16	123	911	163
4432	20	121	993	165
4432	35	123	990	165
4436	27	125	998	165
4437	24	121	999	165
4468	23	129	988	165
4468	34	121	996	165

**Gambar 4. 47** Plot Data Hasil Optimisasi Kedua Bagian 12.25”

Selanjutnya, untuk bagian 12.25”, rentang hasil optimisasi untuk keempat parameter dapat dilihat seperti pada **Tabel 4.53** berikut. Rentang hasil yang dihasilkan sudah sesuai dengan hasil uji kelayakan sehingga keempat parameter dapat dijadikan acuan untuk

perencanaan pemboran pada sumur terdekat atau sumur yang memiliki formasi serupa dengan Sumur X Lapangan Mudi. Selain itu, hasil optimisasi ROP akan digunakan untuk perhitungan waktu dan biaya pemboran.

**Tabel 4. 56** Hasil Optimisasi setelah Uji Kelayakan 12.25”

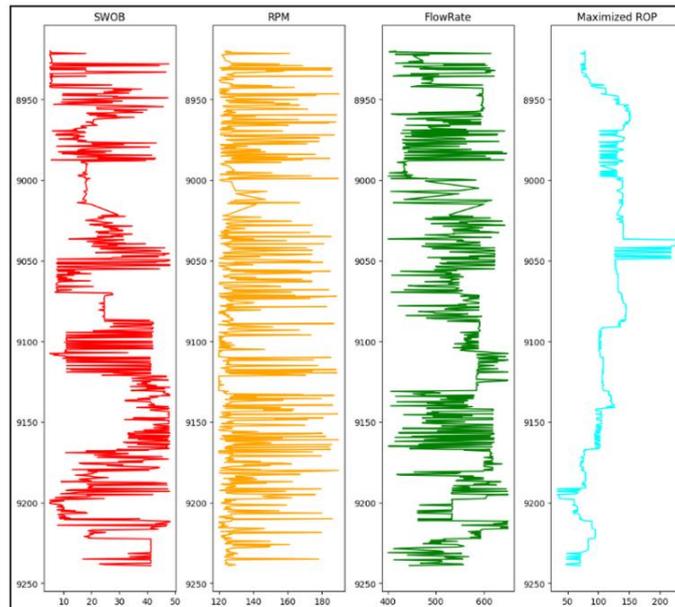
<b>Hasil Optimisasi setelah Uji Kelayakan 12.25”</b>	
Weight on Bit (WOB)	5-35 klbs
Rotation per Minute (RPM)	120-187 rpm
FlowRate	750-1081 gpm
Maximized ROP	42-287 ft/hr

#### 4.3.4 Bagian 8.5”

Pada **Tabel 4.54** berikut, disajikan hasil optimisasi untuk lima belas kedalaman pertama pada bagian 8.5”. Optimisasi yang dilakukan setelah uji kelayakan menggunakan *lower-upper bound* berdasarkan hasil uji kelayakan seperti yang tertera pada **Tabel 4.45**.

**Tabel 4. 57** Data Head Hasil Optimisasi Kedua Bagian 8.5”

<b>Kedalaman (ftMD)</b>	<b>WOB (klbs)</b>	<b>RPM (rpm)</b>	<b>FlowRate (gpm)</b>	<b>ROP (ft/hr)</b>
8920	5	124	416	79
8921	5	127	403	79
8921	5	124	498	79
8922	18	161	615	72
8922	5	125	415	79
8923	5	122	485	79
8923	5	122	453	79
8926	6	124	473	79
8927	6	126	443	79
8927	6	126	473	79
8928	5	127	415	79
8928	48	155	602	72
8929	6	127	516	79
8929	44	169	606	72
8930	5	126	432	79



**Gambar 4. 48** Plot Data Hasil Optimisasi Kedua Bagian 8.5”

Rentang hasil optimisasi pada bagian 12.25” dapat dilihat seperti pada **Tabel 4.55** berikut. Dari **Tabel 4.55** rentang hasil untuk WOB, RPM, dan Flow Rate telah sesuai dengan hasil uji kelayakan sehingga hasil optimisasi dapat dijadikan acuan untuk rencana pemboran di sumur terdekat atau sumur yang memiliki kondisi formasi yang serupa dengan Sumur X Lapangan Mudi.

**Tabel 4. 58** Hasil Optimisasi setelah Uji Kelayakan 8.5”

<b>Hasil Optimisasi setelah Uji Kelayakan 8.5”</b>	
Weight on Bit (WOB)	5-48 klbs
Rotation per Minute (RPM)	120-190 rpm
FlowRate	400-650 gpm
Maximized ROP	33-228 ft/hr

#### **4.4 Analisis Hasil RPM, WOB, dan FlowRate terhadap ROP**

Hasil optimisasi ROP seperti yang dijabarkan pada Sub Bab 4.3 memiliki pengaruh dari ketiga parameter, yaitu RPM, WOB, dan *flowrate*. Nilai optimal ROP yang dihasilkan dianalisis hubungannya dengan ketiga parameter tersebut. Peningkatan nilai WOB dapat meningkatkan nilai ROP karena berat yang lebih besar pada bit dapat meningkatkan daya penetrasi ke dalam formasi batuan. Akan tetapi, terdapat batas optimal untuk WOB, yaitu apabila terlalu tinggi, maka dapat menyebabkan kerusakan pada bit dan peralatan pengeboran

lainnya. Selanjutnya, WOB yang terlalu tinggi juga dapat mengakibatkan biaya yang lebih besar karena adanya peningkatan kebutuhan untuk penggantian bit dan perawatan peralatan, serta potensi kerusakan pada rig. Nilai WOB juga dipengaruhi oleh formasi batuan dari sumur tersebut. Kedalaman sumur dengan formasi keras, memerlukan WOB yang lebih tinggi untuk dapat menembus batuan, tetapi terdapat batas peningkatan WOB, yaitu ketika peningkatan WOB tidak memberikan peningkatan signifikan pada ROP yang menyebabkan keausan pada bit. Kedalaman sumur dengan formasi lunak akan menghasilkan peningkatan ROP yang lebih mudah dengan diberikannya peningkatan WOB, tetapi terlalu tinggi nilai WOB dapat menyebabkan *balling*, yaitu keadaan di mana potongan batuan menempel pada bit sehingga mengurangi efektivitas pemboran.

Peningkatan WOB pada operasi di lapangan, dapat dilakukan melalui beberapa metode, yaitu pengaturan berat *drill string*, pengaturan tension di *drawworks*, penggunaan *hydraulic set-up*, penggunaan *mud motor*, dan pengaturan dengan *sub weight*. Metode utamanya adalah pengaturan berat *drill string* yang dilakukan dengan menambahkan *drill collars* ke *string* atau menambahkan *heavy weight drill pipe* (HDWP) pada *string*. Secara umum, terdapat kecenderungan bahwa semakin dalam kedalaman sumur, maka WOB yang diperlukan juga semakin besar, tetapi hal tersebut tidak selalu berlaku secara linear atau tanpa batas karena terdapat berbagai faktor yang dapat mempengaruhi kebutuhan WOB pada berbagai kedalaman sumur. Data histori yang diperoleh dari operasi pemboran Sumur X Lapangan Mudi menunjukkan bahwa nilai WOB tidak konstan atau linear yang menyebabkan hasil optimisasi seperti yang tertera pada **Tabel 4.55**, **Tabel 4.57**, **Tabel 4.59**, dan **Tabel 4.61** memiliki nilai WOB yang tidak konstan. Hal tersebut dapat terjadi karena adanya beberapa faktor yang dapat terjadi di lapangan, yaitu keadaan formasi yang berubah pada kedalaman tertentu. Misalnya, pada formasi lunak memungkinkan WOB yang lebih rendah untuk menghindari *overdrilling* (kondisi ketika bit pemboran terlalu banyak menekan formasi batuan sehingga menyebabkan penetrasi yang lebih cepat dari yang diinginkan). Selain itu, kondisi bit yang mulai mengalami keausan juga dapat menjadi penyebab penyesuaian pengurangan WOB.

Peningkatan nilai RPM juga dapat meningkatkan nilai ROP karena laju rotasi yang lebih cepat memungkinkan bit untuk menghancurkan batuan lebih cepat. Akan tetapi, seperti WOB, terdapat batas optimal karena RPM yang terlalu tinggi dapat menyebabkan keausan bit dan masalah vibrasi. RPM juga dapat dipengaruhi oleh keadaan formasi batuan, yaitu pada formasi lunak, peningkatan ROP lebih mudah diperoleh dengan RPM yang tinggi karena

batuan dapat mudah dihancurkan oleh bit yang berputar dengan cepat. Akan tetapi, RPM yang terlalu tinggi dapat menyebabkan vibrasi yang mengurangi efektivitas pemboran dan merusak bit. Selain itu, pada formasi keras, RPM yang tinggi cenderung dibutuhkan untuk meningkatkan nilai ROP. Parameter ketiga adalah *flowrate*. *Flowrate* yang lebih tinggi dapat membantu dalam membersihkan *cuttings* dari lubang bor dengan lebih efisien, yang dapat meningkatkan ROP. Akan tetapi, *flowrate* yang terlalu tinggi dapat menyebabkan masalah erosional pad abut dan dinding lubang bor. *Flowrate* juga dapat dipengaruhi oleh keadaan formasi batuan dari sumur. *Flowrate* yang lebih tinggi dibutuhkan pada formasi batuan yang lebih keras untuk membawa *cuttings* dengan *density* yang lebih besar.

