



**TUGAS AKHIR - MN 234801**

**STRATEGI PENGATURAN KOMPOSISI *HYDROGEN* DAN  
*DIESEL FUEL* PADA *HYBRID HYDROGEN-DIESEL*  
*ENGINE* MENGGUNAKAN *MACHINE LEARNING***

**Nicholas Satria Putra Guntoro  
NRP 5018211038**

**Dosen Pembimbing  
Dr. Eng. Ir. Yuda Apri Hermawan, S.T., M.T  
NIP 1989202011007**

**DEPARTEMEN TEKNIK PERKAPALAN  
FAKULTAS TEKNOLOGI KELAUTAN  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
2025**



**TUGAS AKHIR - MN 234801**

**STRATEGI PENGATURAN KOMPOSISI *HYDROGEN* DAN  
*DIESEL FUEL* PADA *HYBRID HYDROGEN-DIESEL*  
*ENGINE* MENGGUNAKAN *MACHINE LEARNING***

**Nicholas Satria Putra Guntoro  
NRP 5018211038**

**Dosen Pembimbing  
Dr. Eng. Ir. Yuda Apri Hermawan, S.T., M.T.**

**DEPARTEMEN TEKNIK PERKAPALAN  
FAKULTAS TEKNOLOGI KELAUTAN  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2025**



**FINAL PROJECT - MN 234801**

**MACHINE LEARNING-BASED STRATEGY OF HYDROGEN-  
DIESEL FUEL COMPOSITION CONTROL IN HYBRID  
COMBUSTION ENGINES**

**Nicholas Satria Putra Guntoro  
NRP 5018211038**

**Supervisor  
Dr. Eng. Ir. Yuda Apri Hermawan, S.T., M.T.**

**DEPARTMENT OF NAVAL ARCHITECTURE  
FACULTY OF MARINE TECHNOLOGY  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2025**

## LEMBAR PENGESAHAN

# STRATEGI PENGATURAN KOMPOSISI *HYDROGEN* DAN *DIESEL FUEL* PADA *HYBRID HYDROGEN-DIESEL ENGINE* MENGUNAKAN *MACHINE LEARNING*

### TUGAS AKHIR

Diajukan Guna Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sarjana Teknik

pada  
Program Sarjana Departemen Teknik Perkapalan  
Fakultas Teknologi Kelautan  
Institut Teknologi Sepuluh Nopember

Oleh:

**Nicholas Satria Putra Guntoro**  
NRP 5018211038

Disetujui oleh:

Dosen Pembimbing



Dr. Eng. Ir. Yuda Apri Hermawan, S.T., M.T.  
NIP 1989202011007

Mengetahui,  
Kepala Departemen Teknik Perkapalan



Ir. Leguh Putranto, S.T., M.T., Ph.D.  
NIP 199005132014041001

SURABAYA, 28 Juli 2025

## LEMBAR REVISI

### STRATEGI PENGATURAN KOMPOSISI *HYDROGEN* DAN *DIESEL FUEL* PADA *HYBRID HYDROGEN-DIESEL ENGINE* MENGUNAKAN *MACHINE LEARNING*

#### TUGAS AKHIR

Telah direvisi sesuai dengan hasil Ujian Tugas Akhir  
Tanggal 15 Juli 2025

Program Sarjana Departemen Teknik Perkapalan  
Fakultas Teknologi Kelautan  
Institut Teknologi Sepuluh Nopember

Oleh:

Nicholas Satria Putra Guntoro  
NRP 5018211038

Disetujui oleh Tim Penguji Ujian Tugas Akhir:

1. Ir. Teguh Putranto, S.T., M.T., Ph.D.

  
.....

2. Prof. Ir. Raden Sjarief Widjaja, Ph.D

  
.....

3. Ir. Totok Yulianto, S.T., M.T.

  
.....

Disetujui oleh Dosen Pembimbing Tugas Akhir:

1. Dr. Eng. Ir. Yuda Apri Hermawan, S.T., M.T.

  
.....

SURABAYA, 28 Juli 2025

## PERNYATAAN ORIGINALITAS

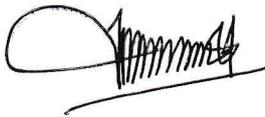
Yang bertanda tangan di bawah ini:

Nama Mahasiswa / NRP : Nicholas Satria Putra Guntoro / 5018211038  
Departemen : Teknik Perkapalan  
Dosen Pembimbing / NIP : Dr. Eng. Ir. Yuda Apri Hermawan, S.T., M.T. /  
1989202011007

dengan ini menyatakan bahwa tugas akhir dengan judul “**STRATEGI PENGATURAN KOMPOSISI HYDROGEN DAN DIESEL FUEL PADA HYBRID HYDROGEN-DIESEL ENGINE MENGGUNAKAN MACHINE LEARNING**” adalah hasil karya 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.

Mengetahui,  
Dosen Pembimbing



Dr. Eng. Ir. Yuda Apri Hermawan, S.T., M.T.  
NIP 1989202011007

Surabaya, 10 Juli 2025  
Mahasiswa,



Nicholas Satria Putra Guntoro  
NRP 5018211038

## **HALAMAN PERUNTUKAN**

Dipersembahkan kepada kedua orang tua atas segala dukungan dan doanya

## KATA PENGANTAR

Puji syukur kepada Tuhan Yang Maha Esa karena atas karunianya Tugas Akhir ini dapat diselesaikan dengan baik. Pada kesempatan ini Penulis ingin mengucapkan terima kasih kepada pihak-pihak yang membantu penyelesaian Tugas Akhir ini, yaitu:

1. Bapak Dr. Eng. Ir. Yuda Apri Hermawan, S.T., M.T. selaku Dosen Pembimbing yang dengan sabar menuntun saya untuk melakukan pengerjaan dan penyusunan Tugas Akhir ini;
2. Bapak Prof. Ir. Sjarief Widjaja, Ph.D., Bapak Ir. Totok Yulianto, S.T., M.T., dan Ibu Dr. Adi Novitarini Putri, S.T., M.T. selaku Dosen Penguji yang telah memberikan kritik dan sarannya untuk perbaikan Laporan Tugas Akhir ini;
3. Ibu Dr. Eng. Ir. Septia Hardy Sujiatanti, S.T., M.T. selaku Dosen Wali yang telah membantu dan membimbing selama masa perkuliahan;
4. Orang tua saya yang selalu memberikan dukungan selama perkuliahan;
5. Seluruh teman-teman Laboratorium Teknologi Kapal Digital.

Penulis menyadari bahwa Tugas Akhir ini masih jauh dari kesempurnaan, sehingga kritik dan saran yang bersifat membangun sangat diharapkan. Akhir kata semoga laporan ini dapat bermanfaat bagi banyak pihak.

Surabaya, 15 Juli 2024

Nicholas Satria Putra Guntoro

# ABSTRAK

## **STRATEGI PENGATURAN KOMPOSISI *HYDROGEN* DAN *DIESEL* FUEL PADA *HYBRID HYDROGEN-DIESEL ENGINE* MENGGUNAKAN *MACHINE LEARNING***

Nama Mahasiswa / NRP : Nicholas Satria Putra Guntoro / 5018211038  
Departemen : Teknik Perkapalan  
Dosen Pembimbing / NIP : Dr. Eng. Ir. Yuda Apri Hermawan, S.T., M.T. /1989202011007

### **Abstrak**

Penelitian ini mengembangkan pendekatan prediktif berbasis machine learning untuk mengatur komposisi bahan bakar hidrogen dan diesel dalam mesin hybrid. Tujuannya adalah meningkatkan efisiensi pembakaran dan menurunkan emisi gas buang. Empat model *machine learning* yang digunakan meliputi XGBoost Regressor, Random Forest Regressor (RFR), Multi-Layer Perceptron (MLP), dan Deep Neural Network (DNN). Setiap model dievaluasi menggunakan metrik  $R^2$ , Mean Absolute Error (MAE), dan validasi hold-out. Hasil menunjukkan bahwa XGBoost memberikan performa terbaik dengan nilai  $R^2$  sebesar 0,9538, MAE 2,77, dan waktu komputasi hanya 0,39 detik. Sementara itu, DNN menghasilkan  $R^2$  sebesar 0,8077 dan MAE 9,16 setelah 50 kali pelatihan, serta membutuhkan waktu komputasi 3671 detik. Model terbaik (XGBoost) kemudian digunakan dalam simulasi interaktif untuk memprediksi performa mesin secara real-time berdasarkan input *throttle*. Visualisasi output seperti rasio hidrogen, emisi CO<sub>2</sub> dan NO<sub>x</sub>, serta tingkat asap memberikan pemahaman mendalam terhadap dinamika sistem pembakaran. Penelitian ini menunjukkan bahwa *machine learning* mampu menjadi solusi efektif dalam optimasi sistem bahan bakar hybrid dan berpotensi diterapkan dalam sistem kendali mesin kapal masa depan.

**Kata kunci:** Mesin Hybrid, Bahan Bakar Hidrogen-Diesel, *Machine Learning*, Efisiensi Pembakaran, Reduksi Emisi, Model Prediktif, XGBoost, Random Forest Regressor, MLP, Simulasi

## ABSTRACT

# MACHINE LEARNING-BASED STRATEGY OF HYDROGEN-DIESEL FUEL COMPOSITION CONTROL IN HYBRID COMBUSTION ENGINES

Author / Student Number : Nicholas Satria Putra Guntoro / 5018211038  
Department / Faculty : Naval Architecture / Marine Technology  
Supervisor : Dr. Eng. Ir. Yuda Apri Hermawan, S.T., M.T. /1989202011007

### Abstract

This study develops a predictive machine learning approach for optimizing hydrogen and diesel fuel composition in hybrid engines. The aim is to enhance combustion efficiency while reducing exhaust emissions. Four machine learning models were employed: XGBoost Regressor, Random Forest Regressor (RFR), Multi-Layer Perceptron (MLP), and Deep Neural Network (DNN). The models were evaluated using  $R^2$ , Mean Absolute Error (MAE), and hold-out validation. Results indicate that XGBoost achieved the best performance with an  $R^2$  score of 0.9538, MAE of 2.77, and a training time of only 0.39 seconds. In comparison, DNN reached an  $R^2$  of 0.8077, MAE of 9.16, required 50 training iterations, and a total computation time of 3671 seconds. The best-performing model (XGBoost) was integrated into a real-time interactive simulation that predicts engine performance based on *throttle* input. Visualization of outputs such as hydrogen ratio,  $CO_2$  and  $NO_x$  emissions, and smoke level enhances understanding of combustion dynamics. This study demonstrates the effectiveness of machine learning in hybrid fuel system optimization and its potential in future intelligent marine engine control.

**Keyword:** *Hybrid Engine, Diesel-Hydrogen Fuel, Machine Learning, Fuel Efficiency, Emission Reduction, Predictive Model, XGBoost, Random Forest Regressor, MLP, Simulation*

# DAFTAR ISI

|   |      |
|---|------|
| LEMBAR PENGESAHAN .....   | iv   |
| LEMBAR REVISI.....  | v    |
| PERNYATAAN ORIGINALITAS .....   | vi   |
| HALAMAN PERUNTUKAN.....   | vii  |
| KATA PENGANTAR.....   | viii |
| ABSTRAK .....   | ix   |
| ABSTRACT .....  | x    |
| DAFTAR ISI .....  | xi   |
| DAFTAR GAMBAR.....  | xiv  |
| DAFTAR TABEL .....  | xvi  |
| BAB 1 PENDAHULUAN.....  | 1    |
| 1.1. Latar Belakang Masalah .....                                     | 1    |
| 1.2. Perumusan Masalah .....  | 3    |
| 1.3. Tujuan .....   | 3    |
| 1.4. Batasan Masalah .....  | 3    |
| 1.5. Manfaat .....  | 4    |
| 1.6. Hipotesis .....  | 4    |
| BAB 2 STUDI LITERATUR.....  | 5    |
| 2.1. Dasar Teori .....  | 5    |
| 2.1.1. Apa itu mesin hidrogen hybrid .....                            | 5    |
| 2.1.2. Hidrogen sebagai bahan bakar .....                             | 6    |
| 2.1.3. Teknologi Injeksi Hidrogen .....                               | 7    |
| 2.1.4. Teknologi Penyimpanan Hidrogen .....                           | 9    |
| 2.1.5. Implementasi hybrid hydrogen diesel engine pada kapal .....    | 18   |
| 2.1.6. Kecerdasan Buatan dalam pengaturan komposisi bahan bakar ..... | 20   |
| 2.1.7. Perhitungan Efisiensi Bahan Bakar .....                        | 21   |
| 2.1.8. XGBoost Regressor .....  | 25   |
| 2.1.9. Random Forest Regressor (RFR).....                             | 26   |
| 2.1.10. <i>Multi Layer Perceptron</i> .....                           | 29   |

|  |    |
|--|----|
| 2.1.11. <i>Deep Neural Network</i> (DNN) .....                                       | 31 |
| 2.1.12. Metrik Evaluasi yang Digunakan.....  | 33 |
| 2.2. TINJAUAN PUSTAKA .....  | 35 |
| BAB 3 METODOLOGI .....   | 39 |
| 3.1. Metodologi Penelitian.....  | 39 |
| 3.2. Diagram Alir.....   | 40 |
| 3.2.1. Rancangan Penelitian.....   | 40 |
| 3.2.2. Pengumpulan Data .....  | 41 |
| BAB 4 STUDI PEMILIHAN ALGORITMA DAN PERANCANGAN MODEL .....                          | 43 |
| 4.1. Analisa Penentuan Algoritma Machine Learning .....                              | 44 |
| 4.2. Training dan Augmentasi .....   | 46 |
| 4.2.1. Pengolahan Data dan Teknik Augmentasi pada Model XGBoost Regressor...         | 47 |
| 4.2.2. Pengolahan Data dan Teknik Augmentasi pada Model RFR .....                    | 49 |
| 4.2.3. Pengolahan Data dan Teknik Augmentasi pada Model MLP.....                     | 51 |
| 4.2.4. Pengolahan Data dan Teknik Augmentasi pada Model DNN .....                    | 53 |
| 4.3. Hasil Evaluasi Model.....   | 57 |
| 4.3.1. Perbandingan Kinerja Model .....  | 58 |
| 4.4. Pemilihan Model Terbaik dan Penerapannya .....                                  | 65 |
| BAB 5 HASIL Simulasi .....   | 67 |
| 5.1. Desain Simulasi .....   | 67 |
| 5.1.1. Arsitektur Simulasi .....   | 67 |
| 5.1.2. Mekanisme Simulasi.....   | 70 |
| 5.1.3. Integrasi Model Prediktif .....   | 72 |
| 5.2. Skenario simulasi.....  | 73 |
| 5.3. Hasil Simulasi.....   | 74 |
| 5.3.1. Hasil Simulasi Case 1 (Ketika kapal bermanuver (RPM naik-turun).....          | 75 |
| 5.3.2. Hasil Simulasi Case 2 (Ketika kapal dalam keadaan stabil naik).....           | 76 |
| 5.3.3. Hasil Simulasi Case 3 (Ketika kapal dalam keadaan stabil turun) .....         | 78 |
| 5.3.4. Hasil Simulasi Case 4 (Ketika kapal dalam keadaan <i>service speed</i> )..... | 79 |
| 5.3.5. Hasil Simulasi Case 5 (Ketika kapal dalam keadaan Lonjakan Mendadak) ....     | 81 |
| 5.3.6. Hasil Simulasi Case 6 (Ketika kapal dalam keadaan Manuver Ekstrem).....       | 82 |
| 5.4. Rasio Hidrogen Optimal dalam Simulasi .....                                     | 84 |
| BAB 6 Kesimpulan dan Saran.....  | 87 |

|  |    |
|--|----|
| 6.1. Kesimpulan.....                                     | 87 |
| 6.2. Saran .....   | 88 |
| DAFTAR PUSTAKA.....                                      | 91 |
| LAMPIRAN   |    |
| LAMPIRAN 1 Dataset Kinerja Mesin                         |    |
| LAMPIRAN 2 SCATTER PLOT MASING-MASING MODEL              |    |
| LAMPIRAN 3 MEAN ABSOLUTE ERROR (MAE) MASING-MASING MODEL |    |
| LAMPIRAN 4 WAKTU KOMPUTASI MASING-MASING MODEL           |    |
| LAMPIRAN 5 HASIL HOLD-OUT VALIDATION MASING-MASING MODEL |    |
| BIODATA PENULIS  |    |

## DAFTAR GAMBAR

|  |    |
|--|----|
| Gambar 1. 1 Infografis Perdagangan Laut Global.....                        | 1  |
| Gambar 2. 1 Skema Mesin Hydrogen-Diesel Hybrid.....                        | 6  |
| Gambar 2. 2 Teknik karburasi bahan bakar.....                              | 8  |
| Gambar 2. 3 Teknik manifold injection dan inlet port .....                 | 8  |
| Gambar 2. 4 Sistem <i>direct injection</i> .....                           | 9  |
| Gambar 2. 5 Tipe-Tipe Tangki Hidrogen.....                                 | 10 |
| Gambar 2. 6 Tangki Hidrogen Tipe 1 .....                                   | 11 |
| Gambar 2. 7 Tangki Hidrogen Tipe 2 .....                                   | 13 |
| Gambar 2. 8 Tangki Hidrogen Tipe 3 .....                                   | 15 |
| Gambar 2. 9 Tangki Tipe 4.....   | 17 |
| Gambar 2. 10 Skematik Sistem Mesin Hybrid Hydrogen-Diesel .....            | 18 |
| Gambar 2. 11 Arsitektur XGBoost.....                                       | 25 |
| Gambar 2. 12 Arsitektur Random Forest Regressor .....                      | 27 |
| Gambar 2. 13 Arsitektur Multi Layer Perceptron .....                       | 29 |
| Gambar 2. 14 Arsitektur DNN .....  | 31 |
| Gambar 3. 1 Diagram alir pengerjaan Tugas Akhir .....                      | 40 |
| Gambar 4. 1 Arsitektur XGBoost yang Sudah Disesuaikan.....                 | 49 |
| Gambar 4. 2 Arsitektur Random Forest Regressor yang sudah disesuaikan..... | 51 |
| Gambar 4. 3 Arsitektur Multi-Layer Perceptron yang Sudah Disesuaikan.....  | 53 |
| Gambar 4. 4 Arsitektur Deep Neural Network yang Sudah Disesuaikan .....    | 55 |
| Gambar 4. 5 Scatter Plot XGBoost.....                                      | 59 |
| Gambar 4. 6 Grafik MAE XGBoost.....  | 59 |
| Gambar 4. 7 Waktu Komputasi XGBoost.....                                   | 60 |
| Gambar 4. 8 Pengujian Hold Out Validation XGBoost .....                    | 60 |
| Gambar 4. 9 Scatter Plot Random Forest Regressor .....                     | 60 |
| Gambar 4. 10 Grafik MAE Random Forest Regressor .....                      | 61 |
| Gambar 4. 11 Waktu Komputasi Random Forest Regressor .....                 | 61 |
| Gambar 4. 12 Pengujian Hold Out Validation Random Forest Regressor .....   | 61 |
| Gambar 4. 13 <i>Scatter Plot Multi Layer Perceptron</i> .....              | 62 |

|  |    |
|--|----|
| Gambar 4. 14 Grafik MAE <i>Multi Layer Perceptron</i> .....                        | 62 |
| Gambar 4. 15 Waktu komputasi <i>Multi Layer Perceptron</i> .....                   | 63 |
| Gambar 4. 16 Pengujian <i>Hold Out Validation Multi Layer Perceptron</i> .....     | 63 |
| Gambar 4. 17 Scatter Plot Deep Neural Network .....                                | 64 |
| Gambar 4. 18 Grafik MAE Deep Neural Network.....                                   | 64 |
| Gambar 4. 19 Waktu komputasi Deep Neural Network.....                              | 65 |
| Gambar 4. 20 Pengujian Hold Out Validation Deep Neural Network .....               | 65 |
| Gambar 5. 1 Visualisasi Simulasi.....  | 68 |
| Gambar 5. 2 Flowchart Simulasi .....   | 72 |
| Gambar 5. 3 Cuplikan kode proses pembentukan input prediksi model .....            | 72 |
| Gambar 5. 4 Grafik ketika kapal sedang melakukan maneuver (RPM tidak stabil) ..... | 75 |
| Gambar 5. 5 Grafik ketika kapal dalam keadaan stabil naik .....                    | 76 |
| Gambar 5. 6 Grafik kondisi mesin kapal dalam keadaan turun stabil .....            | 78 |
| Gambar 5. 7 Grafik kondisi mesin kapal dalam keadaan stabil .....                  | 80 |
| Gambar 5. 8 Grafik kondisi mesin kapal dalam keadaan Lonjakan Beban Mendadak.....  | 81 |
| Gambar 5. 9 Grafik kondisi mesin kapal dalam keadaan Manuver Ekstrem .....         | 83 |

## DAFTAR TABEL

|   |    |
|---|----|
| Tabel 4. 1 Dataset eksperimen.....                                  | 46 |
| Tabel 4. 2 Evaluasi Kinerja Masing-Masing Model.....                | 66 |
| Tabel 5. 1 Rasio Hidrogen dan Diesel terhadap Kondisi Operasi ..... | 84 |

# BAB 1

## PENDAHULUAN

### 1.1. Latar Belakang Masalah

Perkapalan merupakan salah satu moda transportasi dan ekspedisi pengiriman yang paling vital di dunia. Sekitar 90% perdagangan global dilakukan melalui jalur laut, menjadikan kapal sebagai sarana transportasi yang tidak tergantikan oleh moda lain seperti truk atau kereta api. Selain itu, kapal menawarkan efisiensi ekonomi yang lebih tinggi dibandingkan dengan pesawat, terutama untuk pengiriman dalam jumlah besar dan jarak jauh.



Gambar 1. 1 Infografis Perdagangan Laut Global

(Sumber: <https://blog.solistica.com/en/the-global-landscape-of-sea-trade>)

Namun, seiring dengan meningkatnya aktivitas pelayaran global, sektor perkapalan juga menjadi salah satu penyumbang terbesar emisi gas rumah kaca (GHG). Berdasarkan laporan *International Maritime Organization* (IMO) tahun 2018, sektor perkapalan menyumbang sekitar 3% dari total emisi gas rumah kaca global. Jika tidak ada tindakan

mitigasi yang diambil, emisi ini diperkirakan dapat meningkat 90% hingga 130% pada tahun 2050, seiring dengan pertumbuhan perdagangan internasional dan jumlah kapal yang beroperasi. Sebagai respons terhadap krisis iklim, IMO mengeluarkan kebijakan ketat terkait pengurangan emisi dari sektor maritim, termasuk IMO Tier III dan regulasi terbaru yang mendorong penggunaan teknologi rendah emisi serta bahan bakar alternatif. IMO Tier III menetapkan standar emisi NO<sub>x</sub> (Nitrogen Oksida) yang lebih ketat dibandingkan regulasi sebelumnya, terutama untuk kapal yang beroperasi di *Emission Control Areas* (ECA). Selain itu, IMO juga telah mencanangkan target untuk mengurangi intensitas karbon sebesar 40% pada tahun 2030 dan 70% pada tahun 2050 dibandingkan dengan level tahun 2008.

Salah satu inovasi yang dikembangkan untuk mendukung dekarbonisasi sektor perkapalan adalah penggunaan mesin hidrogen hibrida. Hidrogen memiliki beberapa keunggulan dibandingkan bahan bakar fosil konvensional, antara lain emisi CO<sub>2</sub> nol, pembakaran lebih bersih yang mengurangi emisi partikel jelaga (PM) dan karbon monoksida (CO). Namun, tantangan utama dalam penggunaan hidrogen adalah pengaturan rasio bahan bakar agar tetap efisien dan aman. Jika kandungan hidrogen terlalu tinggi, dapat menyebabkan *knocking* (ketukan) pada mesin dan meningkatkan NO<sub>x</sub> akibat suhu pembakaran yang lebih tinggi. Oleh karena itu, dibutuhkan sistem yang mampu menyesuaikan campuran hidrogen-diesel secara dinamis berdasarkan kondisi operasional kapal.