#### 4.5 Hasil Perhitungan Waktu Pemboran Hasil Optimisasi

Perhitungan waktu pemboran dilakukan menggunakan ROP hasil optimisasi. ROP hasil optimisasi akan mempengaruhi *rotating time* dari waktu pemboran tersebut, sedangkan untuk *trip time* dan *connection time* menyesuaikan dengan keadaan aktual pemboran Sumur X Lapangan Mudi.

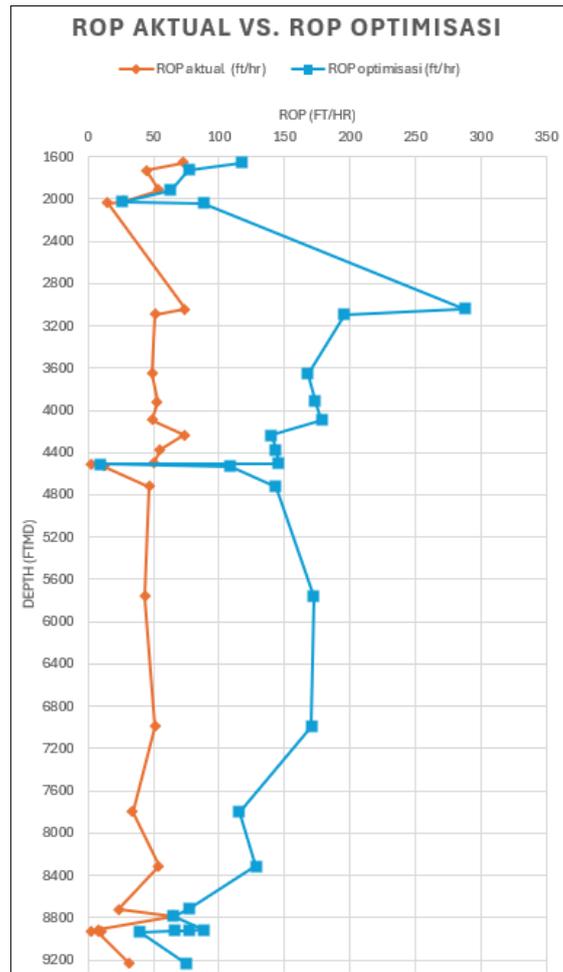
**Tabel 4. 59** Hasil Perhitungan Waktu Pemboran menggunakan ROP Hasil Optimisasi

<i>Depth (ftMD)</i>	<i>Connection/Trip Time (hours)</i>	<i>Rotating Time (hours)</i>	<i>ROP (ft/hr)</i>	<i>Total Days</i>
132	9	-	-	0.58
132-1660	-	13	117.54	1.13
1660-1727	-	0.87	77.01	1.16
1727-1916	-	3	63	1.29
1916	1	-	-	1.33
1916-2023	-	4	26.75	1.49
2023	141.37	-	-	5.89
2023-2038	-	0.17	88.24	5.90
2038	2	-	-	5.98
2038-3044	-	3.5	287.43	6.13
3044-3095	-	0.26	196.15	6.14
3095	0.26	-	-	6.16
3095-3656	-	3.35	167.46	6.30
3656	3.35	-	-	6.36
3656-3920	-	1.52	173.68	6.42
3920	0.5	-	-	6.44
3920-4091	-	0.96	178.13	6.48
4091	0.5	-	-	6.51
4091-4238	-	1.05	140	6.55

**Tabel 4. 59** Hasil Perhitungan Waktu Pemboran menggunakan ROP Hasil Optimisasi

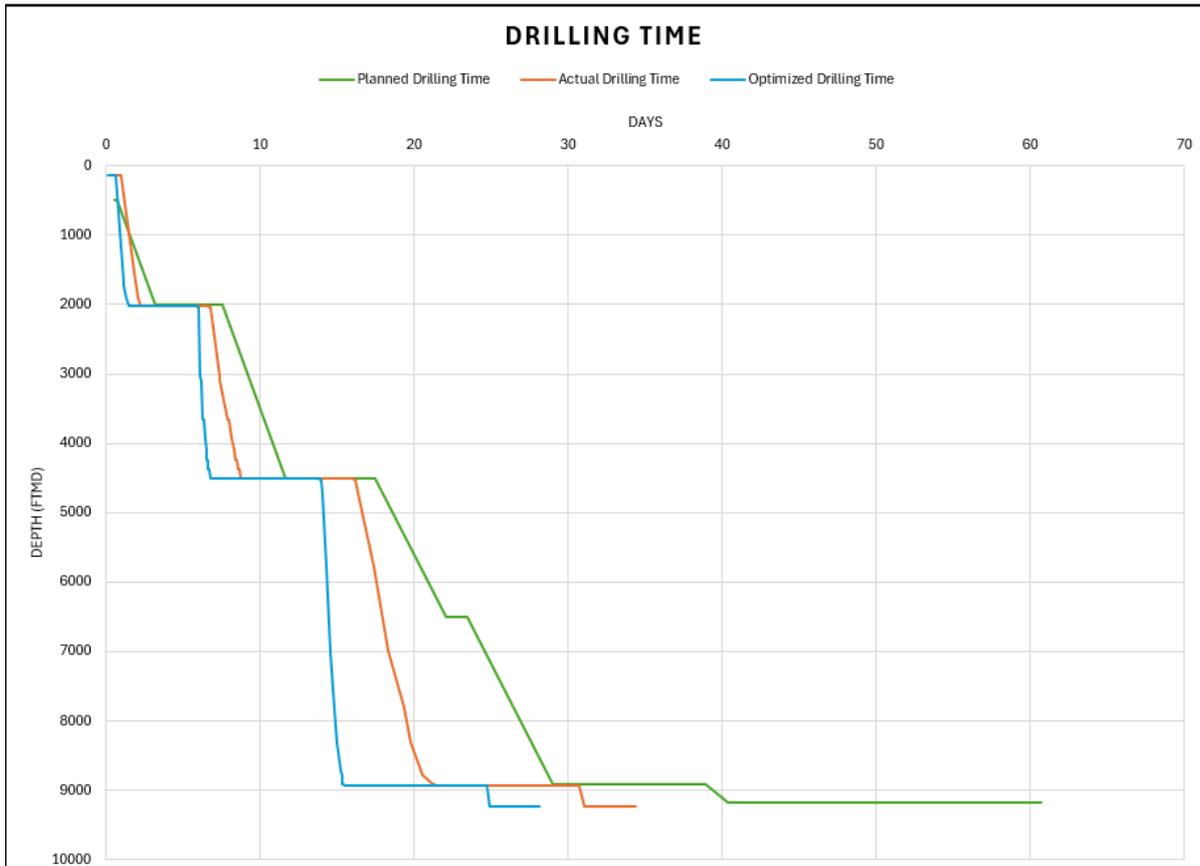
<i>Depth (ftMD)</i>	<i>Connection/Trip Time (hours)</i>	<i>Rotating Time (hours)</i>	<i>ROP (ft/hr)</i>	<i>Total Days</i>
4238	1	-	-	6.59
4238-4376	-	0.96	143.75	6.63
4376	1.5	-	-	6.69
4376-4500	-	0.85	145.88	6.73
4500	167	-	-	13.69
4500-4510	-	1	10	13.73
4510	3	-	-	13.85
4510-4534	-	0.22	109.09	13.86
4534	2	-	-	13.95
4534-4721	-	1.3	143.85	14.00
4721-5762	-	6.05	172.07	14.25
5762-6991	-	7.2	170.69	14.55
6991-7801	-	7	115.71	14.84
7801-8314	-	4	128.25	15.01
8314-8721	-	5.3	76.79	15.23
8721	0.5	-	-	15.25
8721-8786	-	1	65	15.29
8786-8918	-	1.5	88	15.36
8918	2	-	-	15.44
8918-8928	-	0.13	76.92	15.45
8928	220.5	-	-	24.63
8928-8930	-	0.03	66.67	24.63
8930	1	-	-	24.68
8930-8938	-	0.2	40	24.68
8938-9239	-	4	75.25	24.85
9239	79	-	-	28.14

Perbandingan hasil ROP aktual dengan ROP hasil optimisasi dapat dilihat pada **Gambar 4.45** berikut.



**Gambar 4. 49** Perbandingan ROP Aktual dan ROP Optimisasi

Waktu pemboran yang dihabiskan dengan menggunakan ROP hasil optimisasi adalah 28 hari atau lebih cepat 6.2 hari dari waktu pemboran aktual yang menempuh 34 hari dan lebih cepat 32 hari dari perencanaan waktu pemboran yang memakan waktu sebanyak 60 hari pada Sumur X Lapangan Mudi.