Penelitian ini berfokus pada optimasi pengaturan campuran hidrogen dan diesel menggunakan *Machine Learning*. Metode ini penting karena dapat menyesuaikan rasio bahan bakar, menghindari efisiensi rendah atau risiko *knocking* akibat perbandingan bahan bakar yang tidak optimal, serta meningkatkan efisiensi bahan bakar dan mengurangi emisi dengan strategi berbasis data. Dalam penelitian ini, metode *Machine Learning* (ML) akan digunakan untuk menganalisis pola pembakaran mesin dan mengoptimalkan komposisi bahan bakar pada berbagai tingkat RPM. Model yang digunakan adalah *Random Forest Regression* atau *Neural Network*, karena *Random Forest Regression* mampu menangani data non-linear dan bekerja dengan baik untuk prediksi berbasis variabel kompleks seperti tekanan bahan bakar, suhu mesin, dan emisi gas buang, sementara *Neural Network* dapat menangkap hubungan yang lebih kompleks antar variabel dan mampu beradaptasi dengan berbagai kondisi operasional kapal.

Dengan pendekatan ini, penelitian ini bertujuan untuk mengembangkan model berbasis *Machine Learning* untuk mengoptimalkan penggunaan hidrogen sebagai bahan bakar kapal, menganalisis dampak penggunaan hidrogen terhadap efisiensi bahan bakar dan emisi pada berbagai tingkat RPM, serta menyediakan solusi berbasis software yang dapat diterapkan untuk meningkatkan keberlanjutan sektor maritim. Penelitian ini memiliki urgensi yang tinggi mengingat semakin ketatnya regulasi emisi IMO dan kebutuhan untuk mengembangkan solusi bahan bakar yang lebih ramah lingkungan. Dengan menggunakan *Machine Learning* untuk optimasi hidrogen-diesel, penelitian ini diharapkan dapat memberikan kontribusi dalam meningkatkan efisiensi operasional kapal sekaligus menekan emisi gas rumah kaca.

## **1.2. Perumusan Masalah**

Berdasarkan latar belakang di atas, didapatkan permasalahan:

- a. Bagaimana menggunakan model *machine learning* yang mampu menentukan komposisi optimal campuran hidrogen dan diesel berdasarkan putaran mesin (RPM)?
- b. Bagaimana mendapatkan model *machine learning* yang paling sesuai dalam memprediksi komposisi campuran hidrogen-diesel berdasarkan parameter RPM mesin?
- c. Bagaimana hasil implementasi *machine learning* terhadap penyetoran komposisi campuran hidrogen-diesel terhadap beberapa kondisi RPM?

## **1.3. Tujuan**

Berdasarkan rumusan masalah yang telah didapatkan, maka tujuan penelitian ini sebagai berikut

- a. Mendapatkan rancangan sistem komposisi dengan menggunakan *machine learning*
- b. Menentukan model *machine learning* paling sesuai untuk prediksi tersebut
- c. Menguji adaptabilitas model pada data RPM simulasi pelayaran

## **1.4. Batasan Masalah**

Batasan masalah dari penelitian "Simulasi Pengaturan Komposisi *Hydrogen* dan *Diesel Fuel* pada *Hybrid Hydrogen-Diesel Engine* Menggunakan *Machine Learning*" dapat meliputi:

- a. Penelitian ini hanya akan fokus pada penggunaan hidrogen yang telah diproduksi secara konvensional.
- b. Simulasi pengaturan bahan bakar berbasis data primer dan sekunder, bukan eksperimen langsung di kapal.
- c. Studi ini tidak akan mencakup aspek ekonomi secara mendalam, seperti biaya produksi dan distribusi hidrogen.

- d. Tidak ada perubahan bentuk lambung kapal yang berimplikasi pada perubahan karakteristik kapal.
- e. Uji coba hasil dalam skala kecil melalui simulasi computer

### **1.5. Manfaat**

Manfaat dari penelitian “Simulasi Pengaturan Komposisi *Hydrogen* dan *Diesel Fuel* pada *Hybrid Hydrogen-Diesel Engine* Menggunakan *Machine Learning* ” meliputi:

- a. Memberikan wawasan bahwa hydrogen dapat digunakan untuk tenaga penggerak kapal sehingga dapat mengurangi emisi gas rumah kaca dari industri perkapalan.
- b. Mengembangkan metode penggunaan hidrogen yang lebih efisien dan ramah lingkungan
- c. Menyediakan wawasan tentang integrasi teknologi *Machine Learning* dalam sistem pengendalian penggunaan dan komposisi bahan bakar hybrid hidrogen diesel kapal.

### **1.6. Hipotesis**

Hipotesis dalam penelitian ini adalah bahwa sistem pengaturan otomatis komposisi hidrogen dan diesel pada mesin hybrid dapat merespons dan menyesuaikan secara dinamis terhadap kondisi operasi kapal

## **BAB 2**

### **STUDI LITERATUR**

#### **2.1. Dasar Teori**

##### **2.1.1. Apa itu mesin hidrogen hybrid**

Mesin hidrogen hybrid adalah mesin pembakaran internal yang menggabungkan penggunaan hidrogen dan bahan bakar fosil (seperti diesel) dalam satu sistem, yang bertujuan untuk meningkatkan efisiensi energi dan mengurangi emisi gas buang. Mesin ini bekerja dengan prinsip dual-fuel, di mana hidrogen digunakan sebagai bahan bakar tambahan untuk meningkatkan karakteristik pembakaran, seperti laju pembakaran dan efisiensi termal, tanpa harus sepenuhnya mengganti sistem mesin konvensional (Khan et al., 2021).

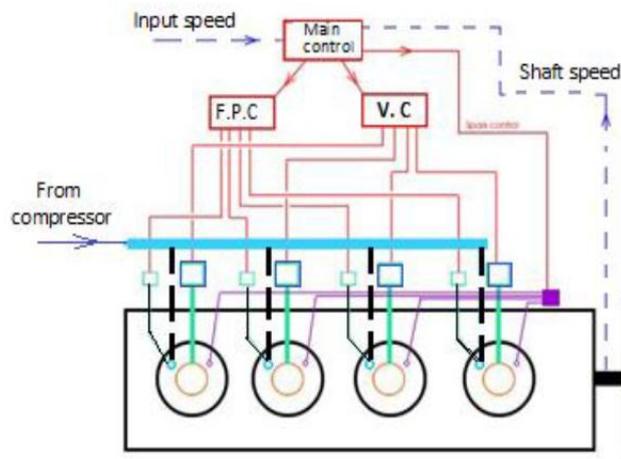
Hidrogen memiliki sifat pembakaran yang cepat, angka oktan yang tinggi, serta tidak menghasilkan emisi karbon saat terbakar. Oleh karena itu, penggunaannya dalam mesin hybrid memungkinkan pengurangan signifikan terhadap emisi karbon dioksida (CO<sub>2</sub>), karbon monoksida (CO), dan partikel (PM), sekaligus memberikan solusi transisi menuju sistem energi yang lebih bersih (Singh et al., 2023).

Sistem mesin hybrid hidrogen-diesel juga memungkinkan fleksibilitas pengaturan komposisi bahan bakar sesuai kondisi operasi, termasuk beban dan kecepatan mesin, sehingga efisiensi dapat dioptimalkan di berbagai skenario penggunaan. Dalam konteks transportasi laut, pendekatan ini menjadi solusi antara yang menarik karena memungkinkan penggunaan teknologi rendah karbon tanpa mengganti seluruh sistem propulsi kapal (Zhou et al., 2020).

Dalam sistem ini, mesin diesel dapat bekerja dengan hidrogen melalui dua pendekatan umum:

1. *Pre-mixing*, yaitu pencampuran hidrogen dan udara sebelum masuk ke ruang bakar.
2. *Direct injection*, yaitu penyuntikan hidrogen langsung ke dalam ruang bakar setelah udara dikompresi.

Sistem ini memerlukan modifikasi pada sistem suplai bahan bakar, sistem pengapian, dan sistem kontrol elektronik. Hidrogen disimpan dalam bentuk gas bertekanan tinggi (350–700 bar) atau cair kriogenik (LH<sub>2</sub>), dan didistribusikan melalui *common rail* ke masing-masing silinder menggunakan injektor khusus.



Gambar 2. 1 Skema Mesin Hydrogen-Diesel Hybrid  
(Sumber: Saddiek et al, 2015)

Gambar diatas menunjukkan sistem pengendalian mesin hidrogen hybrid dengan beberapa komponen utama sebagai berikut:

- *Hydrogen Common Rail*: Saluran utama distribusi hidrogen ke setiap silinder.
- *Hydrogen Injector*: Menyuntikkan hidrogen ke ruang bakar dengan tekanan sekitar 100 bar.
- *Spark Plug & Distributor*: Sistem pengapian digunakan untuk memicu pembakaran hidrogen, dikendalikan oleh *spark distributor*.
- *Exhaust Valve Actuator*: Mengatur bukaan katup buang secara presisi, dikendalikan oleh *Valve Control (V.C)* unit.
- *Fuel Pump Control (F.P.C)*: Mengatur tekanan dan suplai hidrogen dari kompresor.
- *Main Control Unit (MCU)*: Bertanggung jawab terhadap seluruh sistem, termasuk mengatur injeksi bahan bakar, pengapian, dan katup buang berdasarkan data *input/feedback* seperti kecepatan poros dan tekanan sistem.

Semua komponen ini terhubung melalui sinyal kontrol elektronik dan umpan balik real-time, menjadikan sistem dapat beradaptasi terhadap perubahan kondisi operasi kapal seperti kecepatan, beban, dan suhu mesin.

### 2.1.2. Hidrogen sebagai bahan bakar

Debu Hidrogen merupakan salah satu elemen yang paling melimpah di alam dan memiliki kandungan energi yang tinggi. Penggunaan hidrogen sebagai bahan bakar memiliki beberapa keuntungan yaitu:

1. Emisi Nol CO<sub>2</sub>: Ketika dibakar, hidrogen hanya menghasilkan uap air sebagai produk sampingan sehingga tidak menghasilkan emisi karbon maupun emisi gas nitrogen. Hal tersebut merupakan salah satu keunggulan paling signifikan apabila dibandingkan dengan bahan bakar fosil yang menghasilkan gas buang berupa karbon dioksida dan gas nitrogen yang dapat meningkatkan kadar gas rumah kaca.
2. Peningkatan efisiensi termal mesin: Mesin bahan bakar konvensional memiliki efisiensi termal yang kurang baik, dimana dari bahan bakar yang digunakan, sebesar 60-70% terbuang dalam bentuk panas yang dihasilkan oleh pembakaran di ruang mesin. Penambahan hydrogen pada campuran bahan bakar mesin diesel pada kapal, menunjukan peningkatan efisiensi termal maksimum 38% (Zhao et al, 2020).
3. Teknologi injeksi: Teknik penyediaan hidrogen saat akan dimasukkan ke ruang bakar terbagi menjadi 2 cara yaitu:
  - *Direct Injection*: sistem *direct injection* ini melibatkan injector yang berfungsi untuk menyemburkan hidrogen langsung ke ruang bakar.
  - Melalui *intake* udara: setiap mesin bakar pasti memiliki saluran yang berfungsi untuk jalur masuknya udara untuk memasok gas oksigen sehingga proses pembakaran dapat terjadi. Di beberapa mesin hibrida, gas dimasukkan ke ruang bakar melalui saluran *intake* udara. Cara ini terbilang lebih sederhana daripada sistem *direct injection* terutama jika mesin hanya memiliki injektor khusus di ruang bakar untuk memasok gas hidrokarbon.

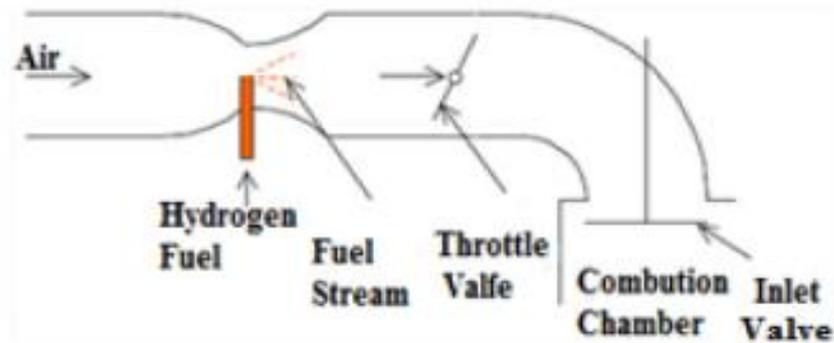
### **2.1.3. Teknologi Injeksi Hidrogen**

Penggunaan hidrogen sebagai bahan bakar pada mesin pembakaran internal memerlukan teknik injeksi yang tepat untuk memastikan efisiensi dan kinerja mesin yang optimal. Ada beberapa teknik utama memasukan hidrogen ke dalam mesin pembakaran internal yaitu:

#### **1. Teknik karburasi bahan bakar:**

Teknik karburasi bahan bakar menggunakan karburator gas untuk mencampur hidrogen dengan udara sebelum masuk ke *intake manifold*. Hidrogen disuplai bersama udara yang diatur oleh katup karburator dan masuk ke dalam silinder mesin untuk melakukan pembakaran. Keunggulan dari teknik ini adalah sistem yang relative sederhana dan pengguna dapat dengan mudah memodifikasi mesin diesel menjadi mesin hidrogen tanpa perlu melakukan modifikasi besar. Selain itu, teknik ini memiliki kekurangan yaitu mesin mudah mengalami knocking. Mesin dengan menggunakan teknik ini dinilai kurang

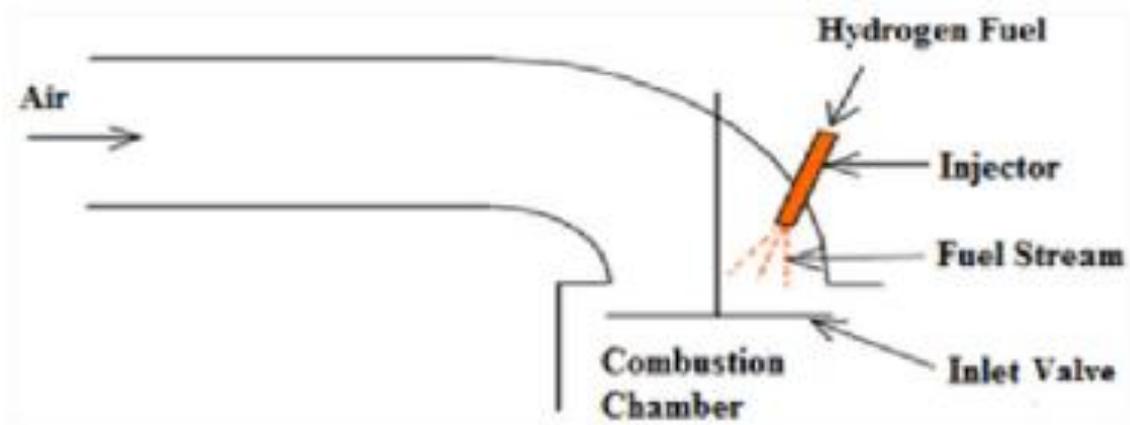
efisien. Hal ini ditunjukkan oleh Behdad Shadidi mencatat bahwa mesin yang menggunakan teknik ini mengalami *powerloss* sebesar 15%



Gambar 2. 2 Teknik karburasi bahan bakar  
(Sumber: M. Faizal & L. S. Chuah, 2019)

## 2. Teknik *manifold injection* dan *inlet port*

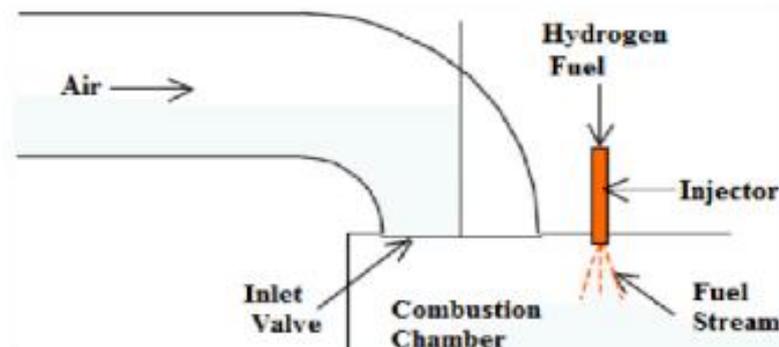
Prosedur injeksi port intake ini melibatkan hidrogen disalurkan ke silinder oleh injector mekanik atau elektrik yang dapat beroperasi pada berbagai konfigurasi dan bercampur dengan udara saat masuk melalui *intake manifold*. Hal ini memungkinkan pencampuran udara dan hidrogen yang lebih baik dan terkontrol dengan presisi terhadap rasio bahan bakar dengan udara. Teknik ini memiliki keunggulan dibandingkan dengan teknik karburasi karena memungkinkan kontrol yang lebih baik terhadap jumlah hidrogen yang dikeluarkan dari injektor sehingga dapat mengurangi risiko pengapian awal dan knocking. Selain itu, teknik ini memiliki kekurangan yaitu memerlukan sistem injeksi yang lebih kompleks dan canggih untuk memastikan pencampuran yang tepat untuk meningkatkan efisiensi.



Gambar 2. 3 Teknik manifold injection dan inlet port  
(Sumber: M. Faizal & L. S. Chuah, 2019)

### 3. Sistem *direct injection*

Sistem *direct injection* langsung dengan menyuntikan hidrogen langsung ke dalam ruang pembakaran dengan menggunakan katup. Hal ini memastikan bahwa hidrogen hanya masuk ke ruang bakar selama langkah kompresi, meningkatkan efisiensi pembakaran dan proses pembakaran yang lebih terkontrol. Keunggulan dari teknik ini adalah efisiensi termal yang lebih tinggi dan kinerja mesin yang lebih baik. Hidrogen yang diinjeksikan langsung ke ruang bakar juga memastikan bahwa hidrogen benar-benar terbakar di ruang bakar sehingga tidak ada hidrogen yang terbuang. Hal ini dapat meningkatkan efisiensi penggunaan hidrogen. Namun, kekurangan dari sistem ini adalah terjadinya peningkatan tekanan di ruang bakar yang signifikan, termasuk peningkatan drastis pada suhu di ruang bakar. Oleh karena itu, mesin yang menggunakan teknik ini memerlukan komponen mesin yang lebih tahan terhadap tekanan dan suhu yang lebih ekstrim menyebabkan meningkatnya berat dari mesin tersebut. Teknik ini juga memerlukan teknologi yang lebih tinggi untuk memastikan pengendalian injeksi sehingga proses pembakaran dapat berjalan dengan baik.



Gambar 2. 4 Sistem *direct injection*

(Sumber: M. Faizal & L. S. Chuah, 2019)

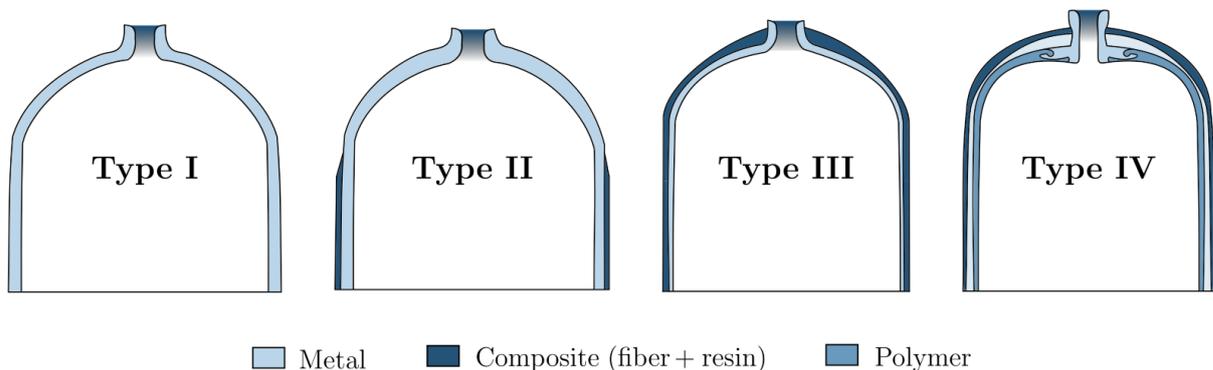
#### 2.1.4. Teknologi Penyimpanan Hidrogen

Penyimpanan hidrogen merupakan aspek krusial dalam pengembangan sistem energi berbasis hidrogen, khususnya dalam aplikasi kelautan yang menuntut efisiensi tinggi dan keselamatan operasional. Dalam konteks bahan bakar alternatif untuk kapal, hidrogen memiliki densitas energi gravimetrik yang tinggi dibandingkan bahan bakar konvensional seperti solar atau LNG, namun menghadapi tantangan dalam hal densitas energi volumetrik yang relatif rendah. Oleh karena itu, teknologi penyimpanan yang andal sangat dibutuhkan agar pemanfaatan hidrogen dapat berjalan efektif dan aman.

Secara umum, metode penyimpanan hidrogen dapat dibagi menjadi dua kategori utama: berbasis material (*material-based*) dan berbasis fisik (*physical-based*). Penyimpanan berbasis

fisik, seperti *compressed gaseous hydrogen (GH<sub>2</sub>)*, *liquid hydrogen (LH<sub>2</sub>)*, dan *cryo-compressed hydrogen (CCH<sub>2</sub>)*, menjadi fokus utama dalam aplikasi kelautan karena tingkat kesiapan teknologinya (Technology Readiness Level) yang lebih tinggi. Masing-masing metode memiliki karakteristik teknis tersendiri, seperti suhu operasi, tekanan, serta kebutuhan insulasi termal. LH<sub>2</sub>, misalnya, menawarkan densitas energi volumetrik lebih tinggi namun memerlukan insulasi ekstrem karena suhu operasionalnya yang sangat rendah (sekitar 20 K), sementara CCH<sub>2</sub> menjadi solusi kompromi antara tekanan dan suhu operasional.

Tantangan utama dalam penyimpanan hidrogen di lingkungan laut mencakup risiko embrittlement pada material akibat suhu kriogenik dan interaksi hidrogen dengan logam, potensi kebocoran akibat permeasi gas, serta akumulasi tekanan internal. Untuk mengatasi hal ini, telah dikembangkan berbagai jenis tangki penyimpanan seperti Type I hingga Type IV, yang menggabungkan struktur logam dan komposit untuk menyesuaikan kekuatan mekanik dan efisiensi massa. Selain itu, sistem insulasi seperti multilayer vacuum insulation (MLVI), variable-density multilayer insulation (VDMLI), serta penggunaan vapor-cooled shields juga digunakan untuk mengurangi perpindahan panas dan kehilangan hidrogen akibat boil-off.



Gambar 2. 5 Tipe-Tipe Tangki Hidrogen

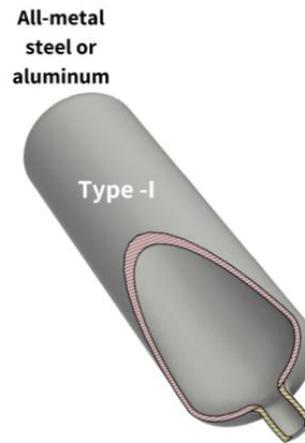
(Sumber: <https://stargatehydrogen.com//hydrogen-storage-solutions/>)

Berikut merupakan jenis-jenis tipe tangki penyimpanan hidrogen

#### 1. Tangki Tipe 1

Tangki Tipe I merupakan jenis tangki penyimpanan hidrogen paling dasar dan paling awal dikembangkan. Tangki ini sepenuhnya terbuat dari material logam, tanpa adanya pelapis atau penguat tambahan dari material komposit. Material logam yang umum digunakan untuk tangki jenis ini meliputi baja tahan karat (seperti SS 304L atau SS 316L) dan paduan aluminium. Tangki ini dirancang untuk menyimpan hidrogen dalam bentuk gas terkompresi (GH<sub>2</sub>) pada tekanan hingga 300 bar, dan

juga bisa digunakan untuk cryo-compressed hydrogen (CcH<sub>2</sub>) dengan penyesuaian tambahan. Kekuatan utama tangki ini terletak pada struktur logamnya yang mampu menahan tekanan internal secara langsung.