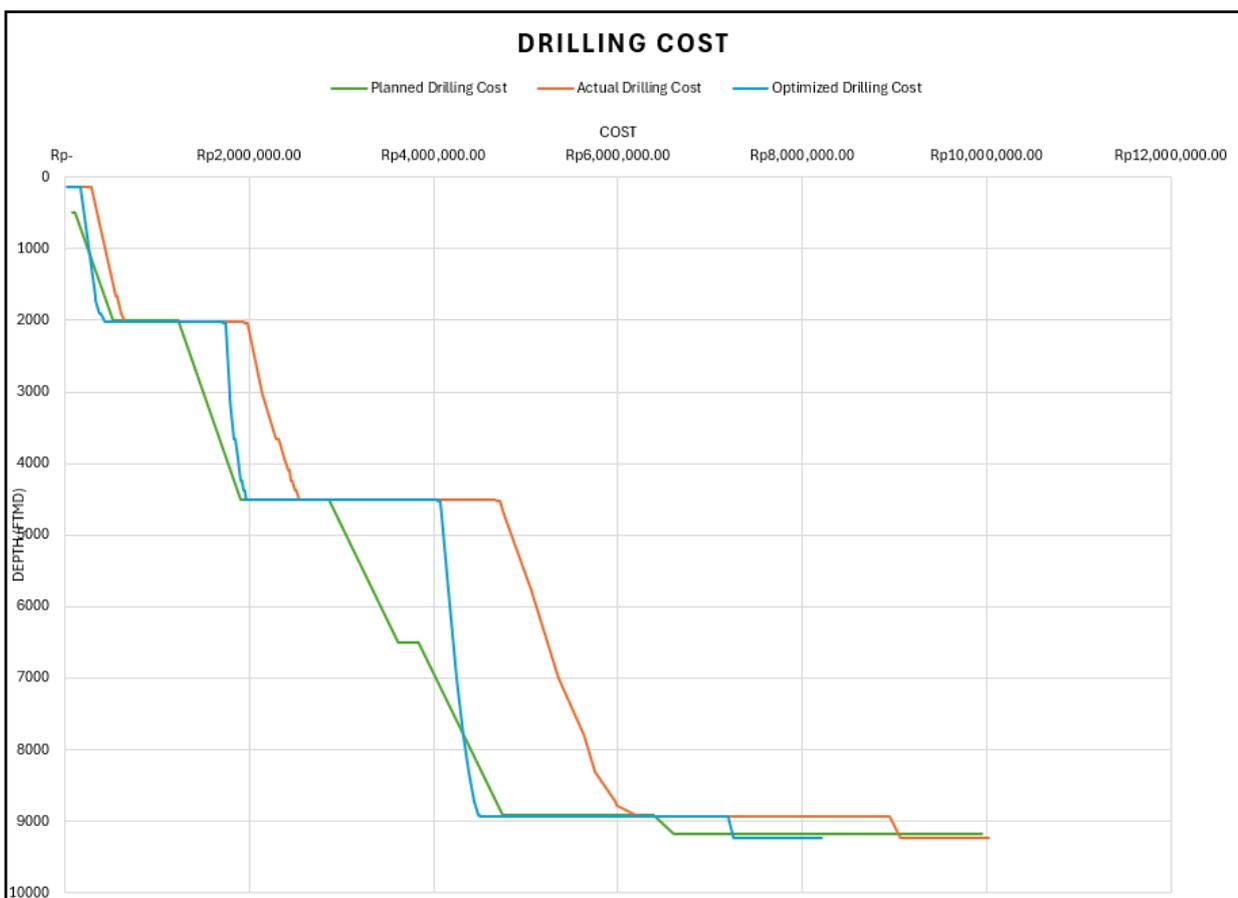
**Gambar 4. 50** Grafik Perbandingan antara *Planned*, *Actual*, dan *Optimized* Waktu Pemboran

**Tabel 4. 60** Ringkasan Perbandingan Waktu Pemboran

Kondisi	Waktu Pemboran (Hari)
Perencanaan	60
Aktual	34
Optimisasi	28

#### 4.6 Hasil Perhitungan Biaya Pemboran Hasil Optimisasi

Biaya pemboran yang dihabiskan dengan menggunakan ROP hasil optimisasi adalah Rp9,594,125.07 atau lebih murah Rp1,812,531.93 dari biaya pemboran aktual sebesar Rp11,406,657.00 dan lebih murah Rp2,428,640.39 dari perencanaan biaya pemboran sebesar Rp12,022,766.00 pada Sumur X Lapangan Mudi. Total biaya pemboran ini merupakan penjumlahan dari *tangible cost* sebesar Rp1,387,795.00 dan *intangible cost* sebesar Rp8,206,330.07. Hasil optimisasi berhasil menurunkan biaya pemboran sebesar 16% dari biaya pemboran aktual Sumur X Lapangan Mudi.



**Gambar 4. 51** Grafik Perbandingan antara *Planned*, *Actual*, dan *Optimized* Biaya Pemboran

**Tabel 4. 61** Ringkasan Perbandingan Biaya Pemboran

Kondisi	Biaya Pemboran (Rp)
Perencanaan	Rp12,022,766.00
Aktual	Rp11,406,657.00
Optimisasi	Rp9,594,125.07

## BAB V

### KESIMPULAN DAN SARAN

#### 5.1 Kesimpulan

Penelitian tugas akhir ini memiliki beberapa kesimpulan sebagai berikut:

- Hasil perbandingan simulasi model ROP menggunakan *predictive modelling* dan model Bingham menunjukkan bahwa algoritma *Random Forest Regressoion* merupakan algoritma dengan keakuratan yang paling tinggi apabila dibandingkan dengan keempat algoritma lainnya (*Gradient Boosting*, *K-Nearest Neighbor*, *Support Vector Regression*, dan Bingham) dengan nilai  $R^2$  tertinggi, yaitu 0.92 pada simulasi bagian 12.25”.
- Particle Swarm Optimization (PSO) telah berhasil diaplikasikan untuk mengoptimalkan nilai ROP dengan *decision variable*, yaitu RPM, WOB, dan *Flowrate*. Model ROP yang digunakan adalah *Random Forest Regression*. *Hyperparamter* yang digunakan adalah *swarmsize* = 200, *omega* = 0.3, *phip* = 0.5, *phig* = 0.5, dan *maxiter* = 200.
- Hasil perhitungan biaya pemboran yang dihabiskan dengan menggunakan ROP hasil optimisasi adalah Rp9,594,125.07 atau lebih murah Rp1,812,531.93 dari biaya pemboran aktual dan lebih murah Rp2,428,640.39 dari perencanaan biaya pemboran pada Sumur X Lapangan Mudi. Hasil perhitungan waktu pemboran yang dihabiskan dengan menggunakan ROP hasil optimisasi adalah 28 hari atau lebih cepat 6.2 hari dari waktu pemboran aktual dan lebih cepat 32 hari dari perencanaan waktu pemboran pada Sumur X Lapangan Mudi.

#### 5.2 Saran

Penelitian tugas akhir ini memiliki beberapa saran sebagai berikut:

- Untuk penelitian selanjutnya, dapat dicoba menggunakan data Sumur lain atau lebih dari satu Sumur sehingga metode dapat lebih tervalidasi.
- Untuk penggunaan langsung di lapangan, simulasi optimisasi dapat langsung menggunakan *lower-upper bound* yang sudah tervalidasi melalui uji kelayakan sehingga tidak perlu melakukan dua kali proses optimisasi.



## DAFTAR PUSTAKA

- Alkinani, H.H. et al. (2019) 'Examination of the relationship between rate of penetration and mud weight based on unconfined compressive strength of the rock,' *Journal of King Saud University - Science*, 31(4), pp. 966–972. <https://doi.org/10.1016/j.jksus.2018.07.020>.
- Alsaihati, A., Elkatatny, S. and Gamal, H. (2022) 'Rate of penetration *prediction* while drilling vertical complex lithology using an ensemble learning model,' *Journal of Petroleum Science and Engineering*, 208, p. 109335. <https://doi.org/10.1016/j.petrol.2021.109335>.
- Amit, Y. and Geman, D. (1997) 'Shape Quantization and Recognition with Randomized Trees,' *Neural Computation*, 9(7), pp. 1545–1588. <https://doi.org/10.1162/neco.1997.9.7.1545>.
- Breiman, L. (2001) 'Random Forests,' *Machine Learning*, 45(1), pp. 5–32. <https://doi.org/10.1023/a:1010933404324>.
- Chen, P.-H., Fan, R.-E. and Lin, C.-J. (2006) 'A study on SMO-Type Decomposition Methods for support vector Machines,' *IEEE Transactions on Neural Networks*, 17(4), pp. 893–908. <https://doi.org/10.1109/tnn.2006.875973>.
- De Buck, V. et al. (2019) 'Multi-objective optimisation of chemical processes via improved genetic algorithms: A novel trade-off and termination criterion,' in *Computer-aided chemical engineering*, pp. 613–618. <https://doi.org/10.1016/b978-0-12-818634-3.50103-x>.
- Fan, R.-E., Chen, P.-H. and Lin, C.-J. (2005) 'Working set selection using second order information for training support vector machines,' *Journal of Machine Learning Research*, 6(63), pp. 1889–1918. <http://jmlr.csail.mit.edu/papers/volume6/fan05a/fan05a.pdf>.
- Flake, P. et al. (2020) 'Verilog HDL and its ancestors and descendants,' *Proceedings of the ACM on Programming Languages*, 4(HOPL), pp. 1–90. <https://doi.org/10.1145/3386337>.
- Hegde, C. et al. (2017) 'Analysis of rate of penetration (ROP) *prediction* in drilling using physics-based and data-driven models,' *Journal of Petroleum Science and Engineering*, 159, pp. 295–306. <https://doi.org/10.1016/j.petrol.2017.09.020>.

- Heinemann, R. (2019) 'Drilling,' in Springer eBooks, pp. 528–534. [https://doi.org/10.1007/978-3-662-53120-4\\_6601](https://doi.org/10.1007/978-3-662-53120-4_6601).
- Hooshyari, M. et al. (2018) 'D-Optimal Design and PARAFAC as Useful Tools for the Optimisation of Signals from Fluorescence Spectroscopy Prior to the Characterisation of Green Tea Samples,' *Food Analytical Methods*, 12(3), pp. 761–772. <https://doi.org/10.1007/s12161-018-01408-0>.
- Hoseinpour, M. and Riahi, M.A. (2021) 'Determination of the mud weight window, optimum drilling trajectory, and Sumurbore stability using geomechanical parameters in one of the Iranian hydrocarbon reservoirs,' *Journal of Petroleum Exploration and Production Technology*, 12(1), pp. 63–82. <https://doi.org/10.1007/s13202-021-01399-5>.
- Huang, T.-M. (2010) Kernel based algorithms for mining huge data sets: supervised, semi-supervised, and unsupervised learning. <http://ci.nii.ac.jp/ncid/BA77316463>.
- Hyne, N.J. (1995) Nontechnical guide to petroleum geology, exploration, drilling & production. <http://www.gbv.de/dms/goettingen/222911786.pdf>.
- Katoch, S., Chauhan, S.S. and Kumar, V. (2020) 'A review on genetic algorithm: past, present, and future,' *Multimedia Tools and Applications*, 80(5), pp. 8091–8126. <https://doi.org/10.1007/s11042-020-10139-6>.
- Khalilidermani, M. and Knez, D. (2023) 'A survey on the shortcomings of the current rate of penetration predictive models in petroleum engineering,' *Energies*, 16(11), p. 4289. <https://doi.org/10.3390/en16114289>.
- Lakatos, I. and Lakatos-Szabó, J. (2012) 'Reservoir conformance Control in Oilfields Using Silicates: State-of-the-Arts and Perspectives,' *All Days* [Preprint]. <https://doi.org/10.2118/159640-ms>.
- Mahdavinejad, M.S. et al. (2018) 'Machine learning for internet of things data analysis: a survey,' *Digital Communications and Networks*, 4(3), pp. 161–175. <https://doi.org/10.1016/j.dcan.2017.10.002>.
- Mahmoud, M. and Gomaa, I. (2022) 'Sandstone matrix stimulation,' in Elsevier eBooks, pp. 341–386. <https://doi.org/10.1016/b978-0-12-822721-3.00004-6>.
- Mohamed, A., Salehi, S. and Ahmed, R. (2021) 'Significance and complications of drilling fluid rheology in geothermal drilling: A review,' *Geothermics*, 93, p. 102066. <https://doi.org/10.1016/j.geothermics.2021.102066>.
- Moraveji, M.K. and Naderi, M. (2016) 'Drilling rate of penetration *prediction* and optimization using response surface methodology and bat algorithm,' *Journal of*

- Natural Gas Science and Engineering, 31, pp. 829–841.  
<https://doi.org/10.1016/j.jngse.2016.03.057>.
- Pacis, F.J. et al. (2023) 'Improving predictive models for rate of penetration in real drilling operations through transfer learning,' *Journal of Computational Science*, 72, p. 102100. <https://doi.org/10.1016/j.jocs.2023.102100>.
- Platt, J. (1998) 'Sequential Minimal Optimization : a fast algorithm for training support vector machines,' Microsoft Research Technical Report, p. 21.  
<http://recognition.mccme.ru/pub/papers/SVM/smoTR.pdf>.
- Samuel, A.L. (2000) 'Some studies in machine learning using the game of checkers,' *IBM Journal of Research and Development*, 44(1.2), pp. 206–226.  
<https://doi.org/10.1147/rd.441.0206>.
- Shi, Y. et al. (2019) 'Analysis on the weight-on-bit transmission efficiency of the static push-the-bit rotary steerable system,' *Natural Gas Industry B* [Preprint].  
<https://doi.org/10.1016/j.ngib.2018.11.016>.
- Tian, J. et al. (2018) 'Working mechanism and rock-breaking characteristics of coring *drill bit*,' *Journal of Petroleum Science and Engineering*, 162, pp. 348–357.  
<https://doi.org/10.1016/j.petrol.2017.12.047>.
- Tyralis, H., Papacharalampous, G. and Langousis, A. (2019) 'A brief review of random forests for water scientists and practitioners and their recent history in water resources,' *Water*, 11(5), p. 910. <https://doi.org/10.3390/w11050910>.
- Vega, M.P., Freitas, M. and Martins, A.L. (2014) 'MIMO Control during Oil Sumur Drilling,' in *Computer-aided chemical engineering*. <https://doi.org/10.1016/b978-0-444-63456-6.50122-8>.
- Yang, X.-S. (2011) 'Optimization algorithms,' in *Springer eBooks*, pp. 13–31.  
[https://doi.org/10.1007/978-3-642-20859-1\\_2](https://doi.org/10.1007/978-3-642-20859-1_2).
- Zhou, Y., Chen, X., Fukushima, E.F., et al. (2021) 'An online hybrid *prediction* model for mud pit volume in the complex geological drilling process,' *Control Engineering Practice*, 111, p. 104793. <https://doi.org/10.1016/j.conengprac.2021.104793>.
- Zhou, Y., Chen, X., Wu, M., et al. (2021) 'Modeling and coordinated optimization method featuring coupling relationship among subsystems for improving safety and efficiency of drilling process,' *Applied Soft Computing*, 99, p. 106899.  
<https://doi.org/10.1016/j.asoc.2020.106899>.
- Westbrook, M. H. (2005). *Development*

*and future of battery, hybrid, and fuel-cell cars.* London: The Institution of Electrical Engineers.

## LAMPIRAN

### A. Deskripsi Aktivitas Operasi Pemboran Sumur X Lapangan Mudi

#### Bagian 26”

Section	No.	Descriptions	Plan				Actual			
			Hours	Days	Cummulative Days	Depth MD (ft)	Hours	Days	Cummulative Days	Depth MD (ft)
26" Hole Section	1	Rig On Mobilization Point	0	0	0	0	0	0	0	0
	2	Rig move from Mobilization Point to Well location	0	0	0	0	0	0	0	0
	3	Rigging up, Rig inspection and commissioning operation.	0	0	0	0	0	0	0	0
	4	Drill 26" Rat Hole to 500 ftMD. Control drilling to keep well vertical.	13	1	1	500	17	1	1	502
	5	Sweep hole with hi-vis and circulate hole clean.	1	0	1	500	0	0	1	502
	6	POOH 26" Steerable BHA to last casing shoe.	1	0	1	500	0	0	1	502
	7	Continue M/U 26" Bit + BHA and RBH to bottom. Perform MWD shallow test.	2	0	1	500	0	0	1	502
	8	Drill 26" Hole to proposed section TD at 2000 ftMD/TVD.	60	3	3	2000	44	2	3	2023
	9	Pump Hi-vis sweep and circulate hole clean.	1	0	3	2000	1	0	3	2023
	10	Drop carbide, sweep hi-dens, and circulate hole clean at least 2 times bottoms up.	2	0	3	2000	3	0	3	2023
	11	POOH 26" Steerable BHA to surface and L/D DD,MWD	10	0	4	2000	11	0	3	2023
	12	R/U Casing Running equipment and function test same.	3	0	4	2000	3	0	3	2023
	13	P/U and M/U shoe track joints and test floats equipment.	3	0	4	2000	4	0	3	2023
	14	M/U and RIH 20" Casing as per casing tally.	20	1	5	2000	16	1	4	2023
	15	Circulate hole at least 2 times bottoms up.	2	0	5	2000	4	0	4	2023
	16	R/U cementing line and pressure test same.	2	0	5	2000	1	0	4	2023
	17	Perform 20" Casing Cementing as per program.	5	0	5	2000	5	0	4	2023
	18	WOC.	12	1	6	2000	12	1	5	2023
	19	N/D bell nipple and Diverter. Perform final cut on 30" and 20" casing and lay out excess. R/D CRT.	6	0	6	2000	12	1	5	2023
	20	N/U Wellhead section A. Perform pressure test seals. N/U riser and mud cross.	2	0	6	2000	12	1	6	2023
	21	N/U 21-1/4" x 2K BOP Stack. N/U bell nipple, install HCR valves, kill line, and flexible hose to BPM. P/U TDS link and elevator.	6	0	6	2000	1	0	6	2023
	22	Install test plug. Perform pressure test connection from BOP to Wellhead.	3	0	6	2000	1	0	6	2023
	23	Perform Function Test 21-1/4" x 2K BOP.	3	0	7	2000	1	0	6	2023
	24	Retrieve test plug and install wear bushing.	1	0	7	2000	1	0	6	2023
	25	Install flow line at bell nipple and v-door while P/U 17-1/2" BHA to RF.	4	0	7	2000	3	0	6	2023