Gambar 2. 6 Tangki Hidrogen Tipe 1

(Sumber: <https://www.addcomposites.com/post/types-of-hydrogen-tanks-technological-differences-and-advantages-explained>)

Tangki ini memiliki keunggulan dalam hal ketahanan mekanik karena seluruh struktur berbahan logam. Desainnya yang sederhana dan teknologi manufakturnya yang telah matang menjadikan tangki ini mudah untuk diproduksi, diperbaiki, serta diperiksa kualitasnya. Biaya produksi tangki Tipe I juga relatif lebih rendah dibandingkan tipe tangki yang lebih kompleks. Karena konstruksinya logam penuh, tangki ini memiliki stabilitas termal yang tinggi dan tidak memerlukan perlakuan khusus terhadap sambungan antara material yang berbeda.

Kekurangan utama dari tangki Tipe I terletak pada bobotnya yang berat. Karena seluruh beban tekanan ditanggung oleh logam, tangki ini memiliki densitas gravimetrik yang rendah, yaitu hanya sekitar 1,7 persen berat, yang berarti hanya sebagian kecil dari berat total tangki merupakan hidrogen yang tersimpan. Hal ini menjadikan tangki ini kurang efisien dari sisi rasio penyimpanan terhadap massa total. Selain itu, untuk aplikasi suhu rendah seperti LH<sub>2</sub> atau CcH<sub>2</sub>, tangki ini memerlukan insulasi tambahan agar tidak terjadi kehilangan energi akibat perpindahan panas. Risiko korosi juga harus diperhatikan, terutama untuk penggunaan dalam lingkungan laut.

Material utama yang digunakan dalam tangki Tipe I adalah baja tahan karat dan paduan aluminium. Baja tahan karat memberikan kekuatan dan ketahanan terhadap

tekanan tinggi, sedangkan paduan aluminium menawarkan bobot yang lebih ringan meskipun dengan kekuatan yang lebih rendah. Tangki umumnya diproduksi melalui proses pengelasan atau pemrosesan tekanan tinggi untuk memastikan integritas strukturalnya.

Tangki Tipe I banyak digunakan dalam sistem penyimpanan stasioner, seperti stasiun pengisian hidrogen, sistem cadangan energi berbasis fuel cell, serta kapal-kapal kecil yang menggunakan hidrogen sebagai sumber energi. Karena kekuatannya yang tinggi dan desain yang sederhana, tangki ini juga digunakan untuk pengujian atau aplikasi eksperimental dalam pengembangan sistem propulsi hidrogen di sektor kelautan.

Dalam desain tangki Tipe I, perlu diperhatikan faktor-faktor seperti perlindungan terhadap korosi, ketahanan terhadap hidrogen embrittlement, dan kemampuan menahan tekanan tinggi secara berulang. Jika digunakan untuk penyimpanan hidrogen pada suhu kriogenik, tangki perlu dilengkapi insulasi multilapis atau sistem perlindungan panas lainnya. Karena bobotnya yang signifikan, penempatan tangki pada kapal harus memperhatikan distribusi beban dan dampaknya terhadap stabilitas kapal.

## 2. Tangki Tipe 2

Tangki Tipe II merupakan bentuk pengembangan dari tangki logam penuh (Tipe I) dengan menambahkan pembungkus komposit sebagian pada bagian silinder dari tangki. Struktur dasarnya tetap menggunakan liner logam, umumnya paduan aluminium, yang berfungsi untuk menahan tekanan internal dan menjaga kedap gas hidrogen. Bagian luar tangki dilapisi dengan serat komposit seperti serat karbon atau serat kaca yang dibungkus secara parsial menggunakan teknik filament winding. Desain ini bertujuan untuk memperkuat bagian tangki yang paling banyak menerima tekanan, tanpa membungkus seluruh permukaan tangki seperti pada tipe III dan IV.



Gambar 2. 7 Tangki Hidrogen Tipe 2

(Sumber: <https://www.addcomposites.com/post/types-of-hydrogen-tanks-technological-differences-and-advantages-explained>)

Tangki Tipe II memiliki keunggulan dari segi bobot yang lebih ringan dibandingkan Tipe I karena pembungkus komposit mengurangi kebutuhan ketebalan pada liner logam. Meskipun tidak seefisien tangki komposit penuh, tipe ini sudah menawarkan peningkatan densitas gravimetrik hingga sekitar 2,1 persen berat, yang berarti dapat menyimpan lebih banyak hidrogen dalam bobot tangki yang lebih ringan. Biaya produksinya juga lebih rendah dibandingkan tangki komposit penuh karena masih mempertahankan struktur logam yang sederhana. Selain itu, proses fabrikasinya lebih mudah disesuaikan dengan fasilitas produksi tangki logam konvensional.

Meskipun lebih ringan dari tangki logam penuh, tangki Tipe II tetap lebih berat dibandingkan tangki komposit penuh. Hal ini disebabkan karena sebagian besar struktur tangki masih bergantung pada liner logam. Pembungkus komposit yang hanya sebagian membuat distribusi tekanan tidak optimal tangki dengan pembungkus penuh. Tangki ini juga kurang cocok untuk penyimpanan pada tekanan sangat tinggi di atas 350 bar, karena pembungkus parsial tidak mampu memberikan kekuatan penuh yang diperlukan. Selain itu, potensi delaminasi antara lapisan komposit dan liner logam menjadi salah satu risiko teknis jika tidak dilakukan kontrol kualitas yang ketat saat proses manufaktur.

Tangki Tipe II digunakan secara luas dalam sektor kendaraan berat berbahan bakar hidrogen dan mulai dikembangkan untuk aplikasi maritim seperti kapal kecil

dan sistem penyimpanan cadangan di atas kapal. Tipe ini cocok untuk sistem dengan tekanan menengah hingga 300 bar, seperti yang dibutuhkan dalam sistem bahan bakar berbasis fuel cell. Penggunaannya juga ditemukan pada sistem stasiun pengisian hidrogen, kendaraan komersial, serta sistem transportasi yang menuntut kombinasi antara kekuatan, efisiensi, dan biaya yang seimbang.

Penggunaan dua jenis material berbeda (logam dan komposit) memerlukan perhatian khusus dalam desain sambungan agar tidak terjadi kegagalan akibat perbedaan sifat termal. Selain itu, tangki ini perlu dilengkapi sistem pengaman tekanan untuk menghindari kebocoran atau ledakan akibat tekanan berlebih. Jika digunakan dalam penyimpanan suhu kriogenik seperti cryo-compressed hydrogen (CCH<sub>2</sub>), tangki memerlukan insulasi tambahan untuk mencegah perpindahan panas dan menjaga kestabilan termal.

### 3. Tangki Tipe 3

Tangki Tipe III adalah jenis tangki hidrogen bertekanan tinggi yang menggabungkan liner logam di bagian dalam dan pembungkus komposit penuh di seluruh permukaan tangki. Artinya, seluruh permukaan luar tangki dibungkus dengan serat komposit, tidak hanya bagian silinder seperti pada Tipe II. Teknologi filament winding digunakan untuk melilitkan serat komposit secara menyeluruh guna memperkuat struktur tangki dan menahan tekanan internal.

Liner logam biasanya hanya berfungsi sebagai penahan gas dan pelindung terhadap difusi hidrogen, sementara kekuatan utama tangki berasal dari lapisan komposit yang melilitinya. Tangki ini umumnya digunakan untuk penyimpanan *compressed gaseous hydrogen* (GH<sub>2</sub>) hingga tekanan 700 bar, dan juga cocok untuk penyimpanan *cryo-compressed hydrogen* (CCH<sub>2</sub>) dengan tambahan sistem insulasi.



Gambar 2. 8 Tangki Hidrogen Tipe 3

(Sumber: <https://www.addcomposites.com/post/types-of-hydrogen-tanks-technological-differences-and-advantages-explained>)

Tangki Tipe III memiliki bobot yang jauh lebih ringan dibandingkan tipe I dan II karena sebagian besar beban mekanik ditanggung oleh material komposit. Tangki ini juga memiliki densitas gravimetrik yang tinggi, yaitu sekitar 4,2 persen berat, sehingga mampu menyimpan lebih banyak hidrogen dalam bobot total yang lebih ringan. Selain itu, tangki ini mendukung penyimpanan hidrogen pada tekanan sangat tinggi hingga 700 bar dan memiliki risiko korosi yang lebih rendah karena penggunaan logam diminimalkan.

Meskipun unggul secara teknis, tangki Tipe III memiliki biaya produksi yang lebih tinggi dibandingkan tipe I dan II. Proses pembuatannya memerlukan bahan baku premium seperti serat karbon dan teknik manufaktur presisi tinggi. Kompleksitas dalam menggabungkan material logam dan komposit juga menambah tantangan, terutama dalam menghadapi perubahan suhu ekstrem yang dapat menimbulkan tegangan termal. Selain itu, material komposit lebih sulit untuk didaur ulang dibandingkan logam.

Liner dalam pada tangki ini biasanya terbuat dari paduan aluminium ringan seperti AA6061, yang berfungsi menjaga kedekatan terhadap gas hidrogen. Bagian luar tangki dibungkus penuh dengan serat karbon atau kombinasi serat aramid dan kaca, yang diikat dengan resin epoksi melalui proses *filament winding* otomatis.

Tangki Tipe III digunakan dalam berbagai aplikasi yang membutuhkan tekanan tinggi dan efisiensi berat maksimal. Di bidang maritim, tangki ini cocok untuk kapal berbahan bakar hidrogen yang beroperasi pada jarak jauh dan memerlukan daya

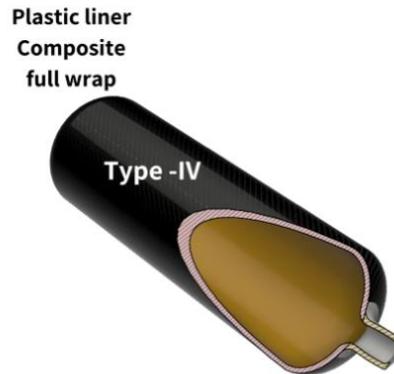
besar. Selain itu, tangki ini juga digunakan dalam kendaraan berat seperti truk atau bus berbahan bakar hidrogen, serta sistem penyimpanan energi terdistribusi untuk sektor energi bersih. Contoh penerapannya antara lain pada kapal penumpang seperti *Hydroville* dan SF-BREEZE.

Desain sambungan antara logam dan komposit harus mempertimbangkan perbedaan koefisien ekspansi termal agar tidak terjadi delaminasi. Tangki ini juga harus dilengkapi dengan sistem ventilasi dan perangkat pelepas tekanan (PRD) untuk menghindari kerusakan akibat tekanan berlebih. Uji ketahanan terhadap siklus tekanan dan suhu kriogenik menjadi bagian penting dalam proses sertifikasi dan penerapan pada lingkungan laut.

#### 4. Tangki Tipe 4

Tangki Tipe IV merupakan generasi paling mutakhir dalam teknologi penyimpanan hidrogen bertekanan tinggi. Tangki ini tidak lagi menggunakan logam sebagai liner, melainkan memanfaatkan material polimer seperti polietilen berdensitas tinggi (HDPE) atau poliamida sebagai lapisan dalam. Seluruh struktur luar tangki dibungkus sepenuhnya oleh serat komposit menggunakan teknik filament winding. Material komposit yang digunakan umumnya adalah serat karbon, aramid, atau serat kaca yang diikat dengan resin epoksi. Karena seluruh kekuatan tangki bertumpu pada pembungkus komposit, tipe ini menawarkan efisiensi berat yang sangat tinggi dan digunakan untuk menyimpan hidrogen pada tekanan hingga 700 bar atau lebih.

Tangki Tipe IV merupakan jenis tangki paling ringan di antara semua tipe, dengan densitas gravimetrik mencapai sekitar 5,7 persen berat. Hal ini memungkinkan penyimpanan hidrogen dalam jumlah besar dengan bobot tangki yang sangat minim, menjadikannya ideal untuk aplikasi transportasi yang menuntut efisiensi energi tinggi. Karena tidak menggunakan logam, tangki ini juga bebas dari risiko korosi galvanik. Desainnya yang fleksibel memudahkan produsen menyesuaikan bentuk dan ukuran tangki sesuai kebutuhan ruang pada kendaraan atau kapal.



Gambar 2. 9 Tangki Tipe 4

(Sumber: <https://www.addcomposites.com/post/types-of-hydrogen-tanks-technological-differences-and-advantages-explained>)

Meskipun sangat ringan dan efisien, tangki Tipe IV memiliki tantangan dalam hal ketahanan terhadap penetrasi hidrogen dan pengaruh suhu ekstrem. Liner polimer memiliki permeabilitas gas yang lebih tinggi dibanding logam, sehingga berisiko mengalami kebocoran jangka panjang akibat difusi hidrogen. Selain itu, material polimer cenderung rapuh pada suhu kriogenik, sehingga penggunaan tangki ini untuk penyimpanan *liquid hydrogen* (LH<sub>2</sub>) atau *cryo-compressed hydrogen* (CCH<sub>2</sub>) memerlukan penyesuaian struktural dan sistem insulasi tambahan. Dari segi biaya, tangki ini juga memiliki harga tinggi karena penggunaan serat komposit kelas premium dan proses manufaktur yang kompleks.

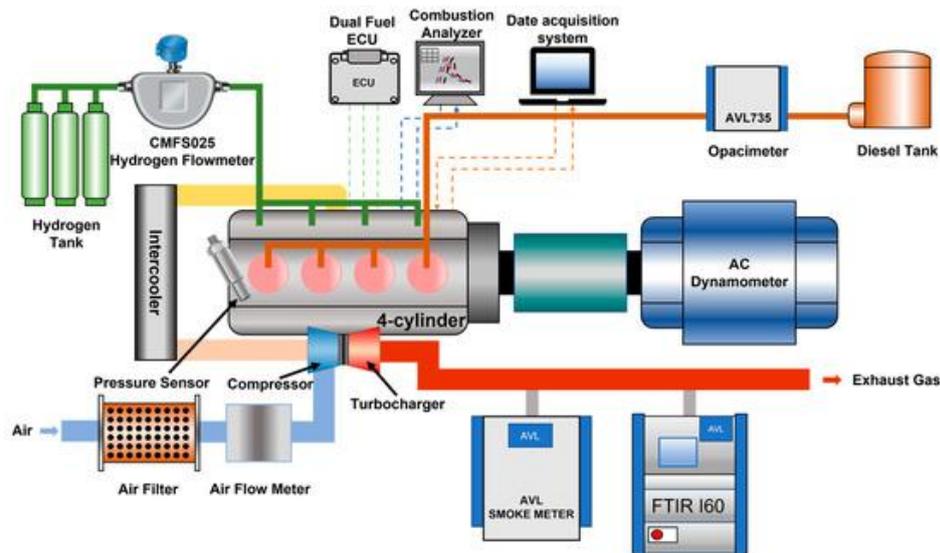
Liner dalam menggunakan material termoplastik seperti HDPE atau poliamida, yang memiliki fleksibilitas tinggi dan cukup tahan terhadap interaksi kimia dengan hidrogen. Bagian luar tangki dibungkus penuh oleh serat karbon yang diatur sedemikian rupa untuk menahan tekanan secara merata di seluruh permukaan. Resin epoksi berfungsi sebagai pengikat serat agar struktur tetap kaku dan kuat. Karena tidak ada elemen logam, sambungan tangki, leher pengisian, dan katup pengaman harus didesain agar kompatibel dengan bahan polimer dan tidak menyebabkan deformasi saat beroperasi dalam tekanan tinggi.

Tangki Tipe IV banyak digunakan dalam industri otomotif, khususnya pada kendaraan berbahan bakar hidrogen seperti mobil penumpang, bus, dan truk. Di sektor maritim, tangki ini mulai diterapkan pada kapal kecil dan sistem penyimpanan

cadangan energi, terutama jika bobot dan efisiensi ruang menjadi faktor utama. Selain itu, tipe ini digunakan dalam sistem penyimpanan energi terdistribusi untuk pembangkit listrik berbasis hidrogen, karena dapat dengan mudah disesuaikan dengan kebutuhan ruang dan tekanan.

### 2.1.5. Implementasi hybrid hydrogen diesel engine pada kapal

Implementasi mesin hybrid hydrogen-diesel pada kapal merupakan salah satu langkah strategis dalam upaya dekarbonisasi sektor maritim. Sistem ini menggabungkan penggunaan bahan bakar hidrogen sebagai co-fuel bersama bahan bakar solar (diesel) dalam mesin pembakaran dalam (*internal combustion engine*). Teknologi ini tidak sepenuhnya menggantikan diesel, tetapi mengurangi porsi penggunaannya dengan cara menginjeksikan hidrogen ke dalam ruang bakar secara bersamaan. Pendekatan ini terbukti mampu menurunkan emisi gas buang, meningkatkan efisiensi pembakaran, dan mendukung transisi energi pada industri pelayaran.



Gambar 2. 10 Skematik Sistem Mesin Hybrid Hydrogen-Diesel

(Sumber: Longlong Xu et al, 2023)

#### 1. Treatment Hidrogen

Agar dapat digunakan dalam sistem mesin kapal, hidrogen memerlukan perlakuan khusus (treatment) dan infrastruktur pendukung. Berdasarkan Gambar 2.10, perlakuan hidrogen melibatkan beberapa tahap sebagai berikut:

##### - Penyimpanan di Kapal

Hidrogen disimpan dalam tangki tekanan tinggi atau tangki kriogenik. Dalam gambar sistem, hidrogen dari tangki disalurkan melalui *hydrogen flowmeter* (CMF5025) untuk

mengukur laju aliran gas sebelum masuk ke sistem injeksi. Karena sifat hidrogen yang sangat reaktif, diperlukan sistem pengaman berlapis. (Moccia et al., 2022)

- Sistem Regulasi dan Injeksi

Setelah melewati flowmeter, hidrogen diarahkan menuju intake manifold mesin. Sebelum itu, tekanan hidrogen diturunkan melalui pressure regulator, kemudian disesuaikan dengan *fuel metering valve*. Proses ini dikendalikan oleh Dual Fuel ECU, yang menentukan jumlah dan waktu injeksi hidrogen berdasarkan masukan dari sensor suhu, beban, dan throttle mesin. (Yoon et al., 2016)

## 2. Komponen Sistem *Hybrid Hydrogen-Diesel*

Berdasarkan Gambar 2.10, komponen utama dari sistem *hybrid hydrogen-diesel engine* terdiri dari:

- *Diesel Engine Core (4-cylinder)*

Mesin diesel tetap berfungsi sebagai sumber utama tenaga dan penginisiasi pembakaran melalui pilot injection.

- *Hydrogen Supply Line*

Terdiri dari tangki hidrogen, *flowmeter*, regulator tekanan, dan injektor. Hidrogen disalurkan ke *intake manifold* untuk bercampur dengan udara sebelum masuk ruang bakar.

- *Air Intake System*

Udara masuk melalui filter udara, diukur oleh *air flow meter*, dikompresi oleh *compressor* atau *turbocharger*, kemudian dicampur dengan hidrogen dan udara di dalam manifold. Tekanan udara dipantau oleh *pressure sensor*.

- *Dual Fuel ECU & Combustion Analyzer*

ECU bertugas mengatur proporsi solar dan hidrogen, serta mengontrol parameter operasi. *Combustion analyzer* digunakan untuk memantau kinerja pembakaran secara real-time.

- Emission Monitoring System

Emisi gas buang dipantau dengan berbagai alat ukur seperti:

- o *Opacimeter (AVL735)* untuk mengukur kepekatan asap.
- o *Smoke Meter* untuk partikel padat (PM).
- o FTIR I60 untuk analisis emisi gas seperti CO<sub>2</sub>, NO<sub>x</sub>, dan HC secara spektral.

- *Cooling and Safety System*

Sistem pendingin dan deteksi kebocoran diperlukan karena hidrogen memiliki ambang ledak yang rendah dan cepat terbakar. (Karim, 2003)

#### **2.1.6. Kecerdasan Buatan dalam pengaturan komposisi bahan bakar**

Dalam pengoperasian mesin kapal berbasis hybrid hidrogen-diesel, pengaturan komposisi bahan bakar memegang peranan penting dalam menjaga efisiensi termal dan mengurangi emisi gas buang. Salah satu pendekatan modern yang mulai berkembang dalam bidang ini adalah penerapan kecerdasan buatan atau *artificial intelligence* (AI). Teknologi ini memungkinkan sistem untuk mempelajari pola pembakaran dan karakteristik performa mesin melalui data historis maupun data real-time. Dengan memanfaatkan algoritma machine learning, AI mampu memprediksi kinerja mesin berdasarkan berbagai kombinasi rasio hidrogen dan diesel, serta kondisi operasional yang berubah-ubah. Sebuah studi yang dilakukan oleh tim peneliti dari sektor otomotif dan energi bersih menunjukkan bahwa penggabungan metode *reinforcement learning* dan *model predictive control* dapat menghasilkan sistem kontrol adaptif yang secara otomatis mengatur suplai bahan bakar hidrogen dan diesel untuk mencapai efisiensi optimal pada berbagai beban kerja mesin. (Rupp et al., 2024)

AI tidak hanya digunakan untuk optimasi rasio bahan bakar, tetapi juga dapat berfungsi dalam sistem pemeliharaan prediktif. Dengan memanfaatkan sensor dan model prediktif berbasis data, sistem mampu mendeteksi gejala awal kerusakan pada komponen mesin sebelum kegagalan terjadi. Dalam studi lainnya, pendekatan *generative models* digunakan untuk memperbanyak variasi data kegagalan (failure data), yang pada umumnya sulit diperoleh dalam sistem yang masih baru seperti hybrid hydrogen-diesel engine. Dengan pendekatan ini, akurasi prediksi kegagalan dapat ditingkatkan sehingga operator kapal memiliki waktu respons yang lebih baik dalam melakukan perawatan. (Xie et al., 2023)

Lebih lanjut, model jaringan syaraf tiruan atau *artificial neural network* (ANN) telah diterapkan untuk memetakan hubungan antara rasio campuran hidrogen-diesel terhadap output mesin, seperti emisi NOx, konsumsi bahan bakar spesifik, dan efisiensi pembakaran. Model ANN ini menunjukkan hasil prediksi yang sangat akurat dengan nilai koefisien determinasi ( $R^2$ ) di atas 0,95. Hasil ini membuktikan bahwa AI dapat menjadi alat yang sangat potensial untuk mendukung simulasi dan perancangan sistem bahan bakar hybrid berbasis hidrogen dalam konteks pengembangan teknologi propulsi kapal yang ramah lingkungan. (Ali et al., 2023)

Dengan meningkatnya kebutuhan akan efisiensi energi dan penurunan emisi dalam industri pelayaran, integrasi AI dalam sistem bahan bakar hybrid tidak hanya memberikan

keunggulan operasional tetapi juga membuka peluang baru dalam pengembangan mesin yang cerdas dan adaptif terhadap berbagai tantangan laut. Maka dari itu, penelitian dan penerapan AI dalam pengaturan bahan bakar dan pemeliharaan prediktif menjadi langkah strategis menuju sistem propulsi kapal masa depan yang lebih berkelanjutan.

### 2.1.7. Perhitungan Efisiensi Bahan Bakar

Untuk memahami perhitungan efisiensi bahan bakar pada mesin hybrid, kita bisa menggunakan beberapa konsep dasar dari termodinamika dan mekanika fluida. Berikut adalah beberapa langkah kunci dalam perhitungan ini:

#### 1. Efisiensi Termal (Thermal Efficiency):

Efisiensi termal adalah ukuran seberapa baik suatu mesin mengubah energi dari bahan bakar menjadi kerja (energi mekanik yang berguna). Dalam konteks sistem propulsi kapal, efisiensi termal menunjukkan proporsi energi dari bahan bakar (seperti hidrogen dan diesel) yang benar-benar dimanfaatkan untuk menghasilkan daya gerak atau listrik, dibandingkan dengan energi yang hilang dalam bentuk panas atau emisi.