**Bagian 17.5”**

17.5" Hole Section	26	M/U & R/H 17-1/2" Steerable BHA + DD+MWD to tag TOC. Perform choke drill.	11	0	7	2000	11	0	7	2023
	27	Drill out shoe track joints, test floats equipment, and cement.	6	0	7	2000	8	0	7	2023
	28	Drill 10 ft new formation, circulate hole. Perform FIT.	2	0	8	2010	6	0	7	2023
	29	Drill 17-1/2" Hole to proposed section TD at 4500 #MD/TVD.	100	4	12	4500	55	2	9	4500
	30	Pump Hi-vis sweep and circulate hole clean.	1	0	12	4500	3	0	10	4500
	31	Perform Wiper Trip to 20" casing shoe at 2000 #MD/TVD.	18	1	12	4500	7	0	10	4500
	32	Drop carbide, sweep hi dens, and circulate hole clean at least 2 times bottoms up.	4	0	13	4500	1	0	10	4500
	33	POOH 17-1/2" Steerable BHA to surface and rack back.	9	0	13	4500	9	0	10	4500
	34	R/U Casing Running equipment and function test same.	3	0	13	4500	2	0	10	4500
	35	P/U and M/U shoe track joints and test floats equipment.	3	0	13	4500	2	0	10	4500
	36	M/U and R/H 13-3/8" Casine as per casine tally.	30	1	15	4500	19	1	11	4500
	37	Circulate hole at least 2 times bottoms up.	2	0	15	4500	2	0	11	4500
	38	R/U cementine line and pressure test same.	2	0	15	4500	1	0	11	4500
	39	Perform 13-3/8" Casine Cementine as per program.	5	0	15	4500	7	0	12	4500
	40	WOC.	12	1	15	4500	12	0	12	4500
	41	Rough cut 13-3/8" casine and lay out same.	2	0	15	4500	0	0	12	4500
	42	N/D 21-1/4" x 2K BOP Stack. Set casing hanger slip, final cut 13-3/8" Casine.	6	0	16	4500	18	1	13	4500
	43	N/U Wellhead section B. Perform pressure test seals. N/U 13-5/8" x 5K BOP Stack. N/U bell nipple, install HCR valves, kill line, and flexible hose to BPM.	6	0	16	4500	9	0	14	4500
	44	Install test plug. Perform pressure test connection from BOP to Wellhead.	1	0	16	4500	2	0	14	4500
	45	Perform Function Test 13-5/8" x 5K BOP.	9	0	16	4500	2	0	14	4500
46	Retrieve test plug and install wear bushing.	1	0	17	4500	1	0	14	4500	
47	Reinstall v door, N/U Bell Nipple & Flowline.	4	0	17	4500	3	0	14	4500	

**Bagian 12.25”**

12.25" Hole Section	49	M/U and R/H 12-1/4" Milltooth Bit + DD+ MWD BHA Steerable BHA to tag TOC. Perform choke drill.	11	0	17	4500	47	2	16	4500
	50	Drill out shoe track joints, test floats equipment, and cement.	6	0	17	4500	14	1	17	4500
	51	Drill 10 ft new formation, circulate hole. Perform FIT.	2	0	17	4510	4	0	17	4510
	52	Drill 12-1/4" Hole to penetrate Marl Fm to approximately 6500 #MD	111	5	22	6500	153	6	23	8928
	53	CBU to verify cuttine sample prior to Tuban Fm	2	0	22	6500	0	0	23	8928
	54	Pump Hi-vis sweep and circulate hole clean.	2	0	22	6500	0	0	23	8928
	55	POOH 12-1/4" Bit + BHA to surface. Rack back.	14	1	23	6500	0	0	23	8928
	56	M/U 12-1/4" PDC Bit + BHA and R/H to bottom.	14	1	23	6500	0	0	23	8928
	57	Continue Drill 12-1/4" Hole from 6500 #MD to section TD. Control drilline to penetrate Top Tuban Fm.	134	6	29	8919	0	0	23	8928
	58	CBU to verify cuttine sample prior to Tuban Fm	2	0	29	8919	0	0	23	8928
	59	Pump Hi-vis sweep and circulate hole clean.	2	0	29	8919	2	0	23	8928
	60	Perform Wiper Trip to 13-3/8" casing shoe at 4500 #MD/TVD.	22	1	30	8919	3	0	23	8928
	61	Drop carbide, sweep hi dens, circulate hole clean at least 2 times bottoms up.	4	0	30	8919	0	0	23	8928
	62	POOH 12-1/4" BHA to 13-3/8" casing shoe at 4500 #MD/TVD.	11	0	31	8919	15	1	24	8928
	63	Slip drilline line.	2	0	31	8919	0	0	24	8928
	64	Continue POOH 12-1/4" BHA from 13-3/8" casing shoe to surface and rack back.	18	1	32	8919	12	0	24	8928
	65	R/U Casing Running equipment and function test same.	3	0	32	8919	4	0	24	8928
	66	P/U and M/U shoe track joints and test floats equipment.	3	0	32	8919	2	0	25	8928
	67	M/U and R/H 9-5/8" Casine as per casine tally.	30	1	33	8919	25	1	26	8928
	68	Circulate hole at least 2 times bottoms up.	2	0	33	8919	2	0	26	8928
	69	R/U cementine line and pressure test same.	2	0	33	8919	1	0	26	8928
	70	Perform 9-5/8" Casine Cementine as per program.	5	0	33	8919	7	0	26	8928
	71	WOC.	12	1	34	8919	22	1	27	8928
	72	Rough cut 9-5/8" casine and lay out same.	2	0	34	8919	2	0	27	8928
	73	N/D 13-5/8" x 5K BOP Stack. Set casing hanger slip, final cut 9-5/8" Casine.	6	0	34	8919	10	0	27	8928
	74	N/U Wellhead section C. Perform pressure test seals. N/U 13-5/8" x 5K BOP Stack. N/U bell nipple, install HCR valves, kill line, and flexible hose to BPM.	6	0	35	8919	19	1	28	8928
75	Install test plug.	1	0	35	8919	2	0	28	8928	
76	Reinstall v door, N/U Bell Nipple & Flowline.	4	0	35	8919	2	0	28	8928	

## Bagian 8.5”

NO	DESCRIPTION OF WORK	NO	QTY	UNIT	EST. COST	NO	QTY	UNIT	EST. COST
77	M/U 8-1/2" Steerable BHA and RIH to tag TOC. Perform choke drill.	18	1	35	8919	13	1	29	8928
78	Drill out shoe track joints, test floats equipment, and cement to approx 20 ft before 9-5/8" float shoe.	0	0	35	8919	4	0	29	8928
79	Displace HPWBM to RDIF as per program.	2	0	36	8919	4	0	29	8928
80	DOC. Sweep H/vis.	8	0	36	8919	2	0	29	8928
81	POOH 8-1/2" DOC BHA to inside 9-5/8" casing. Perform H2S and abandon drill.	6	0	36	8919	5	0	29	8928
82	POOH 8-1/2" DOC BHA from inside 9-5/8" casing to surface.	7	0	36	8919	6	0	30	8928
83	Stab-in 5-1/2" DP to RCD bearing.	1	0	36	8919	1	0	30	8928
84	M/U 9-5/8" scrapper BHA and RIH till 8852 ftMD	10	0	37	8919	9	0	30	8928
85	Scrape 8852 ftMD - 8918 ftMD.	1	0	37	8919	1	0	30	8928
86	POOH Scrapper 9-5/8" Scrapper BHA 8918 ftMD to surface.	14	1	37	8919	11	0	31	8928
87	R/U Wireline and FT GR-CCL-CBL tool	2	0	38	8919	2	0	31	8928
88	RIH Run#1GR-CCL-CBL to TOC	5	0	38	8919	6	0	31	8928
89	B/O & L/D GR-CCL-CBL	1	0	38	8919	1	0	31	8928
90	M/U & F/T e-log Run#2: Gvro Survey Tool	1	0	38	8919	1	0	31	8928
91	RIH e-log Run#2: Gvro to 8900 ftMD	2	0	38	8919	2	0	31	8928
92	POOH Gvro Tool to surface. B/O & L/D.	3	0	38	8919	4	0	31	8928
93	M/U & F/T e-log Run#3: GR-DSN	1	0	38	8919	1	0	31	8928
94	RIH e-log Run#3: GR-DSN to 8900 ftMD	4	0	38	8919	2	0	31	8928
95	POOH e-line GR-DSN to surface. B/O & L/D.	3	0	38	8919	3	0	31	8928
96	M/U 1-2 Steerable BHA and RBH to tag TOC. Perform Choke Drill.	10	0	39	8919	15	1	32	8928
97	Mud conditioning Salt Polymer 9.0 ppg. Drill out shoe track cement and reamer shoe	3	0	39	8919	5	0	32	8928
98	Drill 8-1/2" Hole to proposed Well TD at@ 9169 ftMD/ 8770 ftVD	33	1	40	9169	13	1	33	9239
99	Pump Hi-vis sweep and circulate hole clean.	2	0	40	9169	2	0	33	9239
100	Perform Wiper Trip to 9-5/8" casing shoe @ 8884 ftMD/ 8461 ftVD	1	0	40	9169	4	0	33	9239
101	Pump Hi-vis sweep and circulate hole clean.	2	0	41	9169	1	0	33	9239
102	POOH 8-1/2" BHA to surface.	18	1	41	9169	12	0	33	9239
103	R/U, M/U and RIH E-log tools. GR-Density-Neutron-Resistivity-Sonic.	4	0	41	9169	4	0	34	9239
104	Run Logline (Log up #1 & #2).	12	1	42	9169	2	0	34	9239
105	POOH E-log tools to surface.	3	0	42	9169	4	0	34	9239
106	Prepare and M/U wireline logging tool (GR-Res-Den-Neu-Son) on PCL mode.	4	0	42	9169	0	0	34	9239
107	RIH wireline logging tool to proposed depth, CBU. M/U tools to Strine stab + SES + wet connector.	26	1	43	9169	0	0	34	9239
108	Run Logging (Log up #1 & #2 for approx 1000 ft interval).	6	0	44	9169	0	0	34	9239
109	Break out SES, L/D Wireline logging equipment (sinker bar, SES, Sheave).	2	0	44	9169	0	0	34	9239
110	POOH wireline logline tools PCL to surface.	18	1	44	9169				