Rumus dasar efisiensi termal ditulis sebagai:

$$\eta_{th} = \frac{W_{out}}{Q_{in}} \quad (2.1)$$

Keterangan:

- $\eta_{th}$  adalah efisiensi termal (dinyatakan dalam persen atau desimal),
- $W_{out}$  adalah total kerja keluaran mesin (biasanya dalam satuan joule, kWh, atau kW selama durasi tertentu),
- $Q_{in}$  adalah total energi bahan bakar yang masuk ke sistem (dihitung dari nilai kalor bahan bakar dikalikan dengan laju alir bahan bakar).

Sebuah sistem hybrid kapal dengan kombinasi internal combustion engine (ICE), gas turbine (GT), dan solid oxide fuel cell (SOFC) diuji efisiensi termalnya. Dengan menggunakan bahan bakar campuran hidrogen dan dimetil eter, sistem ini mampu menghasilkan daya maksimum 27.773 kW. Energi bahan bakar yang masuk dihitung berdasarkan total massa bahan bakar dan nilai kalor masing-masing jenis bahan bakar.

Hasilnya, efisiensi termal sistem ini mencapai 34 persen, jauh lebih tinggi dibandingkan mesin diesel konvensional yang hanya mencapai sekitar 22,9 persen. Hal ini menunjukkan bahwa pemanfaatan hidrogen dalam sistem hybrid tidak hanya

mengurangi emisi, tetapi juga mampu meningkatkan efektivitas konversi energi bahan bakar menjadi kerja. (Seyam et al, 2023),

## 2. Efisiensi Eksergi (Exergy Efficiency):

Efisiensi eksergi adalah ukuran seberapa efektif suatu sistem dalam menggunakan kualitas energi yang tersedia dari bahan bakar untuk menghasilkan kerja. Tidak seperti efisiensi termal yang hanya mempertimbangkan jumlah energi, efisiensi eksergi juga mempertimbangkan potensi kerja maksimum yang bisa diperoleh dari suatu sumber energi ketika berinteraksi dengan lingkungan sekitarnya (dalam keadaan seimbang termodinamika).

Efisiensi ini sangat penting dalam sistem energi modern karena membantu mengukur seberapa besar energi yang benar-benar berguna, bukan hanya energi totalnya.

Rumus umum efisiensi eksergi adalah:

$$\eta_{ex} = \frac{E_{out}}{E_{in}} \quad (2.2)$$

Keterangan:

- $\eta_{ex}$  adalah efisiensi eksergi,
- $E_{out}$  adalah total eksergi keluaran (kerja yang berguna secara ideal),
- $E_{in}$  adalah total eksergi masukan (kemampuan maksimal energi dari bahan bakar untuk menghasilkan kerja).

Efisiensi eksergi digunakan untuk menilai seberapa efektif sistem hybrid (ICE + GT + SOFC) mengubah potensi energi dari campuran bahan bakar (hidrogen, metanol, etanol, dimetil eter) menjadi kerja aktual. Mereka menemukan bahwa:

- Sistem ICE konvensional dengan marine gas oil hanya mencapai 29 persen efisiensi eksergi,
- Sementara sistem hybrid dengan konfigurasi fuel cell mampu mencapai 44 persen efisiensi eksergi.

Hal ini menunjukkan bahwa sistem hybrid tidak hanya lebih efisien secara kuantitas energi (seperti pada efisiensi termal), tetapi juga secara kualitas, karena mampu meminimalkan pemborosan energi akibat disipasi panas dan ketidakterbalikan proses termodinamika. (Seyam et al. 2023)

## 3. Spesifik Konsumsi Bahan Bakar (Specific Fuel Consumption, SFC):

Specific Fuel Consumption (SFC) adalah parameter yang digunakan untuk mengukur efisiensi pemakaian bahan bakar dalam suatu mesin. SFC menyatakan berapa banyak bahan bakar (dalam satuan massa) yang dibutuhkan untuk menghasilkan satu unit daya dalam waktu tertentu. SFC menjadi ukuran langsung dari seberapa boros atau hemat suatu mesin dalam menggunakan bahan bakar.

Secara matematis, rumusnya adalah:

$$SFC = \frac{m_f}{P} \quad (2.3)$$

**Keterangan:**

- SFC adalah konsumsi bahan bakar spesifik, biasanya dinyatakan dalam gram per kilowatt-jam (g/kWh),
- $m_f$  adalah laju aliran massa bahan bakar, yaitu jumlah bahan bakar yang dikonsumsi per satuan waktu (gram/jam),
- P adalah daya keluaran dari mesin dalam satuan kilowatt (kW).

Nilai SFC memungkinkan perbandingan performa mesin yang menggunakan bahan bakar berbeda, atau konfigurasi mesin yang berbeda (konvensional vs hybrid). Mesin dengan nilai SFC lebih rendah dianggap lebih efisien, karena dapat menghasilkan daya lebih besar dengan jumlah bahan bakar yang lebih sedikit.

Nilai SFC digunakan untuk membandingkan konsumsi bahan bakar antara mesin diesel konvensional dan sistem hybrid berbahan bakar campuran hidrogen. Hasil studi menunjukkan bahwa:

- Mesin diesel konvensional memiliki nilai SFC sebesar 325 g/kWh, artinya untuk menghasilkan 1 kWh energi, mesin membutuhkan 325 gram bahan bakar.
- Sistem hybrid dengan campuran hidrogen dan etanol (MF3) menurunkan nilai SFC menjadi hanya 266.6 g/kWh, atau lebih hemat sekitar 18 persen.

Penurunan nilai SFC ini membuktikan bahwa penambahan hidrogen sebagai bagian dari komposisi bahan bakar dapat meningkatkan efisiensi pembakaran sekaligus menurunkan konsumsi bahan bakar secara keseluruhan. (Seyam et al. 2023)

Dalam konteks kapal, penurunan SFC berdampak besar pada biaya operasional jangka panjang dan logistik bahan bakar. Terutama untuk pelayaran jarak jauh, semakin kecil nilai SFC, semakin hemat bahan bakar yang dibawa dan digunakan, sehingga efisiensi distribusi serta daya jelajah kapal meningkat. Kombinasi teknologi hybrid dan

optimasi rasio bahan bakar melalui bantuan kecerdasan buatan (AI) dapat memperkecil nilai SFC secara dinamis tergantung beban dan kondisi operasional.

#### 4. Pengurangan Emisi:

Pengurangan emisi adalah indikator penting dalam evaluasi performa sistem propulsi modern, khususnya yang berbasis energi bersih. Tujuan utama dari penggunaan bahan bakar alternatif seperti hidrogen adalah untuk mengurangi emisi gas buang berbahaya, seperti karbon dioksida (CO<sub>2</sub>), nitrogen oksida (NO<sub>x</sub>), karbon monoksida (CO), dan hidrokarbon (HC). Evaluasi ini menjadi sangat penting dalam industri maritim karena tekanan global terhadap pemenuhan regulasi emisi seperti IMO 2020 dan target dekarbonisasi tahun 2050.

Untuk menghitung pengurangan emisi, digunakan rumus berikut:

$$\text{Pengurangan Emisi (\%)} = \frac{\text{Emisi Referensi} - \text{Emisi Baru}}{\text{Emisi Referensi}} \times 100 \quad (2.4)$$

##### **Keterangan:**

- Emisi Referensi adalah jumlah emisi yang dihasilkan oleh sistem lama (misalnya mesin diesel konvensional),
- Emisi Baru adalah jumlah emisi dari sistem baru (misalnya mesin hybrid hidrogen-diesel).

Dalam studi oleh Seyam et al. (2023), sistem hybrid yang menggabungkan ICE, gas turbine, dan solid oxide fuel cell diuji menggunakan berbagai campuran bahan bakar hidrogen. Hasilnya menunjukkan pengurangan signifikan pada emisi, di antaranya:

- CO<sub>2</sub> turun hingga 61.6 persen saat menggunakan campuran hidrogen dan dimetil eter dibandingkan dengan sistem berbahan bakar marine gas oil (MGO),
- Emisi NO<sub>x</sub>, CO, dan HC juga menurun drastis karena pembakaran hidrogen tidak menghasilkan senyawa karbon, dan suhu pembakaran lebih rendah membantu mengurangi pembentukan NO<sub>x</sub>.

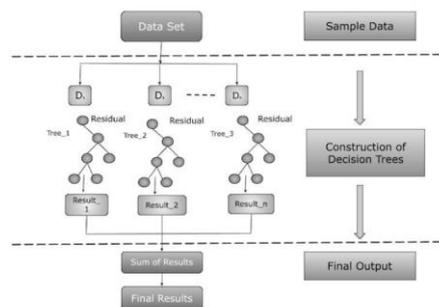
Penggunaan AI dalam sistem hybrid juga memungkinkan pengaturan rasio bahan bakar secara dinamis untuk menjaga tingkat emisi tetap rendah sesuai target operasional, tanpa mengorbankan performa.

Dengan berkurangnya konsumsi bahan bakar dan emisi yang lebih rendah, sistem hybrid hidrogen-diesel menunjukkan potensi yang kuat sebagai solusi transisi menuju propulsi kapal masa depan yang lebih ramah lingkungan dan efisien energi.

### 2.1.8. XGBoost Regressor

XGBoost (Extreme Gradient Boosting) merupakan algoritma machine learning yang berbasis pada teknik gradient boosting dan dirancang untuk memberikan efisiensi tinggi, skalabilitas, dan akurasi prediksi yang superior. Sejak kemunculannya pada pertengahan tahun 2010-an, XGBoost telah menjadi salah satu algoritma paling populer dan sering digunakan dalam berbagai kompetisi data science karena performanya yang luar biasa dalam menangani data terstruktur baik untuk regresi maupun klasifikasi.

Arsitektur XGBoost terdiri dari dua komponen utama, yaitu pembelajaran sekuensial dan ensembling. Pada pembelajaran sekuensial, model membangun pohon keputusan secara bertahap, di mana setiap pohon baru dibentuk untuk memperbaiki kesalahan prediksi dari pohon sebelumnya. XGBoost menggunakan pendekatan gradient descent untuk mengoptimasi bobot prediksi dan meminimalkan fungsi kerugian (*loss function*) secara iteratif. Ini berarti bahwa setiap pohon dilatih dengan fokus pada data yang diprediksi salah oleh pohon sebelumnya, menjadikannya pembelajar yang kuat dari banyak pembelajar lemah (*weak learners*).



Gambar 2. 11 Arsitektur XGBoost

(Sumber: <https://www.tutorialspoint.com/xgboost/xgboost-architecture.htm>)

Sementara itu, melalui mekanisme ensemble, XGBoost menggabungkan seluruh pohon keputusan yang telah dibuat menjadi satu model akhir. Output prediksi akhir merupakan hasil penjumlahan tertimbang dari seluruh pohon dalam ensemble, di mana bobot ditentukan berdasarkan performa masing-masing pohon.

Keunggulan utama XGBoost terletak pada regularisasi (baik L1 maupun L2) yang diintegrasikan langsung ke dalam proses boosting. Ini memberikan keunggulan dalam menghindari overfitting dan menjaga generalisasi model terhadap data baru. Selain itu, XGBoost mendukung pemrosesan paralel, yang membuat proses pelatihan jauh lebih cepat dibanding metode boosting konvensional. XGBoost juga bersifat fleksibel karena memungkinkan pengguna untuk menyesuaikan tujuan optimasi dan fungsi evaluasi yang digunakan.

Dalam konteks penelitian ini, XGBoost dipilih sebagai salah satu kandidat model prediktif karena kemampuannya dalam mengolah data numerik multivariabel secara efisien, menangani data hilang (*missing values*), serta memberikan performa tinggi bahkan pada dataset berukuran relatif kecil namun kompleks. Proses pelatihannya yang berbasis *supervised learning* menjadikan model ini sangat cocok untuk memahami pola hubungan antara input dan output dalam simulasi performa mesin hybrid hydrogen-diesel.

### 2.1.8.1. Strategi Augmentasi Data XGBoost

Untuk meningkatkan kemampuan generalisasi model, digunakan teknik augmentasi data berbasis *resampling* dan *bootstrap aggregation* (bagging). Teknik ini melibatkan pembuatan data sintetis melalui proses sebagai berikut:

1. Dilakukan *resampling* terhadap data latih: sejumlah sampel dipilih ulang secara acak dengan pengembalian (*with replacement*).
2. Data resample tersebut kemudian diprediksi menggunakan model yang sudah dilatih, menghasilkan target sintetis  $\hat{y}_{synth}$ .
3. Data dan target sintetis kemudian digabungkan kembali ke dalam dataset penuh ( $X_{full}$  dan  $y_{full}$ ), memperbesar ukuran data latih secara bertahap pada setiap iterasi.

Secara matematis, proses augmentasi ini dinyatakan sebagai:

$$X_{synth} \sim Resample(X_{full}, n = N) \quad (2.5)$$

$$\hat{y}_{synth} = f(X_{synth}) \quad (2.6)$$

$$X_{full} = X_{full} \cup X_{synth}, y_{full} = y_{full} \cup \hat{y}_{synth} \quad (2.7)$$

Keterangan:

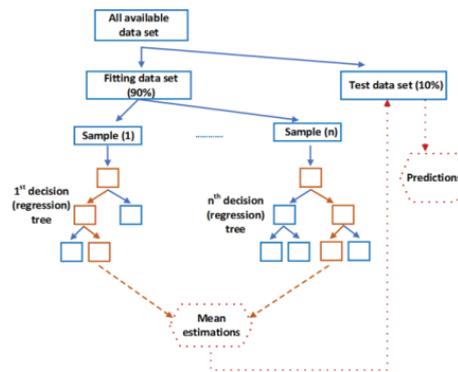
- $X_{full}$  dan  $y_{full}$  adalah data fitur dan target saat ini,
- $f(\cdot)$  adalah fungsi prediksi model XGBoost yang telah dilatih,
- Proses ini diulang setiap iterasi hingga model mencapai ambang batas performa tertentu,  $R^2 > 0.85$ .

### 2.1.9. Random Forest Regressor (RFR)

*Random Forest Regressor* (RFR) merupakan salah satu metode machine learning berbasis ensemble yang menggunakan banyak pohon keputusan (decision trees) untuk melakukan prediksi terhadap variabel kontinu. Algoritma ini diperkenalkan oleh Breiman (2001) dan menjadi populer karena kemampuannya dalam menghasilkan model prediktif yang akurat dan tahan terhadap *overfitting*, bahkan ketika diterapkan pada data non-linear dan kompleks.

Dalam penelitian yang dilakukan oleh Diamantopoulou (2022), RFR digunakan untuk mensimulasikan diameter pohon pada berbagai ketinggian batang, sebuah tantangan klasik dalam pengukuran kehutanan. Metode ini terbukti dapat mengatasi keterbatasan model regresi non-linear tradisional, yang memerlukan asumsi distribusi tertentu, estimasi parameter awal, serta struktur model yang telah didefinisikan sebelumnya. Sebaliknya, RFR tidak memerlukan bentuk persamaan tertentu dan dapat belajar langsung dari data mentah, menjadikannya lebih fleksibel dan efisien.

Secara arsitektural, algoritma RFR membangun ratusan pohon keputusan dari subset data yang berbeda-beda melalui teknik *bootstrapping* (juga dikenal sebagai *bagging*). Setiap pohon dalam hutan dilatih pada sampel acak dari data pelatihan, dan prediksi akhir adalah hasil rata-rata dari semua pohon tersebut. Proses ini mengurangi varians model dan menghasilkan prediksi yang lebih stabil. Selain itu, karena setiap pohon bekerja secara independen, RFR mendukung pemrosesan paralel yang membuat proses pelatihan lebih cepat.



Gambar 2. 12 Arsitektur Random Forest Regressor

(Sumber: Diamantopoulou, 2022)

Salah satu keunggulan penting dari RFR adalah kemampuannya untuk menangani data yang memiliki hubungan non-linear serta kemampuan bawaan dalam mengukur pentingnya setiap fitur (*feature importance*). Hal ini memungkinkan identifikasi fitur mana yang paling berpengaruh terhadap variabel target. Dalam kasus penelitian ini, fitur-fitur seperti *hydrogen ratio*, *brake thermal efficiency*, dan parameter emisi lainnya menjadi sangat penting untuk dipelajari secara mendalam oleh algoritma.

Namun demikian, RFR juga memiliki beberapa kelemahan, terutama dalam hal ekstrapolasi. Model ini tidak mampu memprediksi nilai di luar rentang data pelatihan karena tidak memiliki struktur fungsi eksplisit yang mendukung generalisasi secara matematis. Oleh karena itu, akurasi model sangat bergantung pada kelengkapan dan keragaman data pelatihan.

Dalam eksperimen ini, RFR digunakan sebagai salah satu kandidat model pembelajaran untuk mempelajari hubungan antara input simulasi dan output performa mesin hybrid hydrogen-diesel. Dengan memanfaatkan struktur ensemble-nya, model ini dilatih dan dievaluasi menggunakan metrik  $R^2$ , MAE, dan validasi silang (*cross validation*). Hasil yang diperoleh dari RFR kemudian dibandingkan dengan model lain seperti XGBoost, DNN, dan MLP untuk menentukan model paling optimal yang akan digunakan dalam simulasi akhir.

### 2.1.9.1. Strategi Augmentasi Data Random Forest Regressor

Untuk meningkatkan kemampuan generalisasi model, teknik augmentasi data diterapkan melalui *resampling sintesis*. Proses ini dilakukan dengan menggunakan metode *bootstrap resampling* dari data latih untuk menghasilkan data baru, lalu menggunakan model yang telah dilatih untuk memprediksi nilai target dari data sintesis tersebut. Hasilnya kemudian ditambahkan kembali ke dataset utama. Formulasi dasar augmentasi dalam penelitian ini adalah

$$X_{synth} = Resample(X_{full}, n = 100, \hat{y}_{synth} = Model.Predict(X_{synth})) \quad (2.8)$$

Keterangan:

- $X_{full}$  dan  $y_{full}$  adalah data fitur dan target keseluruhan,
- $X_{synth}$  adalah data fitur baru hasil resampling dari  $X_{full}$ , sebanyak 100 sampel
- $Y_{synth}$  adalah prediksi nilai target  $Y_{synth}$  menggunakan model yang telah dilatih
- Resampling adalah fungsi untuk melakukan pengambilan sampel acak dari data asli dengan pengembalian
- Model.predict adalah fungsi dari model pembelajaran mesin yang digunakan untuk memprediksi nilai target dari data input.

Setelah data sintesis ( $X_{synth}$  dan  $Y_{synth}$ ) diperoleh, maka kedua set tersebut digabungkan kembali ke dataset utama dengan operasi:

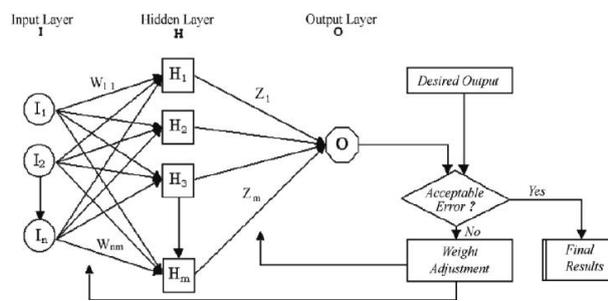
$$X_{full} = X_{full} \cup X_{synth}, y_{full} = y_{full} \cup \hat{y}_{synth} \quad (2.9)$$

Keterangan:

- $\cup$  adalah operasi penggabungan dua himpunan (dalam konteks ini, dua buah *DataFrame*)
- $X_{full} \cup X_{synth}$  berfungsi menambahkan data sintesis ke data asli pada bagian fitur.
- $y_{full} \cup \hat{y}_{synth}$  berfungsi menambahkan hasil prediksi sintesis ke data target asli.
- Langkah tersebut ini diulang setiap iterasi hingga model mencapai ambang batas performa tertentu,  $R^2 > 0.85$ .

### 2.1.10. Multi Layer Perceptron

*Multi-Layer Perceptron* (MLP) merupakan salah satu arsitektur jaringan saraf tiruan (*Artificial Neural Network/ANN*) yang banyak digunakan untuk menyelesaikan permasalahan regresi dan klasifikasi, terutama ketika hubungan antara variabel input dan output bersifat non-linear. Secara umum, MLP terdiri atas tiga jenis lapisan utama yaitu input layer, hidden layer, dan output layer. Lapisan-lapisan ini saling terhubung melalui bobot (weights) yang dapat dioptimalkan melalui proses pelatihan. Setiap neuron dalam hidden layer menggunakan fungsi aktivasi non-linear, seperti ReLU (*Rectified Linear Unit*), untuk meningkatkan kemampuan model dalam menangkap pola-pola kompleks dalam data. MLP bekerja dalam paradigma pembelajaran terawasi (*supervised learning*), di mana proses pelatihan dilakukan berdasarkan dataset yang telah memiliki label atau nilai target.



Gambar 2. 13 Arsitektur Multi Layer Perceptron

(Sumber Faghihi et al, 2011)

Dalam konteks penelitian ini, algoritma MLP digunakan sebagai salah satu kandidat model prediksi performa mesin hybrid hydrogen-diesel. Dataset yang digunakan dalam pelatihan model merupakan data simulasi yang diperoleh dari literatur primer dan disusun berdasarkan parameter operasional mesin seperti rasio hidrogen, efisiensi termal, daya, serta emisi (NOx, CO<sub>2</sub>, dan smoke). Proses pelatihan MLP dimulai dengan *forward propagation*, di mana input diproses dari lapisan awal hingga ke output layer untuk menghasilkan prediksi. Setelah itu, dilakukan proses *backpropagation* untuk menghitung dan memperbarui bobot berdasarkan selisih antara output prediksi dan output aktual menggunakan metode optimasi seperti gradient descent. Fungsi loss yang digunakan pada eksperimen ini adalah Mean Squared Error (MSE), yang dioptimalkan untuk meminimalkan kesalahan prediksi.

Kelebihan utama dari MLP terletak pada kemampuannya dalam mengaproksimasi fungsi-fungsi kompleks, serta fleksibilitasnya untuk diadaptasi dalam berbagai konfigurasi arsitektur, seperti jumlah hidden layer dan jumlah neuron pada tiap layer. Namun, MLP juga memiliki keterbatasan, di antaranya sensitivitas terhadap skala input (yang diatasi melalui

proses normalisasi), serta potensi mengalami overfitting jika tidak dibarengi dengan teknik regularisasi yang tepat seperti *early stopping* atau *dropout*. Dalam studi ini, beberapa konfigurasi arsitektur diuji untuk menemukan kombinasi yang menghasilkan performa prediksi terbaik. Evaluasi dilakukan menggunakan metrik  $R^2$  (koefisien determinasi) dan MAE (mean absolute error), serta validasi silang (*cross-validation*) untuk memastikan generalisasi model terhadap data yang belum pernah dilihat sebelumnya.

Hasil evaluasi MLP dibandingkan dengan algoritma lain seperti XGBoost, *Random Forest Regressor*, dan *Deep Neural Network* (DNN). Meskipun MLP menunjukkan kinerja yang kompetitif dalam beberapa aspek, pemilihan model terbaik akhirnya didasarkan pada performa akurasi yang paling konsisten dalam prediksi seluruh parameter target. Dengan pendekatan ini, penelitian ini menempatkan MLP sebagai model yang dapat menjadi dasar pengembangan lebih lanjut untuk sistem kontrol cerdas berbasis AI dalam aplikasi pembakaran hybrid di masa depan.

#### 2.1.10.1. Strategi Augmentasi Data Multi-Layer Perceptron

Untuk meningkatkan kapasitas generalisasi dan performa model, diterapkan teknik augmentasi data sintetis menggunakan metode bootstrap resampling. Dalam setiap iterasi, sampel acak dari  $X_{full}$  diambil sebanyak  $n=100$  menggunakan fungsi `resample()`, dan prediksi target dari sampel ini dihasilkan menggunakan model yang telah dilatih. Hasilnya dikombinasikan kembali ke dataset utama.

Formulasi dasar dari proses augmentasi data ini sebagai berikut:

$$X_{synth} = Resample(X_{full}, n = 100, \hat{y}_{synth} = Model.Predict(X_{synth})) \quad (2.10)$$

Keterangan:

- $X_{full}$  dan  $y_{full}$  adalah data fitur dan target keseluruhan,
- $X_{synth}$  adalah data fitur baru hasil resampling dari  $X_{full}$ , sebanyak 100 sampel
- $Y_{synth}$  adalah prediki nilai target  $Y_{synth}$  menggunakan model yang telah dilatih
- Resampling adalah fungsi untuk melakukan pengambilan sampel acak dari data asli dengan pengembalian
- `Model.predict` adalah fungsi dari model pembelajaran mesin yang digunakan untuk memprediksi nilai target dari data input.

Setelah data sintetis ( $X_{synth}$  dan  $Y_{synth}$ ) diperoleh, maka kedua set tersebut digabungkan kembali ke dataset utama dengan operasi:

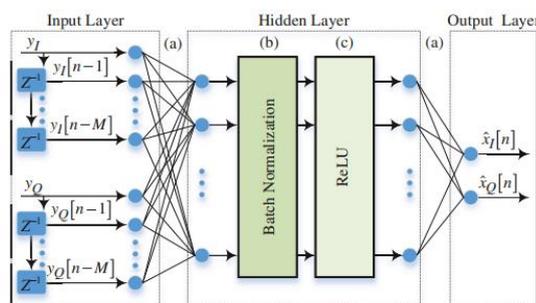
$$X_{full} = X_{full} \cup X_{synth}, y_{full} = y_{full} \cup \hat{y}_{synth} \quad (2.11)$$

Keterangan:

- $\cup$  adalah operasi penggabungan dua himpunan (dalam konteks ini, dua buah *DataFrame*)
- $X_{full} \cup X_{synth}$  berfungsi menambahkan data sintetis ke data asli pada bagian fitur.
- $y_{full} \cup \hat{y}_{synth}$  berfungsi menambahkan hasil prediksi sintetis ke data target asli.
- Langkah tersebut ini diulang setiap iterasi hingga model mencapai ambang batas performa tertentu,  $R^2 > 0.85$ .

### 2.1.11. Deep Neural Network (DNN)

*Deep Neural Network* (DNN) merupakan salah satu arsitektur pembelajaran mesin yang terinspirasi dari jaringan saraf biologis dan dirancang untuk menangani masalah pemodelan non-linear yang kompleks. DNN terdiri dari beberapa lapisan tersembunyi (hidden layers) di antara lapisan input dan output, dengan setiap neuron pada satu lapisan terhubung secara penuh dengan neuron-neuron di lapisan berikutnya. Fungsi aktivasi non-linear seperti ReLU (*Rectified Linear Unit*) digunakan untuk memungkinkan jaringan belajar berbagai pola kompleks dalam data. Kelebihan utama dari DNN adalah kemampuannya untuk menangkap hubungan fitur yang tidak eksplisit, terutama dalam dataset berdimensi tinggi dan dengan struktur data yang kompleks.



Gambar 2. 14 Arsitektur DNN

(Sumber Yufeng et al, 2021)

Pada penelitian ini, DNN digunakan sebagai salah satu model utama untuk memprediksi performa mesin hybrid hydrogen-diesel berdasarkan data simulasi. Model dibangun dengan beberapa lapisan dense (*fully connected*) dan dioptimasi menggunakan algoritma Adam dengan fungsi loss *Mean Squared Error* (MSE). Selain itu, teknik regularisasi diterapkan secara implisit melalui strategi pelatihan seperti *EarlyStopping* dan pengurangan *learning rate* (*ReduceLRonPlateau*) untuk menghindari overfitting dan memastikan konvergensi yang stabil.

Pelatihan DNN dilakukan dengan dataset hasil augmentasi menggunakan teknik penambahan noise untuk memperbesar variasi data. Model ini kemudian dievaluasi

menggunakan metrik  $R^2$  (koefisien determinasi) dan *Mean Absolute Error* (MAE). DNN menunjukkan performa prediksi yang sangat baik, terutama dalam menangkap pola hubungan kompleks antar variabel input dan target seperti emisi gas buang, rasio hydrogen, dan efisiensi termal mesin. Kemampuan DNN untuk beradaptasi dengan variasi input yang luas menjadikannya kandidat kuat dalam simulasi operasional mesin hybrid berbahan bakar hydrogen-diesel yang dinamis dan tidak linear. Arsitektur ini sangat sesuai untuk implementasi lanjutan dalam sistem kontrol cerdas berbasis AI di bidang rekayasa mesin perkapalan.

### 2.1.11.1. Strategi Augmentasi Data Deep Neural Network

Dalam penelitian ini, salah satu strategi penting yang digunakan untuk meningkatkan kemampuan generalisasi dan mengurangi risiko *overfitting* pada model Deep Neural Network (DNN) adalah melalui teknik augmentasi data berbasis *Gaussian noise*. Augmentasi data merupakan proses penambahan variasi terhadap dataset yang sudah ada, dengan tujuan memperluas distribusi data latih tanpa harus mengumpulkan data baru secara fisik (Shorten & Khoshgoftaar, 2019).

Pada model DNN ini, augmentasi dilakukan dengan cara menambahkan noise bertipe Gaussian ke dalam dataset, baik pada fitur input (X) maupun pada target output (y). Gaussian noise adalah derau acak yang mengikuti distribusi normal dengan nilai rata-rata nol

Rumus umum untuk Gaussian Noise adalah seperti berikut

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (2.12)$$

Keterangan:

- $\mu$  adalah mean (rata-rata), biasanya 0
- $\sigma$  adalah standar deviasi, yang menentukan seberapa besar variasi derau yang diberikan
- Derau ini bersifat simetris dan terpusat di sekitar nol, sehingga tidak menimbulkan bias ke arah tertentu

Dalam praktiknya, Gaussian noise digunakan untuk meniru variasi alami atau ketidakpastian dalam data nyata, seperti fluktuasi sensor atau kondisi operasi mesin.

Rumus matematis dari augmentasi data yang digunakan adalah sebagai berikut:

$$X_{augmented} = X + (X \cdot \epsilon) \quad (2.13)$$

$$y_{augmented} = y + (y \cdot \epsilon) \quad (2.14)$$

Keterangan:

- X dan y adalah data fitur dan target asli,
- $\epsilon$  adalah noise Gaussian yang dibangkitkan secara acak,
- $X_{augmented}$  dan  $y_{augmented}$  adalah data hasil augmentasi.

### 2.1.12. Metrik Evaluasi yang Digunakan

Dalam penelitian ini, performa model dievaluasi menggunakan tiga metrik utama, yaitu Koefisien Determinasi ( $R^2$ ), Mean Absolute Error (MAE), dan Hold-Out Validation sebagai strategi pembagian data. Ketiga metrik ini dipilih karena mampu memberikan gambaran menyeluruh mengenai akurasi, ketepatan, dan kemampuan generalisasi model dalam memprediksi output target berdasarkan input yang diberikan.

#### a. Koefisien Determinasi ( $R^2$ )

Koefisien determinasi atau R-squared ( $R^2$ ) adalah metrik yang menunjukkan seberapa besar variabilitas dari variabel target yang dapat dijelaskan oleh variabel input dalam model. Nilai  $R^2$  berkisar antara 0 hingga 1, dengan nilai mendekati 1 menunjukkan bahwa model memiliki tingkat akurasi prediksi yang tinggi. Rumus perhitungan  $R^2$  dituliskan sebagai berikut:

$$R^2 = 1 - \frac{\sum (y_{aktual} - y_{prediksi})^2}{\sum (y_{aktual} - \hat{y})^2} \quad (2.15)$$

Dimana:

- $y_{aktual}$  = nilai aktual dari data target
- $y_{prediksi}$  = nilai hasil prediksi
- $\hat{y}$  = rata-rata nilai aktual

Dalam konteks penelitian ini, dua input fitur seperti engine speed dan excess air ratio dimasukkan ke dalam model untuk memprediksi enam target yaitu: hydrogen\_ratio, brake\_thermal\_eff, brake\_power, emission\_NOx, emission\_CO2, dan smoke. Nilai  $R^2$  digunakan untuk menilai seberapa baik model mampu menangkap hubungan antar fitur dan target yang kompleks dan non-linear dalam sistem pembakaran hybrid hidrogen-diesel (Chicco et al., 2021).

#### b. Mean Absolute Error (MAE)

MAE mengukur rata-rata besar kesalahan absolut antara nilai aktual dan hasil prediksi. Metrik ini penting karena memberikan indikasi langsung terhadap rata-rata jarak (dalam satuan asli) antara prediksi model dengan data sebenarnya. MAE lebih

toleran terhadap *outlier* dibandingkan dengan metrik kuadrat seperti RMSE. Rumusnya adalah:

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

Dimana:

- $y_i$  = nilai aktual
- $\hat{y}_i$  = nilai prediksi
- $n$  = jumlah data

MAE digunakan dalam penelitian ini untuk memberikan ukuran kuantitatif terhadap ketepatan model dalam memprediksi variabel performa mesin seperti daya dan emisi. Semakin rendah nilai MAE, maka semakin baik model dalam memetakan hubungan antara konfigurasi mesin dan performa aktualnya (Willmott & Matsuura, 2005).

### c. *Hold-Out Validation*

Pendekatan hold-out validation digunakan dalam proses pelatihan dan pengujian model. Dataset dibagi menjadi dua bagian, yaitu 80% data latih dan 20% data uji. Model dilatih menggunakan data latih dan dievaluasi performanya terhadap data uji. Pembagian ini dilakukan menggunakan fungsi `train_test_split` dari pustaka `scikit-learn` dengan parameter `random_state` untuk memastikan reproduisibilitas.

Meskipun metode ini lebih sederhana dibandingkan teknik seperti k-fold cross-validation, hold-out tetap merupakan pendekatan valid untuk mengevaluasi performa awal dan efisiensi model, terutama dalam skenario eksperimen iteratif seperti pada penelitian ini (Hastie et al., 2017). Evaluasi dilakukan di setiap iterasi proses augmentasi data dan pelatihan ulang, sehingga tetap memberikan insight terhadap stabilitas dan tren peningkatan performa model.

Dalam proses evaluasi, model mempelajari pola-pola hubungan antar variabel. Misalnya:

- Peningkatan rasio hidrogen → Penurunan emisi CO<sub>2</sub>
- Penurunan RPM → Peningkatan efisiensi termal
- Kenaikan *volumetric efficiency* → Daya mesin meningkat
- Pola-pola ini diidentifikasi berdasarkan kemampuan model memetakan input ke output pada data uji, dan divalidasi melalui metrik R<sup>2</sup> dan MAE.

Pola-pola ini diidentifikasi berdasarkan kemampuan model memetakan input ke output pada data uji, dan divalidasi melalui metrik  $R^2$  dan MAE.

## 2.2. TINJAUAN PUSTAKA

### a. Kontribusi Hidrogen dalam Pengurangan Emisi Mesin Pembakaran

Artikel Penggunaan hidrogen sebagai bahan bakar alternatif dalam mesin pembakaran dalam (*internal combustion engine/ICE*) telah menjadi fokus utama dalam upaya global mengurangi dampak lingkungan dari sektor transportasi. Hal ini sejalan dengan target dekarbonisasi yang ditetapkan dalam *Paris Agreement*. Hidrogen menawarkan keuntungan signifikan, terutama karena hasil pembakarannya tidak menghasilkan karbon dioksida ( $CO_2$ ), berbeda dengan bahan bakar fosil yang menghasilkan emisi karbon dan partikel lainnya yang merugikan kualitas udara (Onorati et al., 2022).

Studi eksperimental yang dilakukan Karagöz et al. (2016) menunjukkan bahwa ketika hidrogen digunakan sebagai bahan bakar tambahan dalam mesin diesel (*dual-fuel*), terjadi penurunan yang sangat signifikan pada emisi karbon monoksida (CO) dan partikulat hitam. Hal ini menunjukkan bahwa hidrogen dapat memainkan peran penting dalam pengurangan emisi tanpa mengorbankan struktur mesin yang sudah ada.

Dengan sifat pembakaran yang cepat dan kandungan energi per massa yang tinggi (120 MJ/kg), hidrogen memungkinkan pembakaran yang lebih sempurna, sehingga menurunkan emisi karbon yang tidak terbakar seperti UHC (*unburned hydrocarbon*). Di sisi lain, sifat fisik hidrogen seperti energi penyalaan yang sangat rendah juga memicu risiko pre-ignition dan backfire, sehingga penggunaannya dalam sistem pembakaran perlu dilengkapi dengan pengendalian yang presisi. Oleh karena itu, penggunaan teknologi injeksi canggih dan pengaturan waktu penyalaan sangat penting dalam implementasi hidrogen sebagai bahan bakar ramah lingkungan di mesin ICE.

### b. Efek Campuran Hidrogen-Diesel terhadap Kinerja Mesin

Hidrogen tidak hanya dikenal karena dampaknya terhadap lingkungan, tetapi juga karena potensinya dalam meningkatkan performa termal mesin. Salah satu efek paling mencolok dari penambahan hidrogen ke dalam campuran bahan bakar diesel adalah peningkatan laju pelepasan panas dan tekanan maksimum di dalam silinder. Menurut Karagöz et al. (2016), dengan menggunakan campuran hidrogen sebesar 25% hingga 50% dari total energi, terjadi peningkatan tekanan silinder dan efisiensi termal, yang berujung pada efisiensi pembakaran yang lebih tinggi. Hal ini terutama disebabkan oleh kecepatan api (*flame speed*) hidrogen yang jauh lebih tinggi dibandingkan dengan diesel.

Namun, peningkatan efisiensi ini tidak datang tanpa konsekuensi. Karena densitas energi volumetrik hidrogen yang jauh lebih rendah, penambahan hidrogen ke dalam sistem pembakaran *port-injection* dapat menyebabkan pengurangan efisiensi volumetrik. Ini disebabkan oleh gas hidrogen yang menggantikan sebagian volume udara masuk dalam proses intake. Akibatnya, meskipun efisiensi pembakaran meningkat, daya total mesin justru bisa menurun dalam beberapa kondisi operasi tertentu, terutama pada kecepatan tinggi.

Penelitian oleh Seddiek et al. (2015) pada kapal RO/RO Taba menunjukkan bahwa meskipun mesin berbahan bakar hidrogen memiliki efisiensi termal yang sedikit lebih rendah dibandingkan mesin diesel, dampak positifnya pada lingkungan menjadikannya solusi yang layak untuk masa depan. Dalam studi lain yang lebih mutakhir, Seyam et al. (2023) berhasil meningkatkan output daya mesin kapal hingga 32% dengan menerapkan sistem hybrid yang menggabungkan ICE dan turbin gas menggunakan campuran bahan bakar hidrogen dan dimetil eter. Hal ini menunjukkan bahwa dengan desain sistem yang tepat, campuran hidrogen tidak hanya mengurangi emisi tetapi juga dapat meningkatkan performa total sistem tenaga kapal.

c. Tantangan Pembakaran Hidrogen dalam Mesin Kapal

Walaupun hidrogen menawarkan banyak keunggulan sebagai bahan bakar alternatif, sifat-sifat fisiknya yang unik menghadirkan tantangan tersendiri dalam implementasi pada mesin pembakaran dalam, terutama di lingkungan maritim. Salah satu tantangan utama adalah kecenderungan hidrogen untuk mengalami *pre-ignition* dan *backfire* karena nilai energi penyalanya yang sangat rendah dan jangkauan batas pembakarannya yang luas. Onorati et al. (2022) menyoroti bahwa hidrogen memiliki kecepatan nyala api hingga empat kali lebih cepat dari bensin, serta dapat terbakar dalam rentang campuran bahan bakar dan udara yang sangat lebar, dari campuran *ultra-lean* hingga *ultra-rich*.

Kondisi ini membuat hidrogen sangat reaktif terhadap panas sisa atau permukaan panas dalam ruang bakar. Akibatnya, dalam sistem injeksi *port* atau manifold (*Port Fuel Injection*), sisa hidrogen yang tertinggal di intake manifold dapat memicu pembakaran dini bahkan sebelum proses kompresi selesai. Hal ini tidak hanya menurunkan efisiensi pembakaran, tetapi juga berisiko merusak komponen mesin. Oleh karena itu, transisi ke sistem injeksi langsung (*Direct Injection/DI*) menjadi salah satu solusi teknis utama. Dengan DI, hidrogen disuntikkan langsung ke dalam silinder setelah katup intake menutup, sehingga menghindari akumulasi hidrogen di *manifold*.

Selain itu, pengendalian pembakaran abnormal juga dapat dilakukan melalui teknik pengenceran udara (*lean burn*) atau *Exhaust Gas Recirculation* (EGR). Teknik ini memanfaatkan karakteristik pembakaran hidrogen yang tetap stabil dalam campuran *ultra-lean*, yang memungkinkan pengoperasian mesin dengan emisi NO<sub>x</sub> yang jauh lebih rendah. Penggunaan injeksi air atau sistem pelumas dengan titik nyala tinggi juga dapat membantu mengurangi pembakaran dini dan meningkatkan kestabilan sistem. Meskipun tantangan ini bersifat teknis, banyak di antaranya telah diatasi melalui pendekatan desain mesin baru dan strategi kontrol pembakaran adaptif.

d. *Machine Learning* dalam Optimasi Sistem Bahan Bakar

Sebuah Penerapan *Machine Learning* (ML) dalam sistem pembakaran internal menjadi tren baru dalam industri maritim dan otomotif, terutama dalam konteks bahan bakar campuran seperti hidrogen-diesel. Salah satu kekuatan utama ML adalah kemampuannya untuk menemukan pola non-linear dari data kompleks yang melibatkan banyak parameter input dan output. Dalam konteks ini, ML dapat digunakan untuk memprediksi rasio campuran hidrogen-diesel optimal berdasarkan *input* seperti RPM, suhu buang, tekanan *intake*, torsi, dan parameter lingkungan lainnya (Onorati *et al.*, 2022).

Keuntungan lain dari pendekatan ini adalah kemampuannya untuk *self-learning* dari data *real-time* mesin. Dengan menggunakan sensor yang dipasang pada mesin kapal, model ML dapat dilatih secara dinamis untuk menghasilkan rekomendasi campuran bahan bakar yang paling efisien dalam kondisi tertentu. Misalnya, ketika kapal beroperasi dalam beban parsial dan RPM rendah, model dapat menyarankan penurunan fraksi hidrogen demi menjaga efisiensi daya. Sebaliknya, dalam kondisi beban tinggi dan kecepatan tinggi, fraksi hidrogen bisa ditingkatkan untuk mengurangi emisi karbon dan meningkatkan efisiensi termal.

Integrasi ML dalam sistem ECU (*Engine Control Unit*) modern juga memungkinkan sistem kendali bahan bakar yang adaptif dan mandiri. Beberapa studi telah menunjukkan keberhasilan algoritma seperti *Random Forest*, *Support Vector Regression*, dan *Artificial Neural Network* dalam memprediksi emisi NO<sub>x</sub> dan efisiensi termal mesin berbahan bakar hidrogen secara akurat. Ini membuka peluang besar untuk pengembangan *smart engine* yang mampu menyesuaikan karakteristik pembakaran dengan kondisi operasional secara *real-time*, tanpa perlu intervensi manual.

Halaman ini sengaja dikosongkan

## **BAB 3**

### **METODOLOGI**

#### **3.1. Metodologi Penelitian**

Penelitian ini menggunakan pendekatan gabungan antara eksperimental, simulasi, dan pemodelan *Machine Learning* (ML) untuk mengkaji potensi penggunaan bahan bakar campuran hidrogen-diesel pada mesin pembakaran dalam kapal. Tujuan utama dari metodologi ini adalah untuk mengevaluasi peningkatan efisiensi termal, pengurangan emisi gas buang, serta kemampuan *Machine Learning* dalam mengoptimalkan sistem pembakaran secara adaptif berdasarkan data operasional mesin.

##### **1. Perancangan Eksperimen dan Dataset**

Langkah awal dari penelitian ini dimulai dengan perencanaan eksperimental berbasis simulasi, dimana data kinerja mesin dikumpulkan dari literatur, publikasi ilmiah, dan/atau hasil simulasi terkait mesin diesel yang menggunakan campuran hidrogen. Parameter yang dikumpulkan meliputi:

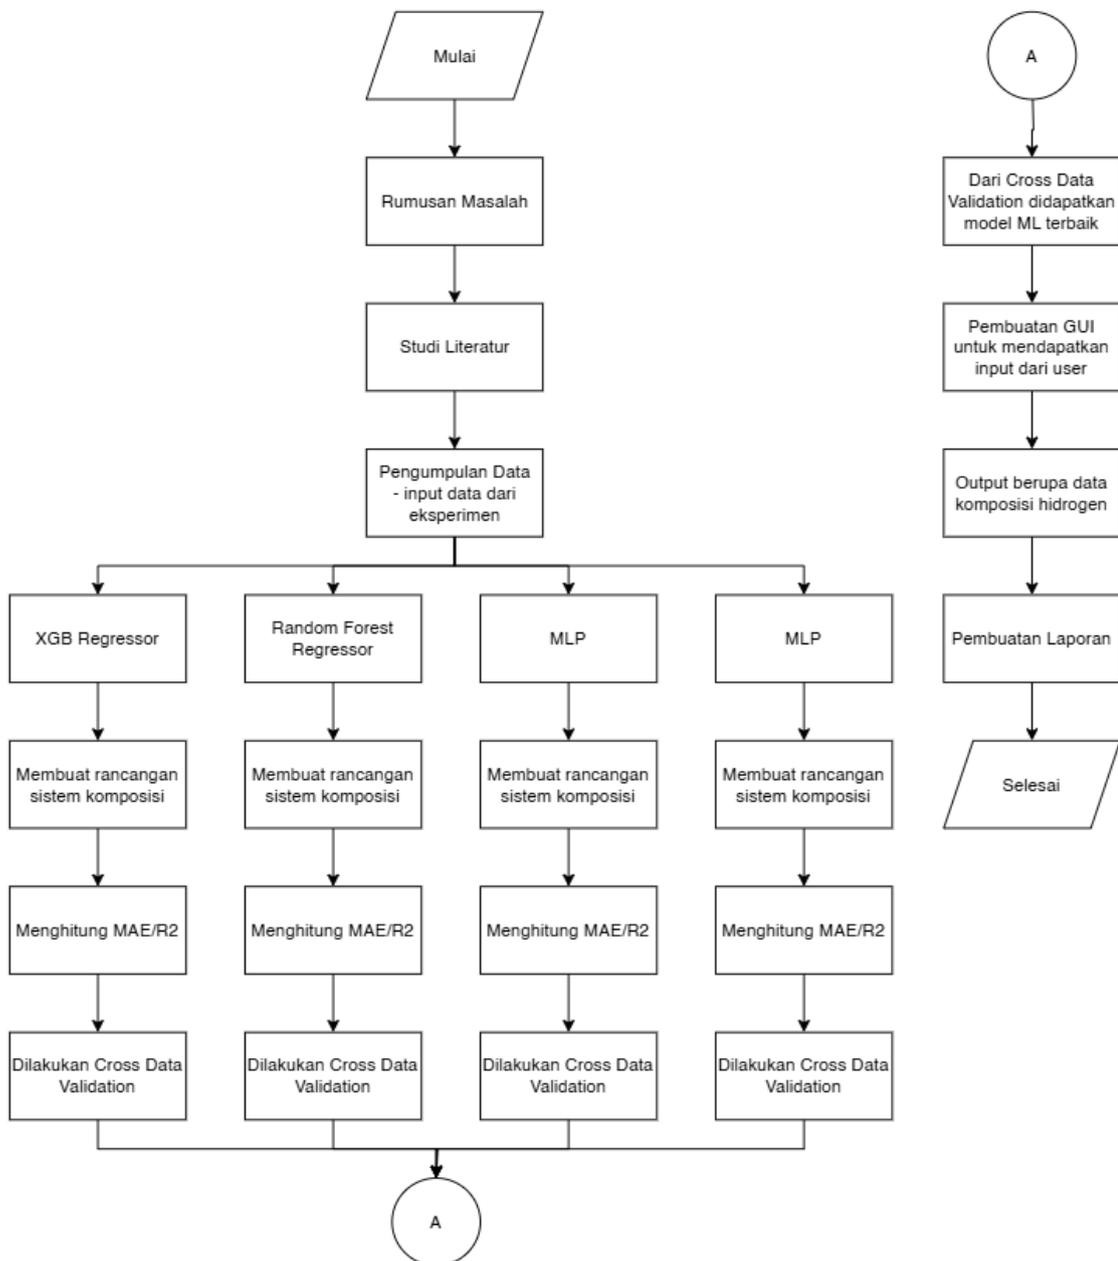
- Kecepatan putaran mesin (RPM)
- Rasio campuran hidrogen-diesel (%)
- Suhu gas buang
- Efisiensi termal (%)
- Daya mesin (kW)
- Emisi CO<sub>2</sub>, NO<sub>x</sub>, dan asap

Data-data ini akan disusun dalam bentuk dataset untuk melatih dan menguji model *Machine Learning*. Apabila diperlukan, data dummy atau sintetis juga akan digunakan sebagai pendekatan awal guna membangun model dasar.