**B. Detail Biaya Pemboran Sumur X Lapangan Mudi**

<i>Tangible Cost</i>	<i>Intangible Drilling Cost</i>
<b>Casing</b>	Preparation and Termination
30", X-52, 310 ppf, SAW/ERW, R3	Drilling/ Workover Operations
20", K-55, 106.5 ppf, BTC, R3	Formation Evaluation
13-3/8", L-80, 68 ppf, BTC, R3	
9-5/8", L-80, 47 ppf, BTC, R3	
7", L-80, 26 ppf, BTC, R3	
13-3/8" Pup Joint, L-80, 68 ppf, BTC, R3	
9-5/8" Pup Joint, L-80, 47 ppf, BTC, R3	
7" Pup Joint, L-80, 26 ppf, BTC, R3	
<b>Casing Accessories</b>	
Float Shoe	
Stringer	
Drill Pipe Centralizer	
Bow Centralizer	
Stop Collar	
Reamer Shoe	
Float Collar	
Centralizer Spiroglider	
Top Plug	
Bottom Plug	
Liner Hanger	
<b>Tubing</b>	
3-1/2", L-80, 9.2 ppf, BTC, R2	
3-1/2" Pup Joint, L-80, 9.2 ppf, BTC, R2 (6 ft)	
3-1/2" Pup Joint, L-80, 9.2 ppf, BTC, R2 (8 ft)	
3-1/2" Pup Joint, L-80, 9.2 ppf, BTC, R2 (10 ft)	
<b>Sumur Equipment Surface</b>	
Sumurhead	
Section A Casing Head Assy, 21-1/4"-2M Flange Top x 20" SOL Bottom	
Section B Casing Spool Assy, 21-1/4"-2M Flange Bottom x 13-5/8"-5M Flange Top	

Section C Tubing Spool Assy, 13-5/8"-5M Flange Bottom x 11"-5M Flange Top	
Section D Tubing Hanger Assy	
X-mass Tree	
X-mass Tree Assy	
<b>Sumur Equipment Subsurface</b>	
ESP	
ESP Cable	

### C. Kode Python *Random Forest Regressor* + PSO

```

from sklearn.ensemble import RandomForestRegressor
from sklearn.model_selection import train_test_split
from sklearn.metrics import mean_squared_error, r2_score
import pandas as pd
import numpy as np
from tqdm import tqdm
import matplotlib.pyplot as plt
!pip install pyswarm
import pyswarm as pso
from pyswarm import pso
from google.colab import drive
drive.mount('/content/gdrive')

# Membaca dataset
df = pd.read_excel("/content/.xlsx")

# Memilih Predictor dan target
X = df[['DEPT', 'SWOB', 'RPM', 'FlowRate']]
y = df['ROP']

# Membagi data menjadi data latih dan data uji
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3,
random_state=42)

# Menginisialisasi model RandomForestRegressor
model_rf = RandomForestRegressor(n_estimators = 300, min_samples_split = 2,
min_samples_leaf = 1, max_depth = 30, bootstrap = true)

# Melatih model
model_rf.fit(X_train, y_train)

# Memprediksi nilai untuk data uji
predictions_rf = model_rf.predict(X_test)

```

```

# Plot nilai sebenarnya vs. prediksi
plt.scatter(y_test, predictions_rf, alpha=0.5)
plt.xlabel("True values")
plt.ylabel("Predictions")
plt.title("True values vs. Predictions (Random Forest)")
plt.show()

# Membuat DataFrame untuk data uji beserta prediksi ROP
predictions_df_rf = pd.DataFrame(X_test, columns=['DEPT', 'SWOB', 'RPM',
'FlowRate'])
predictions_df_rf['Actual ROP'] = y_test.values
predictions_df_rf['Predicted ROP (Random Forest)'] = predictions_rf

# Kelompokkan data berdasarkan DEPTH
depth_groups = df.groupby('DEPTH')

# Inisialisasi list untuk menyimpan hasil optimisasi
optimization_results = []

# Proses optimisasi untuk setiap kelompok DEPTH
for depth, group in tqdm(depth_groups):
    # Memilih fitur dan target untuk kelompok saat ini
    X_group = group[['DEPT', 'SWOB', 'RPM', 'FlowRate']]
    y_group = group['ROP']

    # Definisikan fungsi f(X) untuk optimisasi
    def f_group(X):
        # Convert X to DataFrame with feature names
        X_df = pd.DataFrame(X.reshape(1, -1), columns=['DEPT', 'SWOB',
'RPM', 'FlowRate'])
        return -model_rf.predict(X_df) # Minus sign to optimize

    # Tentukan batas bawah dan atas untuk optimisasi
    lb_group = np.array([depth, 5, 120, 750])
    ub_group = np.array([depth, 35, 130, 1000], dtype=np.float64)
    ub_group += 1e-10

    # Lakukan optimisasi menggunakan PSO pada kelompok saat ini
    Xopt_group, fopt_group = pso(f_group, lb_group, ub_group,
swarmsize=200, omega=0.3, phip=0.5, phig=0.5, maxiter=200, minstep=1e-8)

    # Simpan hasil optimisasi bersama dengan nilai DEPTH, SWOB, RPM, SPP,
dan FlowRate
    optimization_results.append({
        'DEPT': depth,
        'Maximized ROP': -fopt_group,
        'SWOB': Xopt_group[1],
        'RPM': Xopt_group[2],
        'FlowRate': Xopt_group[3]
    })

```

```

# Buat DataFrame dari hasil optimisasi
optimization_results_df = pd.DataFrame(optimization_results)

# Tampilkan DataFrame
print(optimization_results_df)

# Menyimpan Tabel hasil optimisasi ROP ke dalam file Excel
optimization_results_df.to_excel("HasilOptim.xlsx", index=False)

```

#### D. Kode Python *Gradient Boosting Regression*

```

from sklearn.ensemble import GradientBoostingRegressor
from sklearn.model_selection import train_test_split, GridSearchCV
from sklearn.metrics import mean_squared_error, r2_score,
mean_absolute_error
import pandas as pd
import numpy as np
import math
import matplotlib.pyplot as plt

# Membaca dataset
df = pd.read_excel("/content/DataAWALRunning26.xlsx")

# Memilih fitur dan target
X = df[['DEPT', 'SWOB', 'RPM', 'FlowRate']]
y = df['ROP']

# Membagi data menjadi data latih dan data uji
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size=0.2, random_state=42)

# Menginisialisasi model Gradient Boosting Regressor
model = GradientBoostingRegressor()

# Mengatur parameter yang akan di-grid search
param_grid = {
    'n_estimators': [100, 200, 300],
    'learning_rate': [0.01, 0.1, 0.2],
    'max_depth': [3, 5, 7],
    'min_samples_split': [2, 5, 10],
    'min_samples_leaf': [1, 2, 4],
    'loss': ['squared_error', 'absolute_error']
}

# Menginisialisasi Grid Search

```

```

grid_search = GridSearchCV(estimator=model, param_grid=param_grid,
cv=3, n_jobs=-1, verbose=2)

# Melatih model menggunakan Grid Search
grid_search.fit(X_train, y_train)

# Menampilkan parameter terbaik
best_params = grid_search.best_params_
print(f'Best Parameters: {best_params}')

# Memprediksi nilai untuk data uji menggunakan model terbaik
best_model = grid_search.best_estimator_
predictions_gb = best_model.predict(X_test)

# Menghitung nilai error dan R^2
mse_gb = mean_squared_error(y_test, predictions_gb)
rmse_gb = math.sqrt(mse_gb)
r_squared_gb = r2_score(y_test, predictions_gb)
mae_gb = mean_absolute_error(y_test, predictions_gb)
mape_gb = np.mean(np.abs((y_test - predictions_gb) / y_test)) * 100
std_dev_gb = predictions_gb.std()

# Plot nilai sebenarnya vs. prediksi
plt.scatter(y_test, predictions_gb, alpha=0.5)
plt.xlabel("True Values")
plt.ylabel("Predictions")
plt.title("True Values vs. Predictions (GB)")
plt.show()

# Menampilkan nilai error dan R^2
print(f'Mean Squared Error (MSE): {mse_gb}')
print(f'Root Mean Squared Error (RMSE): {rmse_gb}')
print(f'R^2 Score: {r_squared_gb}')
print(f'Mean Absolute Error (MAE) GB: {mae_gb}')
print(f'Standard Deviation of Predictions GB: {std_dev_gb}')
print(f'Mean Absolute Percentage Error (MAPE) GBR: {mape_gb}')

# Membuat DataFrame untuk data uji beserta prediksi ROP
predictions_df = pd.DataFrame(X_test, columns=['DEPT', 'SWOB', 'RPM',
'FlowRate'])
predictions_df['Actual ROP'] = y_test.values
predictions_df['Predicted ROP'] = predictions_gb

# Menambahkan kolom standar deviasi pada DataFrame (untuk setiap
prediksi)
predictions_df['Standard Deviation of Predictions'] = std_dev_gb