##### **2. Eksperimen Simulatif**

Karena keterbatasan akses terhadap mesin fisik, eksperimen dilakukan dalam bentuk simulasi berbasis dataset teknis dan publikasi sebelumnya. Tujuan simulasi adalah mengamati pengaruh rasio hidrogen terhadap output mesin seperti efisiensi dan emisi. Beberapa rasio campuran (misalnya 0%, 10%, 20%, hingga 50%) akan dianalisis dalam kondisi beban mesin yang bervariasi (*low–medium–high* RPM).

### 3.2. Diagram Alir



Gambar 3. 1 Diagram alir pengerjaan Tugas Akhir

#### 3.2.1. Rancangan Penelitian

Penelitian ini dirancang untuk mengembangkan model prediktif berbasis machine learning dalam mengatur komposisi bahan bakar *hybrid hydrogen-diesel* pada mesin kapal. Tujuan utamanya adalah memperoleh model yang mampu memprediksi kinerja pembakaran dan emisi secara akurat guna mendukung efisiensi dan keberlanjutan sistem propulsi maritim.

Proses penelitian dimulai dengan pengumpulan data sekunder dan data hasil perhitungan teknis, yang mencakup variabel-variabel penting seperti rasio hydrogen, efisiensi termal, daya

mesin, serta emisi NO<sub>x</sub>, CO<sub>2</sub>, dan asap. Data ini kemudian dibersihkan, diskalakan, dan disiapkan untuk proses pelatihan model.

Empat algoritma machine learning digunakan dalam studi ini, yaitu XGBoost Regressor, *Random Forest Regressor* (RFR), *Multi-Layer Perceptron* (MLP), dan *Deep Neural Network* (DNN). Masing-masing model dibangun dengan parameter yang disesuaikan dan dilatih secara berulang menggunakan data augmented hasil dari teknik penambahan noise guna meningkatkan generalisasi. Evaluasi performa dilakukan menggunakan metrik R<sup>2</sup>, MAE (*Mean Absolute Error*), serta cross validation untuk mengukur akurasi dan stabilitas model secara objektif.

Model terbaik dipilih berdasarkan nilai R<sup>2</sup> tertinggi dan MAE terendah yang konsisten. Model terpilih ini selanjutnya digunakan untuk melakukan simulasi pengaturan rasio hydrogen dalam berbagai skenario operasional mesin, yang mencerminkan fluktuasi beban atau kondisi pembakaran di lapangan. Simulasi ini dilakukan secara sistematis untuk mengevaluasi bagaimana perubahan kadar hidrogen dalam campuran bahan bakar mempengaruhi efisiensi mesin dan emisi yang dihasilkan.

Seluruh proses penelitian dilakukan secara terstruktur dalam beberapa tahap: identifikasi masalah dan pengumpulan data, pra-pemrosesan dan augmentasi data, pembangunan dan pelatihan model machine learning, evaluasi performa model, pemilihan model terbaik, simulasi prediktif berbasis model, dan analisis hasil dan validasi teknis. Pendekatan ini memungkinkan integrasi kecerdasan buatan dalam sistem permesinan kapal sebagai dasar bagi pengembangan teknologi kontrol otomatis berbasis prediksi.

### **3.2.2. Pengumpulan Data**

Teknik pengumpulan data dalam penelitian ini dilakukan melalui pendekatan berbasis studi literatur dan pemanfaatan data sekunder dari jurnal ilmiah yang relevan. Seluruh dataset yang digunakan dalam penelitian ini diperoleh dari salah satu jurnal internasional yang secara khusus membahas dan meneliti karakteristik performa mesin hybrid hydrogen-diesel, termasuk parameter input dan output yang terukur secara eksperimen.

Dataset tersebut mencakup variabel input seperti rasio campuran hidrogen terhadap diesel, tekanan, temperatur, dan parameter operasional lainnya, serta variabel output berupa efisiensi termal (*brake thermal efficiency*), daya mesin (*brake power*), dan emisi gas buang seperti NO<sub>x</sub>, CO<sub>2</sub>, dan partikel asap. Data tersebut telah divalidasi secara eksperimen dalam publikasi aslinya, sehingga dapat digunakan sebagai dasar pelatihan model machine learning tanpa perlu melakukan eksperimen langsung.

Untuk meningkatkan variasi dan cakupan data, dilakukan proses augmentasi data dengan cara menambahkan noise Gaussian secara terkontrol terhadap data asli. Teknik ini bertujuan untuk mensimulasikan variasi kondisi operasional mesin yang lebih realistis dan memperbesar volume data pelatihan tanpa mengubah karakteristik dasarnya.

Seluruh data kemudian diproses dalam bentuk tabular dan melalui tahapan preprocessing, seperti normalisasi menggunakan metode StandardScaler, penghapusan nilai kosong (missing values), serta pemisahan antara fitur (X) dan target (y). Hasil olahan data inilah yang kemudian digunakan untuk proses pelatihan, validasi, dan pengujian model machine learning.

## **BAB 4**

# **STUDI PEMILIHAN ALGORITMA DAN PERANCANGAN MODEL**

Dalam merancang sistem prediksi performa mesin *hybrid hydrogen-diesel* secara optimal, dilakukan studi komparatif terhadap empat algoritma *machine learning* yang umum digunakan dalam pemodelan regresi multivariabel, yaitu XGBoost Regressor, *Random Forest Regressor*, *Multi-Layer Perceptron* (MLP), dan *Deep Neural Network* (DNN). Pemilihan algoritma tersebut didasarkan pada kemampuannya dalam menangani data non-linear serta akurasi dan stabilitas prediksi yang tinggi pada studi terdahulu dalam bidang teknik. Masing-masing model dilatih menggunakan dataset hasil simulasi berbasis perhitungan teknis dari sumber literatur primer terkait pengujian mesin hybrid. Dataset awal kemudian diperbanyak menggunakan teknik augmentasi berupa penambahan *Gaussian noise* guna memperluas distribusi data dan menghindari overfitting, terutama pada model berbasis jaringan saraf. Seluruh data kemudian dinormalisasi menggunakan *StandardScaler* dan dibagi dalam skema pelatihan dan pengujian. Metrik evaluasi yang digunakan adalah koefisien determinasi ( $R^2$ ), Mean Absolute Error (MAE), serta *cross validation* (CV) untuk memastikan kestabilan dan keandalan masing-masing model. XGBoost dan *Random Forest* bekerja dengan metode ensemble tree; XGBoost mengoptimalkan hasil prediksi melalui pendekatan boosting berurutan, sedangkan *Random Forest* menggunakan teknik bagging yang membangun banyak pohon keputusan secara paralel. Di sisi lain, MLP dan DNN mengandalkan struktur jaringan saraf berlapis untuk mengenali pola hubungan antar variabel melalui proses propagasi maju dan *backpropagation*. DNN memiliki arsitektur lebih dalam dibanding MLP, memungkinkan pembelajaran representasi data yang lebih kompleks. Hasil pelatihan menunjukkan perbedaan performa antar model, di mana DNN memberikan hasil paling konsisten dengan  $R^2$  tertinggi dan MAE terendah setelah diuji dengan skema cross validation. Model ini kemudian dipilih sebagai model utama yang digunakan untuk menyimulasikan pengaruh variasi rasio hidrogen terhadap output performa mesin, seperti efisiensi termal, daya, dan emisi. Perancangan akhir model dilakukan dengan mengintegrasikan pelatihan multi-iteratif, strategi pengurangan laju pembelajaran, serta *early stopping* untuk mencapai generalisasi yang optimal. Model yang telah divalidasi ini menjadi fondasi utama dalam sistem simulasi prediktif mesin hybrid yang efisien dan adaptif.

#### 4.1. Analisa Penentuan Algoritma Machine Learning

Pada Eksperimen dalam penelitian ini dirancang secara sistematis untuk mengevaluasi kinerja dari empat algoritma machine learning dalam memprediksi output performa mesin hybrid berbahan bakar hydrogen-diesel, yaitu XGBoost Regressor (XGB), *Random Forest Regressor* (RFR), *Multi-Layer Perceptron* (MLP), dan *Deep Neural Network* (DNN). Keempat algoritma ini dipilih karena masing-masing mewakili pendekatan berbeda dalam regresi non-linear multivariabel XGB sebagai model boosting berbasis pohon keputusan yang efisien dan kuat terhadap *overfitting*, RFR sebagai model ensemble berbasis agregasi pohon acak yang stabil, serta MLP dan DNN yang merepresentasikan jaringan saraf tiruan dengan kompleksitas arsitektur dan fleksibilitas dalam menangkap hubungan kompleks antar fitur.

Dataset yang digunakan dalam penelitian ini diperoleh dari hasil ekstraksi data dan perhitungan teknis berdasarkan studi literatur yang membahas kinerja mesin berbahan bakar campuran hydrogen dan diesel. Dataset awal berjumlah 63 entri, yang mencakup parameter-parameter masukan seperti karakteristik pembakaran dan parameter mesin, serta target keluaran berupa efisiensi termal, daya output, dan emisi gas buang (NO<sub>x</sub>, CO<sub>2</sub>, dan asap). Karena jumlah data relatif terbatas, dilakukan augmentasi data dengan pendekatan penambahan *Gaussian noise* terkontrol terhadap fitur input dan output. Teknik ini dilakukan untuk memperluas distribusi data dan meningkatkan kemampuan generalisasi model dalam mempelajari variasi yang mungkin terjadi di dunia nyata. Setelah augmentasi, jumlah data bertambah secara progresif pada tiap iterasi pelatihan model.

Eksperimen dilakukan dalam tiga tahap utama pra-pemrosesan data, pelatihan dan pengujian model, serta evaluasi dan perbandingan performa. Pada tahap pra-pemrosesan, seluruh data input dan output dinormalisasi menggunakan metode *StandardScaler* untuk menghindari bias akibat perbedaan skala antar fitur. Pembagian data dilakukan menggunakan *train\_test\_split* dengan proporsi 80:20, yang dipertahankan secara konsisten di seluruh algoritma agar hasil perbandingan bersifat adil. Untuk MLP dan DNN, data pelatihan selanjutnya dibagi kembali menjadi data training dan validation menggunakan *validation\_split* sebesar 20%, guna mengaktifkan fungsi *early stopping* untuk menghindari *overfitting*.

Tahap kedua adalah pelatihan model, di mana setiap algoritma dilatih secara independen menggunakan arsitektur dan parameter dasar yang sesuai. Pada model *tree-based* (XGB dan RFR), digunakan pengaturan default dengan sedikit penyesuaian pada jumlah estimators dan kedalaman pohon untuk mempercepat proses pelatihan. Sedangkan pada MLP dan DNN, digunakan beberapa lapisan neuron bertingkat dengan aktivasi *ReLU* dan lapisan output linear

sebanyak jumlah target variabel. Optimizer *Adam* digunakan dengan learning rate awal yang disesuaikan (misal 0.001 untuk DNN), dan pelatihan dilakukan hingga 300 *epoch* dengan mekanisme penghentian otomatis (*early stopping*) jika tidak ada penurunan loss selama 20 *epoch* berturut-turut.

Pada tahap evaluasi, digunakan metrik kuantitatif utama yaitu koefisien determinasi ( $R^2$ ) sebagai ukuran seberapa baik model menjelaskan variansi data aktual, serta *Mean Absolute Error* (MAE) sebagai ukuran seberapa jauh prediksi model dari nilai sebenarnya secara rata-rata. Selain itu, untuk menilai stabilitas model terhadap variasi data pelatihan, digunakan Teknik *cross validation* pada seluruh model. Hasil  $R^2$  dan MAE pada masing-masing fold dibandingkan untuk mengidentifikasi model dengan performa paling konsisten. Model terbaik dipilih berdasarkan kombinasi nilai  $R^2$  tertinggi, MAE terendah, dan deviasi antar fold terkecil. Eksperimen ini juga mencakup analisis scatter plot aktual vs prediksi untuk masing-masing output, sehingga dapat ditinjau visualisasi hubungan linearitas dan distribusi error prediktif dari tiap model. Seluruh proses eksperimen dilakukan dalam lingkungan Python menggunakan pustaka seperti Scikit-Learn, TensorFlow Keras, NumPy, dan Pandas.

Dengan desain eksperimen ini, diharapkan pemilihan algoritma terbaik tidak hanya didasarkan pada performa numerik semata, tetapi juga pada stabilitas, efisiensi pelatihan, serta kemampuannya dalam menangani kompleksitas hubungan antar variabel dalam sistem mesin *hybrid hydrogen-diesel*. Algoritma yang terpilih nantinya akan digunakan pada tahap simulasi pengaruh variasi rasio hydrogen terhadap performa dan emisi mesin untuk mengevaluasi kemampuan adaptif model dalam kondisi pengoperasian yang berubah-ubah

Tabel 4. 1 Konfigurasi Model Machine Learning

|                         | XGBoost Regressor | Random Forest Regressor | Multi-Layer Perceptron    | Deep Neural Network                  |
|-------------------------|-------------------|-------------------------|---------------------------|--------------------------------------|
| Tipe Model              | Tree Boosting     | Random Forest           | Neural Network (shallow)  | Neural Network (deep)                |
| Arsitektur Jaringan     | 100 Pohon         | 100 Pohon               | 1 hidden layer, 50 neuron | 4 hidden layers, 32–256 neuron/layer |
| Data Split (train:test) | 20:80             | 20:80                   | 20:80                     | 20:80                                |
| Augmentasi Data         | Resample          | Resample                | Resample                  | Gaussian Noise                       |

|                |                                    |                                    |                                    |                                    |
|----------------|------------------------------------|------------------------------------|------------------------------------|------------------------------------|
|                | XGBoost Regressor                  | Random Forest Regressor            | Multi-Layer Perceptron             | Deep Neural Network                |
| Evaluasi Utama | R <sup>2</sup> , MAE, Scatter Plot |

#### 4.2. Training dan Augmentasi

Dataset yang digunakan dalam penelitian ini diperoleh dari jurnal primer yang meneliti performa mesin hybrid hydrogen-diesel. Dataset ini berisi fitur-fitur input seperti rasio hydrogen, RPM, temperatur, tekanan, dan variabel lain yang relevan, serta target output seperti efisiensi termal, brake power, emisi NO<sub>x</sub>, emisi CO<sub>2</sub>, dan smoke.

Berikut dibawah merupakan dataset yang digunakan untuk pelatihan model

Tabel 4. 2 Dataset Pelatihan Model

(Sumber : Yasin Karagoz et al, 2016)

| Engine speed | Hydrogen ratio | Exhaust temp | Volumetric efficiency | Excess air ratio | Brake thermal eff | bsfc    | Emission CO2 | Emission NOx | smoke  |
|--------------|----------------|--------------|-----------------------|------------------|-------------------|---------|--------------|--------------|--------|
| 750          | 0              | 270.59       | 71.75                 | 1.168            | 30                | 286.27  | 838.1        | 3.059        | 16.7   |
| 809          | 0              | 193.806      | 83.197                | 1.588            | 29.210            | 295.418 | 777.258      | 2.917        | 9.540  |
| 850          | 0              | 205.854      | 83.023                | 1.595            | 28.841            | 296.586 | 792.223      | 2.820        | 3.836  |
| 891          | 0              | 217.901      | 82.849                | 1.603            | 28.734            | 297.754 | 807.188      | 2.737        | 3.725  |
| 900          | 0              | 274.500      | 75.240                | 1.496            | 28.680            | 305.880 | 842.432      | 2.734        | 3.529  |
| 974          | 0              | 233.886      | 83.186                | 1.591            | 28.627            | 303.730 | 854.170      | 2.731        | 3.422  |
| 1015         | 0              | 246.399      | 83.078                | 1.608            | 28.163            | 303.919 | 865.909      | 2.730        | 3.147  |
| 1056         | 0              | 258.912      | 82.970                | 1.625            | 28.127            | 304.109 | 880.950      | 2.730        | 3.134  |
| 1100         | 0              | 286.270      | 80.950                | 1.550            | 28.091            | 298.040 | 895.240      | 2.619        | 3.125  |
| 1135         | 0              | 286.920      | 81.730                | 1.643            | 28.032            | 304.086 | 898.211      | 2.577        | 2.846  |
| 1179         | 0              | 288.880      | 82.880                | 1.691            | 27.890            | 305.558 | 903.568      | 2.536        | 2.765  |
| 1223         | 0              | 290.840      | 84.030                | 1.739            | 27.532            | 307.029 | 908.924      | 2.494        | 2.526  |
| 1400         | 0              | 333.730      | 82.540                | 1.712            | 27.357            | 305.880 | 919.047      | 2.452        | 1.958  |
| 1488         | 0              | 326.980      | 84.070                | 1.793            | 27.182            | 309.705 | 928.212      | 2.410        | 1.680  |
| 1599         | 0              | 336.864      | 84.618                | 1.835            | 27.007            | 311.568 | 936.903      | 2.368        | 0.609  |
| 1709         | 0              | 346.748      | 85.166                | 1.877            | 26.832            | 313.430 | 945.593      | 2.327        | 0.560  |
| 1750         | 0              | 396.070      | 75.870                | 1.544            | 26.657            | 290.196 | 983.293      | 2.285        | 0.350  |
| 1860         | 0              | 384.044      | 81.887                | 1.794            | 26.482            | 306.000 | 995.031      | 2.243        | 0.321  |
| 1950         | 0              | 396.557      | 81.779                | 1.811            | 26.307            | 306.190 | 1000.000     | 2.201        | 0.140  |
| 2039         | 0              | 409.070      | 81.670                | 1.828            | 26.132            | 306.379 | 1006.770     | 2.160        | 0.081  |
| 2100         | 0              | 450.980      | 70.160                | 1.296            | 25.957            | 358.830 | 1247.620     | 2.118        | 0.033  |
| 750          | 25             | 262.740      | 66.660                | 1.232            | 32.646            | 309.800 | 533.166      | 4.310        | 14.870 |
| 809          | 25             | 183.439      | 88.366                | 1.794            | 32.485            | 499.810 | 538.368      | 3.876        | 3.761  |
| 850          | 25             | 192.605      | 87.865                | 1.782            | 32.293            | 503.345 | 545.798      | 3.861        | 3.388  |
| 891          | 25             | 201.772      | 87.364                | 1.770            | 32.006            | 506.879 | 555.533      | 3.846        | 3.016  |
| 900          | 25             | 262.740      | 75.240                | 1.420            | 31.940            | 317.650 | 558.431      | 3.838        | 4.600  |
| 974          | 25             | 207.154      | 89.268                | 1.830            | 31.711            | 562.139 | 570.319      | 3.820        | 1.782  |
| 1015         | 25             | 217.616      | 88.476                | 1.810            | 31.528            | 560.854 | 572.699      | 3.819        | 1.458  |
| 1056         | 25             | 228.077      | 87.684                | 1.790            | 31.077            | 559.569 | 592.490      | 3.680        | 1.135  |
| 1100         | 25             | 279.590      | 80.950                | 1.504            | 30.659            | 307.840 | 614.662      | 3.623        | 1.120  |
| 1135         | 25             | 235.317      | 88.082                | 1.837            | 30.650            | 640.481 | 629.803      | 3.566        | 0.385  |
| 1179         | 25             | 247.644      | 87.020                | 1.805            | 30.416            | 627.812 | 658.232      | 3.508        | 0.075  |
| 1223         | 25             | 259.971      | 85.958                | 1.772            | 30.183            | 615.144 | 686.662      | 3.451        | 0.234  |
| 1400         | 25             | 286.270      | 82.540                | 1.630            | 29.950            | 313.720 | 695.240      | 3.393        | 0.450  |
| 1488         | 25             | 277.641      | 85.013                | 1.763            | 29.716            | 734.184 | 700.000      | 3.336        | 1.350  |
| 1599         | 25             | 291.465      | 83.699                | 1.718            | 29.483            | 690.578 | 728.570      | 3.278        | 1.553  |

| Engine speed | Hydrogen ratio | Exhaust temp | Volumetric efficiency | Excess air ratio | Brake thermal eff | bsfc    | Emission CO2 | Emission NOx | smoke  |
|--------------|----------------|--------------|-----------------------|------------------|-------------------|---------|--------------|--------------|--------|
| 1709         | 25             | 305.289      | 82.384                | 1.674            | 29.250            | 646.971 | 730.410      | 3.221        | 1.756  |
| 1750         | 25             | 339.210      | 75.780                | 1.504            | 29.017            | 617.640 | 730.698      | 3.164        | 0.280  |
| 1860         | 25             | 325.816      | 81.981                | 1.628            | 28.783            | 510.974 | 730.986      | 3.106        | 3.235  |
| 1950         | 25             | 330.228      | 82.619                | 1.647            | 28.550            | 526.268 | 752.380      | 3.049        | 4.069  |
| 2039         | 25             | 334.639      | 83.258                | 1.665            | 28.317            | 541.561 | 762.900      | 2.991        | 4.902  |
| 2100         | 25             | 403.920      | 68.570                | 1.264            | 28.083            | 384.313 | 904.760      | 2.934        | 0.098  |
| 750          | 50             | 249.010      | 61.270                | 1.280            | 30.140            | 337.250 | 521.552      | 9.600        | 12.000 |
| 809          | 50             | 191.498      | 72.867                | 1.741            | 30.007            | 246.233 | 533.330      | 8.800        | 1.929  |
| 850          | 50             | 199.631      | 72.770                | 1.730            | 29.816            | 252.013 | 533.330      | 7.363        | 1.808  |
| 891          | 50             | 207.764      | 72.673                | 1.719            | 29.797            | 257.792 | 534.780      | 7.165        | 1.687  |
| 900          | 50             | 254.900      | 68.250                | 1.410            | 29.785            | 337.250 | 548.008      | 6.967        | 3.930  |
| 974          | 50             | 214.279      | 73.561                | 1.771            | 29.563            | 250.933 | 563.583      | 6.062        | 0.853  |
| 1015         | 50             | 223.387      | 73.356                | 1.753            | 29.492            | 258.555 | 577.899      | 5.915        | 0.790  |
| 1056         | 50             | 232.495      | 73.151                | 1.734            | 29.435            | 266.177 | 592.215      | 4.992        | 0.728  |
| 1100         | 50             | 254.900      | 71.430                | 1.504            | 29.344            | 325.500 | 604.760      | 4.387        | 1.090  |
| 1135         | 50             | 246.278      | 73.246                | 1.768            | 28.890            | 264.186 | 645.247      | 3.783        | 0.462  |
| 1179         | 50             | 255.991      | 72.973                | 1.740            | 28.670            | 274.158 | 656.236      | 3.178        | 0.419  |
| 1223         | 50             | 265.703      | 72.699                | 1.712            | 27.964            | 284.130 | 667.225      | 2.867        | 0.376  |
| 1400         | 50             | 278.430      | 75.870                | 1.540            | 27.905            | 333.330 | 675.929      | 2.574        | 0.430  |
| 1488         | 50             | 283.620      | 70.428                | 1.728            | 28.065            | 284.460 | 689.762      | 2.263        | 0.242  |
| 1599         | 50             | 293.656      | 70.523                | 1.685            | 27.889            | 298.635 | 703.595      | 1.969        | 0.209  |
| 1709         | 50             | 303.691      | 70.618                | 1.641            | 27.714            | 312.810 | 704.760      | 1.658        | 0.177  |
| 1750         | 50             | 330.980      | 66.980                | 1.504            | 27.538            | 345.100 | 723.809      | 1.365        | 0.210  |
| 1860         | 50             | 315.825      | 73.044                | 1.578            | 27.363            | 338.337 | 728.213      | 1.054        | 0.061  |
| 1950         | 50             | 320.512      | 73.520                | 1.592            | 27.187            | 338.631 | 740.237      | 0.760        | 0.038  |
| 2039         | 50             | 325.198      | 73.996                | 1.607            | 27.012            | 338.926 | 752.261      | 0.449        | 0.015  |
| 2100         | 50             | 376.470      | 66.980                | 1.272            | 26.836            | 415.680 | 780.950      | 0.156        | 0.070  |

Sebelum digunakan dalam proses pelatihan, data mengalami proses normalisasi menggunakan metode *StandardScaler* dari *scikit-learn*. Hal ini dilakukan untuk menstandarisasi rentang nilai fitur menjadi distribusi dengan rata-rata 0 dan deviasi standar 1, sehingga menghindari dominasi variabel dengan skala besar terhadap proses pelatihan model. Data dibersihkan dari nilai kosong dan kemudian dipisahkan menjadi dua komponen utama: fitur input (X) dan target output (y). Proses training dan evaluasi dilakukan dengan membagi data menjadi 80% untuk pelatihan dan 20% untuk pengujian, sebuah pendekatan standar dalam *supervised learning* untuk menghindari overfitting (Goodfellow et al., 2016).