```

```
# Menyimpan Tabel hasil prediksi ROP ke dalam file Excel
predictions_df.to_excel("HASILGB26.xlsx", index=False)
```

## E. Kode Python *Random Forest Regression*

```
from sklearn.ensemble import RandomForestRegressor
from sklearn.model_selection import train_test_split, GridSearchCV
from sklearn.metrics import mean_squared_error, r2_score,
mean_absolute_error
import pandas as pd
import numpy as np
import math
import matplotlib.pyplot as plt

# Membaca dataset
df = pd.read_excel("/content/DataAWALRunning1225.xlsx")

# Memilih fitur dan target
X = df[['DEPT', 'SWOB', 'RPM', 'FlowRate']]
y = df['ROP']

# Membagi data menjadi data latih dan data uji
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size=0.2, random_state=42)

# Menginisialisasi model Random Forest
model_rf = RandomForestRegressor(random_state=42)

# Mengatur parameter yang akan di-grid search
param_grid = {
    'n_estimators': [100, 200, 300],
    'max_depth': [None, 10, 20, 30],
    'min_samples_split': [2, 5, 10],
    'min_samples_leaf': [1, 2, 4],
    'bootstrap': [True, False]
}

# Menginisialisasi Grid Search
grid_search_rf = GridSearchCV(estimator=model_rf,
param_grid=param_grid, cv=3, n_jobs=-1, verbose=2)

# Melatih model menggunakan Grid Search
grid_search_rf.fit(X_train, y_train)

# Menampilkan parameter terbaik
```

```

best_params_rf = grid_search_rf.best_params_
print(f'Best Parameters RF: {best_params_rf}')

# Memprediksi nilai untuk data uji menggunakan model terbaik
best_model_rf = grid_search_rf.best_estimator_
predictions_rf = best_model_rf.predict(X_test)

# Menghitung nilai error dan R^2
mse_rf = mean_squared_error(y_test, predictions_rf)
rmse_rf = math.sqrt(mse_rf)
r_squared_rf = r2_score(y_test, predictions_rf)
mae_rf = mean_absolute_error(y_test, predictions_rf)
mape_rf = np.mean(np.abs((y_test - predictions_rf) / y_test)) * 100
std_dev_rf = predictions_rf.std()

# Plot nilai sebenarnya vs. prediksi
plt.scatter(y_test, predictions_rf, alpha=0.5)
plt.xlabel("True Values")
plt.ylabel("Predictions")
plt.title("True Values vs. Predictions (RF)")
plt.show()

# Menampilkan nilai error, R^2, dan standar deviasi
print(f'Mean Squared Error (MSE) RF: {mse_rf}')
print(f'Root Mean Squared Error (RMSE) RF: {rmse_rf}')
print(f'R^2 Score RF: {r_squared_rf}')
print(f'Mean Absolute Error (MAE) RF: {mae_rf}')
print(f'Standard Deviation of Predictions RF: {std_dev_rf}')
print(f'Mean Absolute Percentage Error (MAPE) RF: {mape_rf}')

# Membuat DataFrame untuk data uji beserta prediksi ROP
predictions_df_rf = pd.DataFrame(X_test, columns=['DEPT', 'SWOB',
' RPM', 'FlowRate'])
predictions_df_rf['Actual ROP'] = y_test.values
predictions_df_rf['Predicted ROP (RF)'] = predictions_rf
predictions_df_rf['Standard Deviation of Predictions'] = std_dev_rf

# Menyimpan Tabel hasil prediksi ROP ke dalam file Excel
predictions_df_rf.to_excel("HasilPrediksi85-RF.xlsx", index=False)

```

## F. Kode Python *K-Nearest Neighbor Regression*

```

import pandas as pd
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split, GridSearchCV

```

```

from sklearn.metrics import mean_squared_error, r2_score
from sklearn.preprocessing import StandardScaler
from sklearn.neighbors import KNeighborsRegressor

# Membaca dataset
df = pd.read_excel("/content/DataAWALRunning1225.xlsx")

# Memilih fitur dan target
X = df[['DEPT', 'SWOB', 'RPM', 'FlowRate']]
y = df['ROP']

# Membagi data menjadi data latih dan data uji
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size=0.2, random_state=42)

# Normalisasi data
scaler = StandardScaler()
X_train = scaler.fit_transform(X_train)
X_test = scaler.transform(X_test)

# Menginisialisasi model KNeighborsRegressor
knn = KNeighborsRegressor()

# Mencari hyperparameter terbaik menggunakan Grid Search
param_grid = {
    'n_neighbors': [3, 5, 7, 9, 11],
    'weights': ['uniform', 'distance'],
    'metric': ['euclidean', 'manhattan', 'minkowski'],
    'algorithm': ['auto', 'ball_tree', 'kd_tree', 'brute'],
    'leaf_size': [20, 30, 40],
    'p': [1, 2]
}

grid_search = GridSearchCV(estimator=knn, param_grid=param_grid, cv=3,
n_jobs=-1, verbose=2)
grid_search.fit(X_train, y_train)

# Menggunakan model terbaik dari Grid Search
best_knn = grid_search.best_estimator_

# Memprediksi nilai untuk data uji
predictions_knn = best_knn.predict(X_test)

# Menghitung nilai error dan R^2
mse_knn = mean_squared_error(y_test, predictions_knn)
r_squared_knn = r2_score(y_test, predictions_knn)

```

```

# Plot nilai sebenarnya vs. prediksi
plt.scatter(y_test, predictions_knn, alpha=0.5)
plt.xlabel("True values")
plt.ylabel("Predictions")
plt.title("True values vs. Predictions (kNN)")
plt.show()

# Menampilkan nilai error dan R^2
print(f'Mean Squared Error (MSE) kNN: {mse_knn}')
print(f'R^2 Score kNN: {r_squared_knn}')

# Membuat DataFrame untuk data uji beserta prediksi ROP
predictions_df_knn = pd.DataFrame(scaler.inverse_transform(X_test),
columns=['DEPT', 'SWOB', 'RPM', 'FlowRate'])
predictions_df_knn['Actual ROP'] = y_test.values
predictions_df_knn['Predicted ROP (kNN)'] = predictions_knn

# Menyimpan tabel hasil prediksi ROP kNN ke dalam file Excel
predictions_df_knn.to_excel("HasilOptim1MudiGabunganAja-KNN.xlsx",
index=False)

```

## G. Kode Python Support Vector Regression

```

from sklearn.svm import SVR
from sklearn.model_selection import train_test_split, GridSearchCV
from sklearn.metrics import mean_squared_error, r2_score,
mean_absolute_error
import pandas as pd
import matplotlib.pyplot as plt
import math
import numpy as np

# Membaca dataset
df = pd.read_excel("/content/DataAWALRunning85.xlsx")

# Memilih fitur dan target
X = df[['DEPT', 'woob', 'RPM', 'FlowRate']]
y = df['ROP']

# Membagi data menjadi data latih dan data uji
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size=0.2, random_state=42)

# Menginisialisasi model SVR