#### 4.2.1. Pengolahan Data dan Teknik Augmentasi pada Model XGBoost Regressor

Model XGBoost Regressor (Extreme Gradient Boosting) digunakan dalam penelitian ini sebagai salah satu metode utama untuk melakukan prediksi multivariat terhadap performa mesin hybrid hydrogen-diesel. Model ini dirancang untuk menangani permasalahan regresi non-linear secara efisien dengan menggabungkan pendekatan *gradient boosting* dan teknik regularisasi. XGBoost dikenal memiliki performa tinggi dalam menangani data terstruktur dan telah banyak digunakan pada berbagai kompetisi data sains karena akurasinya yang tinggi dan efisiensinya dalam proses pelatihan (Chen & Guestrin, 2016).

##### 4.2.1.1. Pengolahan Dataset dan Alur Pemrosesan Model

Dataset yang digunakan memuat parameter-parameter simulasi teknis sistem pembakaran mesin, dengan variabel target yang terdiri dari enam parameter utama, yaitu:

- *hydrogen ratio*,
- *brake thermal efficiency*,
- *emission NO<sub>x</sub>*,
- *emission CO<sub>2</sub>*, dan
- *smoke opacity*.

Langkah awal dalam pemrosesan data adalah memisahkan dataset menjadi dua bagian menggunakan metode train-test split, dengan rasio 80:20. Sebanyak 80% data digunakan sebagai data latih (*training set*), sedangkan 20% sisanya sebagai data uji (*test set*). Model kemudian dilatih untuk mempelajari hubungan kompleks antara fitur masukan dan variabel target menggunakan algoritma XGBoost, dan performanya diuji dengan menggunakan metrik koefisien determinasi ( $R^2$ ) serta *mean absolute error* (MAE).

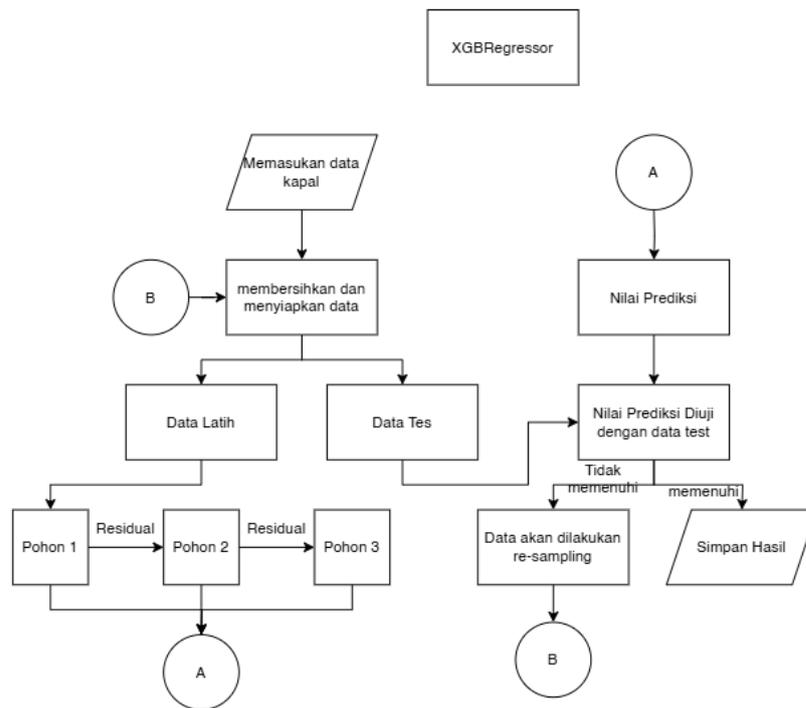
XGBoost bekerja dengan membangun serangkaian pohon keputusan (*decision trees*) secara berurutan. Setiap pohon dibangun untuk memperbaiki kesalahan dari pohon sebelumnya dengan menggunakan pendekatan gradient descent terhadap fungsi kerugian. Proses ini dikenal sebagai sequential learning, dan output akhir merupakan kombinasi dari semua pohon (*ensemble*) dengan bobot tertentu. Arsitektur ini memungkinkan model untuk fokus secara iteratif pada sampel-sampel yang sulit diprediksi (*misclassified samples*), sehingga meningkatkan akurasi keseluruhan (Natekin & Knoll, 2013).

Untuk meningkatkan kapasitas generalisasi model dan mengatasi keterbatasan jumlah data, dilakukan teknik augmentasi berbasis sintetik dengan memanfaatkan kemampuan prediktif dari model XGBoost itu sendiri. Proses augmentasi dilakukan secara iteratif, dengan langkah-langkah sebagai berikut:

1. Model XGBoost dilatih pada data awal.
2. Setelah pelatihan, data sintetik dibuat dengan melakukan *resampling* terhadap data latih sebanyak 100 sampel setiap iterasi.
3. Fitur hasil resampling ini kemudian diprediksi oleh model untuk menghasilkan target sintetis, sehingga membentuk pasangan fitur-target baru yang ditambahkan ke dataset.
4. Proses ini diulang hingga model mencapai nilai  $R^2 \geq 0,85$  atau maksimal sebanyak 30 iterasi (sebagai batas keamanan untuk menghindari *overfitting*).

Dengan setiap iterasi menghasilkan 100 data sintetik, maka jika model membutuhkan  $n$  iterasi untuk mencapai performa yang diharapkan, jumlah total data setelah augmentasi menjadi:

$$\text{Jumlah Akhir Data} = 63 + (n \times 100)$$



Gambar 4. 1 Arsitektur XGBoost yang Sudah Disesuaikan

#### 4.2.1.2. Keunggulan dan Aplikasi

XGBoost memiliki beberapa keunggulan penting:

- Regularisasi (L1 dan L2) untuk mencegah overfitting.
- Manajemen nilai hilang secara otomatis.
- Paralelisasi proses pelatihan untuk efisiensi komputasi.
- Kemampuan menangani hubungan non-linear kompleks.

Dalam konteks penelitian ini, XGBoost menunjukkan performa yang kompetitif dalam memprediksi variabel target dengan tingkat akurasi yang tinggi, serta adaptif terhadap proses augmentasi data yang dilakukan. Oleh karena itu, XGBoost menjadi salah satu kandidat kuat dalam seleksi model terbaik untuk disimulasikan lebih lanjut dalam skenario sistem mesin hybrid berbasis hidrogen dan solar.

#### 4.2.2. Pengolahan Data dan Teknik Augmentasi pada Model RFR

Random Forest Regressor (RFR) merupakan algoritma pembelajaran *ensemble* berbasis pohon keputusan yang bekerja dengan cara membangun sejumlah besar *decision tree* secara paralel, lalu menggabungkan hasil prediksi dari masing-masing pohon untuk mendapatkan estimasi akhir. RFR bekerja dengan prinsip *bootstrap aggregating* atau *bagging*, di mana setiap pohon dilatih menggunakan subset acak dari dataset (dengan pengambilan sampel *with*

*replacement*) dan subset fitur (*feature bagging*) agar setiap pohon memiliki perspektif pembelajaran yang berbeda (Breiman, 2001).

#### 4.2.2.1. Pengolahan Dataset dan Alur Pemrosesan Model

Dataset awal yang digunakan dalam penelitian ini terdiri dari 63 sampel hasil simulasi sistem pembakaran mesin hybrid berbasis hidrogen-diesel. Data ini dipisahkan menjadi dua bagian: 80% sebagai data latih dan 20% sebagai data uji, menggunakan metode *train-test split*.

Model Random Forest Regressor (RFR) dilatih menggunakan seluruh fitur input (seperti *engine speed*, *excess air ratio*, dan parameter teknis lainnya) untuk memprediksi enam variabel target, yaitu: *hydrogen ratio*, *brake thermal efficiency*, *brake power*, *emission NOx*, *emission CO<sub>2</sub>*, dan *smoke opacity*. Setiap pohon dalam Random Forest mempelajari relasi yang berbeda-beda terhadap data, karena dibangun dari subset acak data dan fitur. Hal ini memungkinkan model menangkap hubungan non-linear kompleks, seperti:

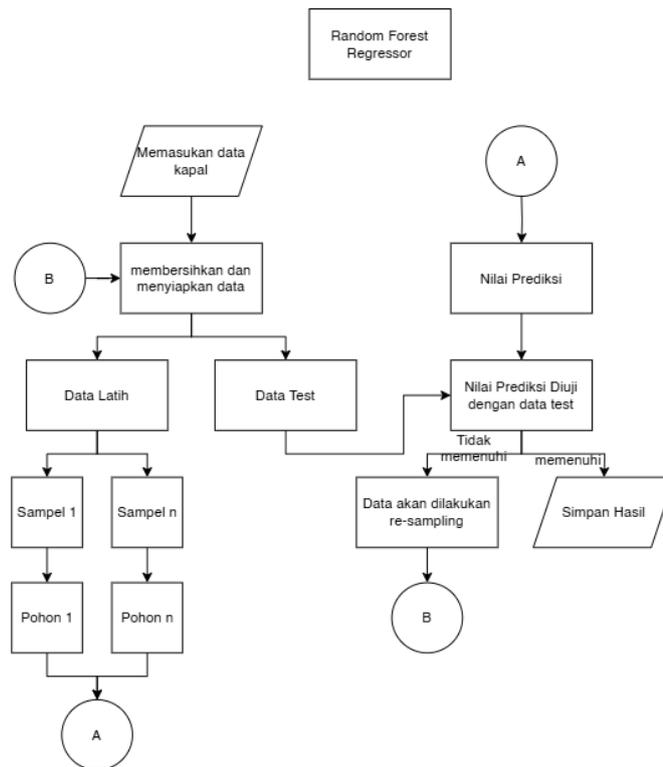
- Penurunan emisi CO<sub>2</sub> akibat peningkatan rasio hidrogen,
- Efisiensi termal yang meningkat saat RPM rendah,
- Kestabilan *brake power* dalam kondisi kombinasi tertentu antara *air excess ratio* dan *volumetric efficiency*.

Untuk mengatasi keterbatasan jumlah data dan meningkatkan kemampuan generalisasi model, diterapkan proses augmentasi data berbasis prediksi sintetis. Tahapan proses augmentasi sebagai berikut:

1. Model RFR pertama kali dilatih menggunakan data asli.
2. Sebanyak 100 sampel di-*resample* secara acak dari data latih menggunakan teknik *bootstrap sampling*.
3. Fitur hasil *resampling* ini diprediksi targetnya oleh model, menghasilkan pasangan data sintetis (fitur dan target).
4. Pasangan data tersebut ditambahkan ke dataset.
5. Proses diulang secara iteratif hingga model mencapai nilai  $R^2 \geq 0,85$  atau maksimal 100 iterasi.

Dengan demikian, jumlah data total setelah augmentasi bergantung pada jumlah iterasi yang dilakukan. Formula umum untuk menghitung jumlah data akhir adalah:

$$\text{Jumlah Akhir Data} = 63 + (n \times 100)$$



Gambar 4. 2 Arsitektur Random Forest Regressor yang sudah disesuaikan

#### 4.2.2.2. Keunggulan dan Aplikasi

Kelebihan utama RFR terletak pada kemampuannya dalam menangani data dengan hubungan non-linier dan *interaksi antar fitur* tanpa memerlukan *feature scaling*. Selain itu, model ini juga cukup tahan terhadap *overfitting* karena adanya rata-rata dari banyak pohon keputusan. Dengan kemampuan untuk mempelajari pola seperti:

- Kenaikan  $H_2$  → Penurunan  $CO_2$
- Penurunan RPM → Potensi peningkatan efisiensi
- Variasi *excess air ratio* → Dampak terhadap emisi  $NO_x$

Hal tersebut yang menjadikan Random Forest Regressor sesuai untuk menganalisis sistem pembakaran hybrid yang kompleks seperti mesin berbahan bakar hydrogen-diesel.

#### 4.2.3. Pengolahan Data dan Teknik Augmentasi pada Model MLP

*Multi-Layer Perceptron* (MLP) merupakan algoritma supervised learning yang termasuk dalam kelompok *feedforward artificial neural networks*. Model ini terdiri atas minimal tiga lapisan: *input layer*, satu atau lebih *hidden layer*, dan *output layer*. Pada penelitian ini, struktur MLP terdiri dari hidden layer berukuran 50 neuron, yang masing-masing menggunakan fungsi aktivasi *ReLU (Rectified Linear Unit)*. MLP digunakan sebagai *multi-*

*output regressor* untuk memprediksi enam variabel target: *hydrogen\_ratio*, *brake\_thermal\_eff*, *brake\_power*, *emission\_NOx*, *emission\_CO2*, dan *smoke*.

#### 4.2.3.1. Pengolahan Dataset dan Alur Pemrosesan Model

Dataset yang digunakan dalam penelitian ini merupakan hasil simulasi performa sistem pembakaran hybrid hydrogen–diesel engine. Data terlebih dahulu dibersihkan dengan menghapus nilai kosong (NaN) pada kolom-kolom target, kemudian dibagi menjadi dua bagian: 80% untuk data pelatihan (*training set*) dan 20% untuk data pengujian (*testing set*) menggunakan metode *train-test split*. Fitur input seperti *engine speed*, *excess air ratio*, dan *volumetric efficiency* digunakan sebagai masukan (*input features*) untuk melatih model agar mampu mempelajari pola hubungan kompleks dengan variabel target.

Model *Multi-Layer Perceptron* (MLP) dibangun dengan *hidden layer* yang terdiri atas 100 dan 50 neuron, menggunakan fungsi aktivasi ReLU dan algoritma *backpropagation* untuk memperbarui bobot pada setiap iterasi pelatihan, sehingga model dapat belajar memperkecil *loss function* (Mean Squared Error) melalui proses iteratif.

Pada *hidden layer*, model MLP mulai mempelajari keterkaitan sederhana, misalnya:

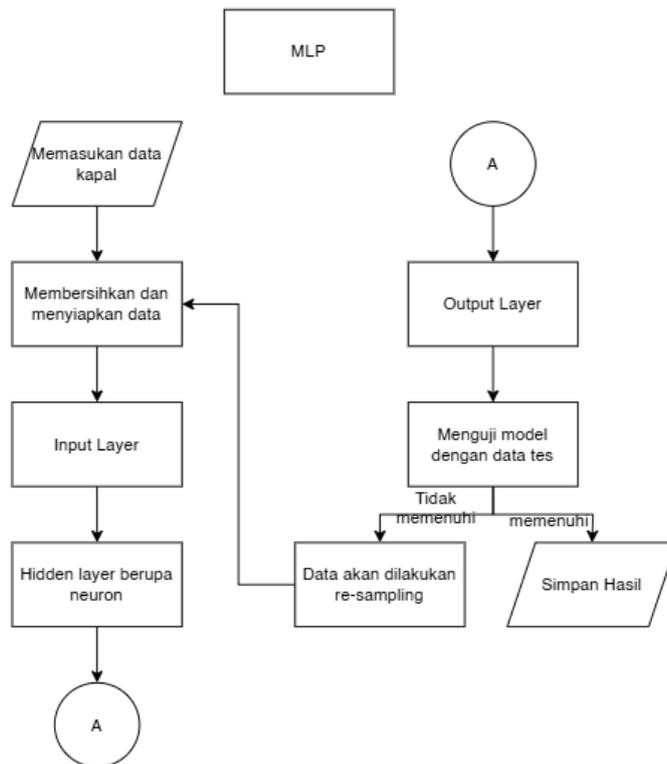
- Apakah peningkatan *engine\_speed* akan menurunkan rasio *hydrogen\_ratio*?
- Apa pengaruh rasio *excess\_air\_ratio* terhadap efisiensi termal?

Untuk memperkuat performa model terhadap keterbatasan data awal yang hanya terdiri dari 63 sampel, diterapkan proses augmentasi data sintetik berbasis prediksi model. Mekanismenya meliputi:

1. Model MLP dilatih pada data awal.
2. Sebanyak 100 sampel di-*resample* secara acak dari dataset menggunakan teknik *bootstrap*.
3. Model kemudian memprediksi target untuk hasil *resampling* tersebut, menghasilkan pasangan data fitur-target sintetik.
4. Dataset baru ini ditambahkan ke data pelatihan dan proses dilanjutkan ke iterasi berikutnya.

Proses augmentasi ini dijalankan secara iteratif hingga model mencapai koefisien determinasi ( $R^2$ ) minimal sebesar 0,85, atau hingga mencapai batas maksimum iterasi. Dengan begitu, jumlah data akhir dapat dihitung dengan rumus:

$$\text{Jumlah Akhir Data} = 63 + (n \times 100)$$



Gambar 4. 3 Arsitektur Multi-Layer Perceptron yang Sudah Disesuaikan

#### 4.2.3.2. Keunggulan dan Aplikasi

Keunggulan utama MLP adalah kemampuannya dalam mempelajari relasi kompleks antar variabel tanpa perlu asumsi distribusi data. Selain itu, arsitektur berlapis memungkinkan MLP menangani hubungan non-linear dan interdependensi antar variabel seperti:

- Peningkatan rasio hidrogen → Penurunan CO<sub>2</sub>
- Penurunan RPM → Peningkatan efisiensi termal
- Variasi volumetric efficiency → Pengaruh terhadap daya mesin

Dengan karakteristik tersebut, MLP sangat relevan dalam sistem pembakaran hybrid karena mampu melakukan prediksi performa berbasis konfigurasi parameter mesin yang kompleks dan dinamis.

#### 4.2.4. Pengolahan Data dan Teknik Augmentasi pada Model DNN

Dataset yang digunakan dalam pelatihan model DNN berasal dari hasil simulasi performa pembakaran mesin hybrid hidrogen–diesel. Setelah dilakukan *data cleaning* dengan menghapus seluruh entri yang memiliki nilai kosong (*NaN*) pada kolom target, data dibagi menjadi dua subset menggunakan metode *train-test split* dengan rasio 80:20. Fitur input mencakup parameter teknis seperti *engine speed*, *excess air ratio*, dan *volumetric efficiency*.

Untuk memastikan model dapat mengenali pola hubungan non-linear secara optimal, dilakukan proses augmentasi data dengan pendekatan berbasis *additive noise*. Teknik ini menghasilkan variasi baru dari data awal dengan menambahkan gangguan acak (*Gaussian noise*) pada nilai-nilai fitur dan target. Dalam setiap iterasi augmentasi:

1. Dibuat 5 salinan dari data asli menggunakan fungsi `add_noise()`, dengan *noise level* sebesar 5%.
2. Masing-masing salinan diberi *noise* secara proporsional terhadap nilainya.
3. Hasil augmentasi ditambahkan ke dataset pelatihan.
4. Dataset kemudian diskalakan menggunakan `StandardScaler` agar setiap fitur memiliki distribusi yang seragam.

Proses pelatihan DNN dilakukan secara iteratif dengan batas maksimum 50 iterasi, atau hingga model mencapai nilai koefisien determinasi  $R^2 \geq 0,85$  pada data uji. Dalam tiap iterasi, data baru ditambahkan sebesar 5 kali lipat dari jumlah data awal. Jika jumlah data awal adalah 63 sampel, maka pada setiap iterasi model akan memperoleh tambahan:

$$63 + 5 = 315 \text{ data sintetik}$$

Sehingga total data setelah  $n$  iterasi dapat dihitung dengan:

$$\text{Jumlah akhir data} = 63 + (n \times 315)$$

Model dibangun menggunakan framework TensorFlow dan Keras, dengan arsitektur sebagai berikut:

- Lapisan input menerima seluruh fitur teknis sebagai masukan.
- Empat hidden layer berturut-turut berukuran 256, 128, 64, dan 32 neuron, masing-masing menggunakan fungsi aktivasi ReLU.
- Lapisan output terdiri dari 6 neuron linear untuk prediksi enam variabel target.

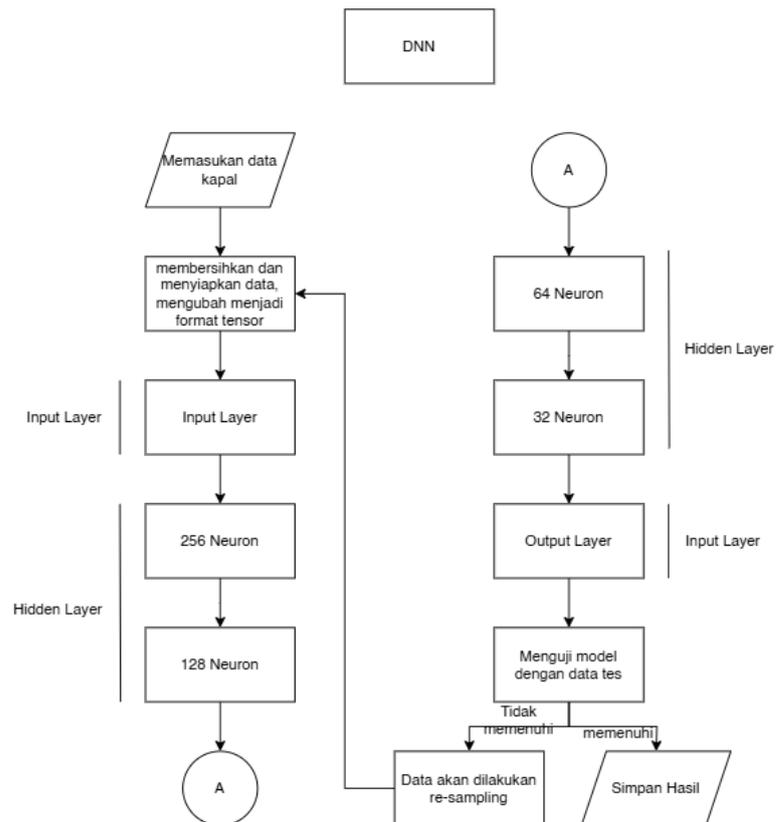
Setiap hidden layer dalam arsitektur DNN berperan dalam mengekstraksi tingkat kompleksitas hubungan antar variabel secara bertahap. Berikut deskripsi umum proses pembelajaran di masing-masing lapisan tersembunyi:

- **Hidden Layer 1 (256 neuron):** Mulai mengenali pola relasi sederhana, seperti *apakah peningkatan engine\_speed berkorelasi negatif terhadap hydrogen\_ratio*, atau *apakah volumetric\_efficiency tinggi berasosiasi dengan kenaikan brake\_power*.
- **Hidden Layer 2 (128 neuron):** Memperkuat keterkaitan kombinatorik antar fitur, seperti *pengaruh simultan antara excess\_air\_ratio dan engine\_speed terhadap emisi CO<sub>2</sub> dan NO<sub>x</sub>*.