```

```

model_svr = SVR()

# Mengatur parameter yang akan di-grid search
param_grid = {
    'kernel': ['rbf', 'linear', 'poly'],
    'C': [0.1, 1, 10, 100],
    'gamma': ['scale', 'auto'],
    'degree': [2, 3, 4] # only relevant for 'poly' kernel
}

# Menginisialisasi Grid Search
grid_search_svr = GridSearchCV(estimator=model_svr,
param_grid=param_grid, cv=3, n_jobs=-1, verbose=2)

# Melatih model menggunakan Grid Search
grid_search_svr.fit(X_train, y_train)

# Menampilkan parameter terbaik
best_params_svr = grid_search_svr.best_params_
print(f'Best Parameters SVR: {best_params_svr}')

# Memprediksi nilai untuk data uji menggunakan model terbaik
best_model_svr = grid_search_svr.best_estimator_
predictions_svr = best_model_svr.predict(X_test)

# Menghitung nilai error dan R^2
mse_svr = mean_squared_error(y_test, predictions_svr)
rmse_svr = math.sqrt(mse_svr)
r_squared_svr = r2_score(y_test, predictions_svr)
mae_svr = mean_absolute_error(y_test, predictions_svr)
mape_svr = np.mean(np.abs((y_test - predictions_svr) / y_test)) * 100
std_dev_svr = predictions_svr.std()

# Plot nilai sebenarnya vs. prediksi
plt.scatter(y_test, predictions_svr, alpha=0.5)
plt.xlabel("True Values")
plt.ylabel("Predictions")
plt.title("True Values vs. Predictions (SVR)")
plt.show()

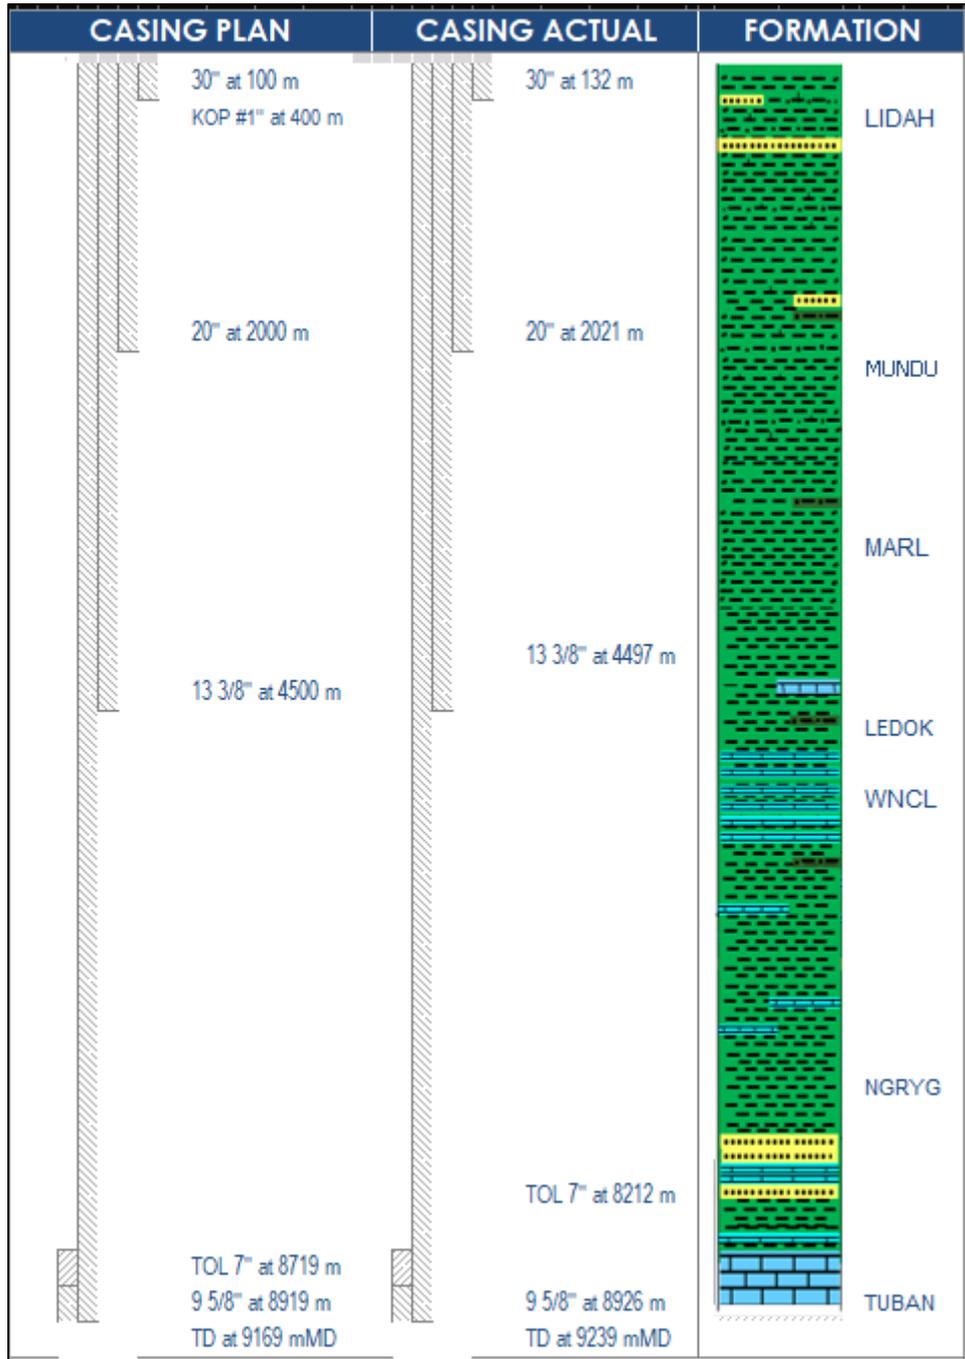
# Menampilkan nilai error, R^2, dan standar deviasi
print(f'Mean Squared Error (MSE) SVR: {mse_svr}')
print(f'Root Mean Squared Error (RMSE) SVR: {rmse_svr}')
print(f'R^2 Score SVR: {r_squared_svr}')
print(f'Mean Absolute Error (MAE) SVR: {mae_svr}')
print(f'Standard Deviation of Predictions SVR: {std_dev_svr}')
print(f'Mean Absolute Percentage Error (MAPE) SVR: {mape_svr}')

```

```
# Membuat DataFrame untuk data uji beserta prediksi ROP
predictions_df_svr = pd.DataFrame(X_test, columns=['DEPT', 'woob',
'RPM', 'FlowRate'])
predictions_df_svr['Actual ROP'] = y_test.values
predictions_df_svr['Predicted ROP (SVR)'] = predictions_svr
predictions_df_svr['Standard Deviation of Predictions'] = std_dev_svr

# Menyimpan Tabel hasil prediksi ROP SVR ke dalam file Excel
predictions_df_svr.to_excel("HASILFINAL85.xlsx", index=False)
```

**H. Kondisi Formasi, *Casing Plan*, dan *Casing Actual* dari Sumur X Lapangan Mudi**



**Waktu Pemboran dengan ROP Aktual**

<i>Depth (ftMD)</i>	<i>Connection/Trip Time (hours)</i>	<i>Rotating Time (hours)</i>	<i>ROP (ft/hr)</i>	<i>Total Days</i>
132	9	-	-	1
132-1660	-	21	72.76	1.87
1660-1727	-	1.5	44.67	1.94
1727-1916	-	3.5	54	2.08
1916	1	-	-	2.13
1916-2023	-	4	26.75	2.25
2023	141.37	-	-	6.65
2023-2038	-	1	15	6.69
2038	2	-	-	6.77
2038-3044	-	13.9	73.97	7.34
3044-3095	-	1	51	7.38
3095	0.26	-	-	7.4
3095-3656	-	11.5	48.78	7.88
3656	3.35	-	-	7.94
3656-3920	-	5	52.8	8.15
3920	0.5	-	-	8.17
3920-4091	-	3.5	48.86	8.32
4091	0.5	-	-	8.34
4091-4238	-	2	73.5	8.42
4238	1	-	-	8.46
4238-4376	-	2.5	55.2	8.57
4376	1.5	-	-	8.63
4376-4500	-	2.5	49.6	8.73
4500	167	-	-	15.69
4500-4510	-	4.5	2.22	15.88
4510	3	-	-	16.00
4510-4534	-	2	12	16.08
4534	2	-	-	16.17
4534-4721	-	4	46.75	16.34
4721-5762	-	24	43.37	17.34
5762-6991	-	24	51.21	18.34

6991-7801	-	24	33.75	19.34
7801-8314	-	9.5	54	19.73
8314-8721	-	17.4	23.40	20.46
8721	0.5	-	-	20.48
8721-8786	-	1	65	20.52
8786-8918	-	17	7.76	21.23
8918	2	-	-	21.32
8918-8928	-	1	10	21.36
8928	220.5	-	-	30.55
8928-8930	-	1	2	30.58
8930	1	-	-	30.63
8930-8938	-	1	8	30.67
8938-9239	-	9.5	31.68	31.07
9239	79	-	-	34.36



## BIODATA PENULIS



Penulis bernama Haya Aqilah Zahra, lahir di kota Bogor, Provinsi Jawa Barat pada tanggal 23 Agustus 2002. Penulis mengawali pendidikannya di SDN Baru 02 Pagi Kopasus Cijantung Kota Jakarta Timur, lalu dilanjutkan di SMPN 179 Jakarta, dan SMAN 99 Jakarta. Lulus dari SMA penulis melanjutkan jenjang sarjana di Departemen Teknik Fisika Institut Teknologi Sepuluh Nopember Surabaya. Semasa kuliah, penulis menekuni bidang Instrumentasi dan Kontrol serta tergabung di Laboratorium Instrumentasi Kontrol dan Optimisasi (ICO) sebagai *staff Research and Development (RnD)*. Penulis mengikuti beberapa kegiatan manajerial, diantaranya SPE ITS SC sebagai *staff of competition training*, *head of competency training*, dan *administrative secretary*, pada periode kepengurusan 2021/2022, 2022/2023 dan 2023/2024. Penulis juga tergabung dalam *event PETROLIDA 2022 dan 2023* sebagai *staff of petrosmart competition* dan *head coordinator of competition*. Penulis juga mengikuti berbagai perlombaan mulai dari *Petrosmart Competition*, *Paper Competition*, *Case Study Competition*, *Business Case Competition*, dan *Plan of Developmen Competition*. Penulis juga memiliki pengalaman magang sebagai *Power Plant Engineer Intern* di PT Geo Dipa Energi Dieng dan *Drilling Engineer Intern* di PT Pertamina EP Cepu. Untuk pembaca yang memiliki kritik, saran, atau ingin berdiskusi mengenai Tugas Akhir ini, dapat menghubungi penulis melalui email [hayaaqilazz@gmail.com](mailto:hayaaqilazz@gmail.com).