- Hidden Layer 3 (64 neuron): Menangkap pola interaksi non-linear dan *trade-off* antar variabel, misalnya *bagaimana peningkatan hydrogen\_ratio berdampak pada peningkatan efisiensi tetapi juga memengaruhi besaran smoke opacity*.
- Hidden Layer 4 (32 neuron): Menyaring representasi data ke bentuk yang paling informatif untuk prediksi akhir, serta menekan noise atau variabel-variabel dengan kontribusi minor.

Model dilatih menggunakan algoritma optimisasi *Adam* dan fungsi kerugian *Mean Squared Error* (MSE), dengan strategi *early stopping* dan *learning rate scheduling* untuk mencegah overfitting dan mempercepat konvergensi. Pelatihan dilakukan dalam *minibatch* berukuran 32, dan validasi internal menggunakan 20% data pelatihan pada setiap epoch.

Dengan arsitektur jaringan yang dalam dan strategi augmentasi yang sistematis, model DNN dalam penelitian ini mampu menghasilkan prediksi multivariabel yang akurat untuk sistem mesin hybrid, sesuai dengan literatur terkait yang menyebutkan efektivitas pendekatan ini pada masalah regresi kompleks (LeCun et al., 2015; Goodfellow et al., 2016).



Gambar 4. 4 Arsitektur Deep Neural Network yang Sudah Disesuaikan

#### 4.2.4.1. Pengolahan Dataset dan Alur Pemrosesan Model

Dataset yang digunakan pertama-tama dinormalisasi menggunakan *StandardScaler* untuk memastikan bahwa seluruh fitur memiliki skala yang seragam. Data kemudian dibagi menjadi dua subset: 80% sebagai data pelatihan dan 20% sebagai data pengujian menggunakan metode *train\_test\_split*.

Dalam jaringan DNN ini, setiap lapisan tersembunyi bekerja secara bertingkat dalam mempelajari relasi antar fitur:

- Lapisan pertama mengevaluasi pengaruh perubahan parameter mesin awal seperti *engine\_speed* dan *excess\_air\_ratio* terhadap fluktuasi variabel target seperti *hydrogen\_ratio*.
- Lapisan kedua mengekstrak hubungan lanjutan, misalnya korelasi antara naiknya *hydrogen\_ratio* terhadap turunnya *emission\_CO2* atau *emission\_NOx*, yang menunjukkan efisiensi pembakaran.
- Lapisan berikutnya menyempurnakan pembelajaran dengan mempelajari interaksi fitur-fitur gabungan, misalnya hubungan antara *rpm rendah*, *rasio H<sub>2</sub> tinggi*, dan *brake\_power* yang tetap stabil atau meningkat, tergantung nilai dari *volumetric\_efficiency*.

Melalui pemrosesan berjenjang ini, DNN berhasil menangkap dinamika kompleks antar parameter sistem pembakaran hybrid secara lebih akurat dibanding pendekatan linier konvensional.

Dalam setiap iterasi pelatihan, dibuat lima salinan ( $n = 5$ ) dari data awal yang telah diberi *Gaussian noise*. Data augmentasi ini kemudian digabung kembali dengan data sebelumnya sehingga memperluas jumlah dan keragaman data yang tersedia untuk pelatihan. Langkah ini meningkatkan robustitas model terhadap data baru dengan fluktuasi nilai input.

Proses augmentasi juga dilanjutkan dengan langkah evaluasi metrik kinerja model pada setiap iterasi, menggunakan nilai *R<sup>2</sup> Score* dan *Mean Absolute Error* (MAE) sebagai indikator utama. Augmentasi diulang secara iteratif hingga model mencapai ambang batas akurasi tertentu (misalnya  $R^2 > 0.87$ ).

Penggunaan augmentasi berbasis *Gaussian noise* pada DNN terbukti efektif dalam meningkatkan akurasi model karena teknik ini meniru ketidakpastian alami yang terjadi dalam sistem fisik seperti variasi kecepatan mesin, perubahan rasio hydrogen, serta emisi yang fluktuatif. Teknik ini banyak digunakan dalam riset *deep learning* modern untuk simulasi kondisi lapangan (Wen et al., 2021).

#### 4.2.4.2. Keunggulan dan Aplikasi

Keunggulan utama DNN adalah kemampuannya dalam membangun representasi hierarkis dari data, memungkinkan model untuk menangkap hubungan non-linear tingkat tinggi antar variabel. Dengan banyaknya *hidden layer* yang dapat dikonfigurasi, DNN sangat efektif dalam mengidentifikasi pola-pola kompleks dalam sistem multi-input dan multi-output seperti mesin hybrid hydrogen-diesel. Beberapa hubungan penting yang mampu dipelajari oleh DNN antara lain:

- Peningkatan rasio hidrogen → Penurunan emisi CO<sub>2</sub> dan NO<sub>x</sub>
- Penurunan RPM → Stabilitas daya mesin dan efisiensi pembakaran meningkat
- Variasi *excess air ratio* → Pengaruh terhadap pembentukan asap (smoke) dan efisiensi termal

Karena memiliki kapasitas generalisasi yang tinggi, DNN mampu mempelajari interaksi yang tersembunyi dan tidak terlihat secara eksplisit dalam data, bahkan ketika data bersifat tidak beraturan atau mengandung *noise*. Keunggulan ini membuat DNN sangat cocok digunakan untuk prediksi performa sistem pembakaran berbasis hydrogen-diesel yang memiliki banyak variabel teknis dan kondisi operasi yang berubah-ubah secara dinamis.

#### 4.3. Hasil Evaluasi Model

Pada tahap ini, dilakukan proses evaluasi untuk membandingkan kinerja dari keempat model machine learning yang telah dibangun, yaitu XGBoost Regressor, Random Forest Regressor (RFR), Multi-Layer Perceptron (MLP), dan Deep Neural Network (DNN). Evaluasi dilakukan untuk menilai seberapa baik setiap model dalam memprediksi parameter performa mesin hybrid hydrogen-diesel, seperti efisiensi termal, daya, serta emisi gas buang (CO<sub>2</sub>, NO<sub>x</sub>, dan smoke) berdasarkan konfigurasi input seperti putaran mesin (RPM), rasio hidrogen, dan parameter pembakaran lainnya.

Pemilihan model terbaik sangat penting agar prediksi performa mesin dapat dilakukan secara akurat dan andal, khususnya untuk diterapkan dalam sistem kontrol cerdas berbasis AI. Evaluasi dilakukan secara kuantitatif menggunakan metrik evaluasi yang umum digunakan dalam regresi multivariabel, seperti koefisien determinasi (R<sup>2</sup>), Mean Absolute Error (MAE), serta *Hold-Out Validation*. Kombinasi ketiga metode evaluasi ini dipilih karena mampu merepresentasikan ketepatan, konsistensi, dan pola error dari masing-masing model (Chicco et al., 2021).

### 4.3.1. Perbandingan Kinerja Model

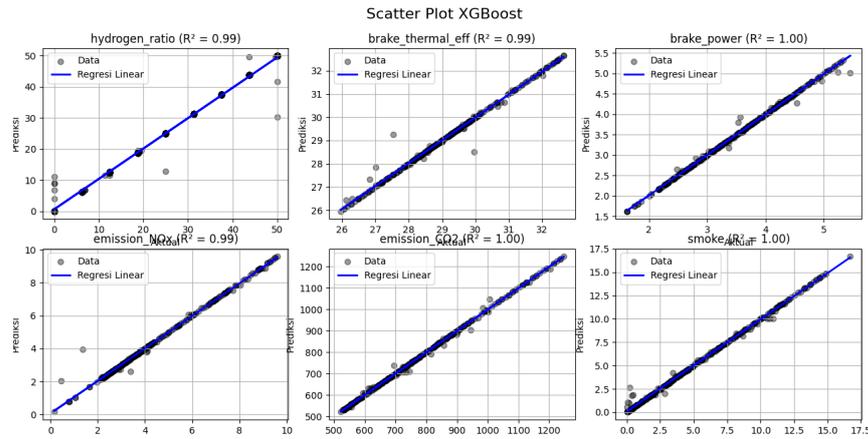
Pada subbab ini, performa masing-masing model Machine Learning yang digunakan dalam penelitian yaitu *XGBoost*, *Random Forest Regressor* (RFR), *Multi-Layer Perceptron* (MLP), dan *Deep Neural Network* (DNN) dievaluasi secara menyeluruh kuantitatif. Evaluasi ini bertujuan untuk mengukur tingkat akurasi, efisiensi, dan kestabilan model dalam memprediksi parameter-parameter kinerja mesin hybrid berbahan bakar campuran hidrogen-diesel berdasarkan input berupa parameter teknis seperti putaran mesin (RPM), *volumetric efficiency*, dan *excess air ratio*.

Tiga indikator utama digunakan sebagai dasar evaluasi, yakni:

1. *Scatter plot* antara nilai prediksi dan nilai aktual untuk setiap variabel target. Visualisasi ini berfungsi untuk melihat sejauh mana hasil prediksi model mendekati nilai sebenarnya, yang mencerminkan tingkat presisi dari model terhadap data input yang telah diberikan.
2. Kurva *Mean Absolute Error* (MAE) per iterasi, yang digunakan untuk memantau tren penurunan error selama proses pelatihan dan augmentasi data. MAE memberikan informasi seberapa besar kesalahan prediksi model dalam satuan asli data, dan grafik ini memungkinkan pemantauan konvergensi model secara progresif.
3. Waktu komputasi, sebagai indikator efisiensi proses pelatihan masing-masing model. Informasi ini penting untuk menentukan seberapa cepat model mampu belajar dari data serta seberapa layak model tersebut digunakan dalam skenario simulasi atau sistem implementasi aktual.

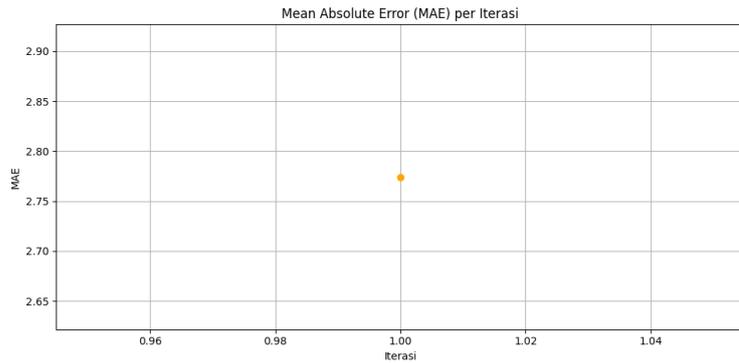
Selain ketiga metrik utama tersebut, dilakukan juga evaluasi menggunakan *metode hold-out validation*, yaitu dengan menguji performa model terhadap subset data yang tidak digunakan selama proses pelatihan. Tujuan dari uji ini adalah untuk mengukur kemampuan generalisasi model terhadap data baru atau data yang belum pernah dikenali sebelumnya. Dengan demikian, kombinasi dari evaluasi visual, metrik akurasi, dan uji validasi eksternal ini memberikan gambaran yang komprehensif tentang kinerja masing-masing model, baik dalam hal kemampuan prediksi, stabilitas hasil, maupun efisiensi waktu komputasi.

### 4.3.1.1. Model XGBoost



Gambar 4. 5 Scatter Plot XGBoost

Scatter plot menunjukkan bahwa prediksi model XGBoost sangat mendekati nilai aktual. Setiap target output, seperti *hydrogen ratio*, *brake thermal efficiency*, *brake power*, *emission NOx*, *emission CO<sub>2</sub>*, dan *smoke* memiliki sebaran titik yang sangat rapat dengan garis regresi, yang mencerminkan kemampuan prediktif tinggi.



Gambar 4. 6 Grafik MAE XGBoost

Pada Gambar 4.6, perubahan nilai MAE (Mean Absolute Error) terhadap jumlah iterasi selama proses pelatihan model XGBoost. Seperti halnya RFR, grafik hanya menunjukkan satu titik pada iterasi pertama dengan nilai MAE sekitar 2.78. Ini menunjukkan bahwa model XGBoost langsung memberikan hasil akhir setelah proses boosting selesai tanpa melalui banyak iterasi yang dicatat.

Nilai MAE yang cukup rendah ini mengindikasikan bahwa model XGBoost memiliki kemampuan prediksi yang baik terhadap data yang digunakan, meskipun grafik tidak menampilkan tren bertahap.

```

PS C:\Users\Nicholas> & C:/Users/Nicholas/AppData/Local/Programs/Python/Python38-64/Scripts/python op.py"

Iterasi ke-1
R²: 0.9538 | MAE: 2.7743 | Jumlah data: 189

Riwayat Hasil Tiap Iterasi:
Iterasi 1: R² = 0.9538, MAE = 2.7743, Data = 189

Total Waktu Komputasi: 0.39 detik (0.01 menit)
PS C:\Users\Nicholas>

```

Gambar 4. 7 Waktu Komputasi XGBoost

XGBoost hanya memerlukan 0.39 detik untuk pelatihan model, menjadikannya model paling efisien dari sisi komputasi.

```

MODE VALIDASI MANUAL - UJI PREDIKSI BERULANG

Fitur yang tersedia:
1. engine_speed
2. exhaust_temp
3. volumetric_efficiency
4. excess_air_ratio
5. bsfc

Masukkan nama fitur pertama (atau ketik 'exit' untuk keluar): bsfc
Masukkan nama fitur kedua: engine_speed
Masukkan nilai untuk bsfc: 337.25
Masukkan nilai untuk engine_speed: 750

Baris data ditemukan yang mendekati input.

Perbandingan Prediksi vs Data Aktual:
hydrogen_ratio | Prediksi: 50.0001 | Aktual: 50.0000 | Selisih: 0.0001
brake_thermal_eff | Prediksi: 17.3884 | Aktual: 17.3860 | Selisih: 0.0024
brake_power | Prediksi: 2.3895 | Aktual: 2.3900 | Selisih: 0.0005
emission_NOx | Prediksi: 9.5983 | Aktual: 9.6000 | Selisih: 0.0017
emission_CO2 | Prediksi: 533.4009 | Aktual: 533.3300 | Selisih: 0.0709
smoke | Prediksi: 11.9975 | Aktual: 12.0000 | Selisih: 0.0025

MAE untuk input ini: 0.0130

```

```

Fitur yang tersedia:
1. engine_speed
2. exhaust_temp
3. volumetric_efficiency
4. excess_air_ratio
5. bsfc

Masukkan nama fitur pertama (atau ketik 'exit' untuk keluar): bsfc
Masukkan nama fitur kedua: engine_speed
Masukkan nilai untuk bsfc: 307.840
Masukkan nilai untuk engine_speed: 1100

Baris data ditemukan yang mendekati input.

Perbandingan Prediksi vs Data Aktual:
hydrogen_ratio | Prediksi: 24.9998 | Aktual: 25.0000 | Selisih: 0.0002
brake_thermal_eff | Prediksi: 27.6307 | Aktual: 27.6300 | Selisih: 0.0007
brake_power | Prediksi: 2.9495 | Aktual: 2.9500 | Selisih: 0.0005
emission_NOx | Prediksi: 3.7598 | Aktual: 3.7600 | Selisih: 0.0002
emission_CO2 | Prediksi: 700.0062 | Aktual: 700.0000 | Selisih: 0.0062
smoke | Prediksi: 1.1203 | Aktual: 1.1200 | Selisih: 0.0003

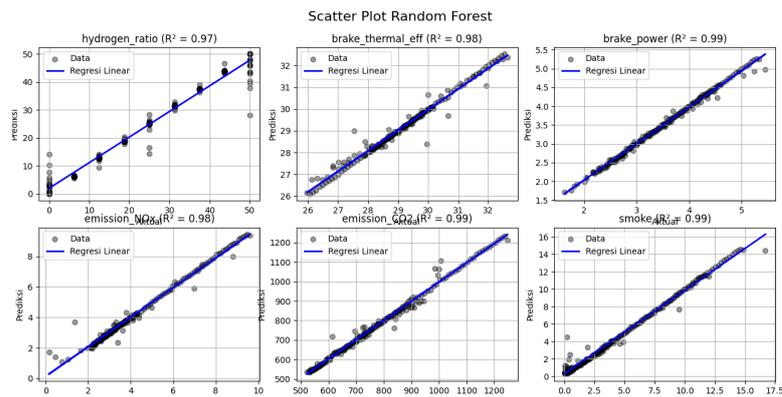
MAE untuk input ini: 0.0014

```

Gambar 4. 8 Pengujian Hold Out Validation XGBoost

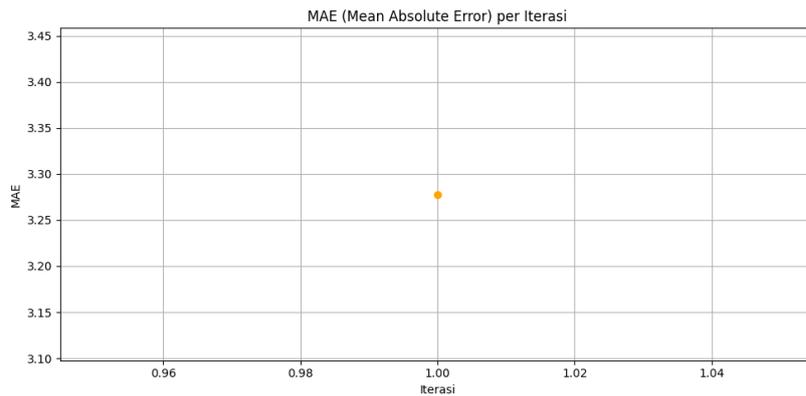
Dengan skor R<sup>2</sup> tertinggi dan MAE terendah, serta waktu komputasi tercepat, XGBoost menunjukkan performa superior. Bahkan pada pengujian hold-out, XGBoost mempertahankan MAE yang sangat kecil (0.0130 dan 0.0014), menunjukkan kemampuan generalisasi yang luar biasa terhadap data baru.

#### 4.3.1.2. Model Random Forest Regressor



Gambar 4. 9 Scatter Plot Random Forest Regressor

RFR menunjukkan performa sangat baik, dengan semua nilai R<sup>2</sup> di atas 0.97 dan sebaran prediksi sangat rapat terhadap nilai aktual. Kinerja terbaik terlihat pada brake power dan CO<sub>2</sub> emission (R<sup>2</sup> = 0.99).



Gambar 4. 10 Grafik MAE Random Forest Regressor

Pada Gambar 4.10, perubahan nilai MAE (Mean Absolute Error) terhadap jumlah iterasi selama proses pelatihan model Random Forest Regressor. Terlihat bahwa grafik hanya memiliki satu titik, yaitu pada iterasi pertama dengan nilai MAE sekitar 3.28. Hal ini terjadi karena model RFR tidak melakukan iterasi bertahap seperti model neural network, melainkan langsung menghasilkan hasil akhir setelah pelatihan.

Meskipun tidak ada tren penurunan secara bertahap, nilai MAE yang relatif rendah menunjukkan bahwa model cukup mampu menangkap pola dalam data dengan baik dalam satu proses pelatihan.

```

PS C:\Users\Nicholas> & C:/Users/Nicholas/AppData/Local/Programs/Python/Python311/Python.exe C:/Users/Nicholas/AppData/Local/Programs/Python/Python311/Scripts/Python.exe C:/Users/Nicholas/AppData/Local/Programs/Python/Python311/Python.exe New/Optimasi Random Forest Regressor.py"

Iterasi ke-1
R2: 0.9529 | MAE: 3.2780 | Jumlah data: 189

Riwayat Iterasi Random Forest:
Iter 1 | Jumlah Data: 189 | R2: 0.9529 | MAE: 3.2780

Total Waktu Komputasi: 3.18 detik (0.05 menit)

```

Gambar 4. 11 Waktu Komputasi Random Forest Regressor

Model ini hanya memerlukan 3.18 detik untuk menyelesaikan pelatihannya, menunjukkan efisiensi tinggi dalam pelatihan.

```

MODE VALIDASI MANUAL - UJI PREDIKSI MODEL BERULANG

Fitur yang tersedia:
1. engine_speed
2. exhaust_temp
3. volumetric_efficiency
4. excess_air_ratio
5. bsfc

Masukkan nama fitur pertama (atau ketik 'exit' untuk keluar): bsfc
Masukkan nama fitur kedua: engine_speed
Masukkan nilai untuk bsfc: 313.720
Masukkan nilai untuk engine_speed: 1400

Baris data ditemukan yang mendekati input.

Perbandingan Prediksi vs Data Aktual:
hydrogen_ratio | Prediksi: 24.0290 | Aktual: 25.0000 | Selisih: 0.9700
brake_thermal_eff | Prediksi: 26.8882 | Aktual: 26.8400 | Selisih: 0.0482
brake_power | Prediksi: 3.4170 | Aktual: 3.5300 | Selisih: 0.1130
emission_NOx | Prediksi: 3.6082 | Aktual: 3.6700 | Selisih: 0.0618
emission_CO2 | Prediksi: 721.8937 | Aktual: 695.2400 | Selisih: 26.5637
smoke | Prediksi: 0.6360 | Aktual: 0.4500 | Selisih: 0.1860

MAE untuk input ini: 4.6471

Fitur yang tersedia:
1. engine_speed
2. exhaust_temp
3. volumetric_efficiency
4. excess_air_ratio
5. bsfc

Masukkan nama fitur pertama (atau ketik 'exit' untuk keluar): exhaust_temp
Masukkan nama fitur kedua: engine_speed
Masukkan nilai untuk exhaust_temp: 254.9
Masukkan nilai untuk engine_speed: 900

Baris data ditemukan yang mendekati input.

Perbandingan Prediksi vs Data Aktual:
hydrogen_ratio | Prediksi: 38.0564 | Aktual: 50.0000 | Selisih: 11.9436
brake_thermal_eff | Prediksi: 24.4959 | Aktual: 25.2600 | Selisih: 0.7641
brake_power | Prediksi: 2.4246 | Aktual: 2.2700 | Selisih: 0.1546
emission_NOx | Prediksi: 5.3508 | Aktual: 8.8000 | Selisih: 3.4492
emission_CO2 | Prediksi: 707.7517 | Aktual: 604.7600 | Selisih: 102.9917
smoke | Prediksi: 5.9346 | Aktual: 3.9300 | Selisih: 2.0046

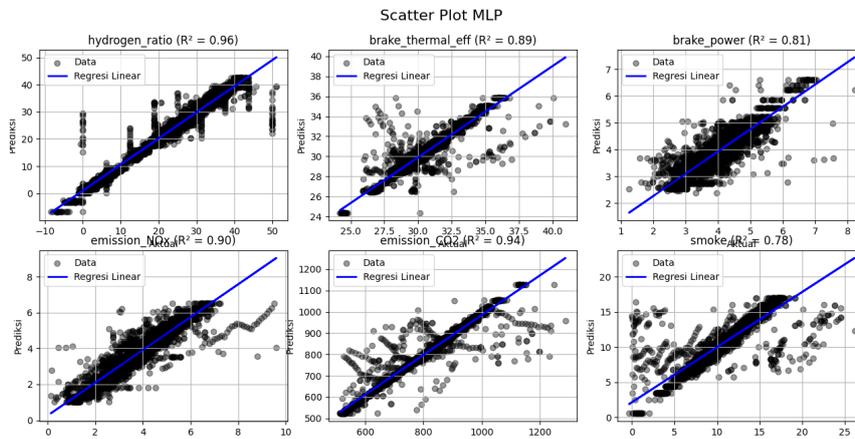
MAE untuk input ini: 20.2180

```

Gambar 4. 12 Pengujian Hold Out Validation Random Forest Regressor

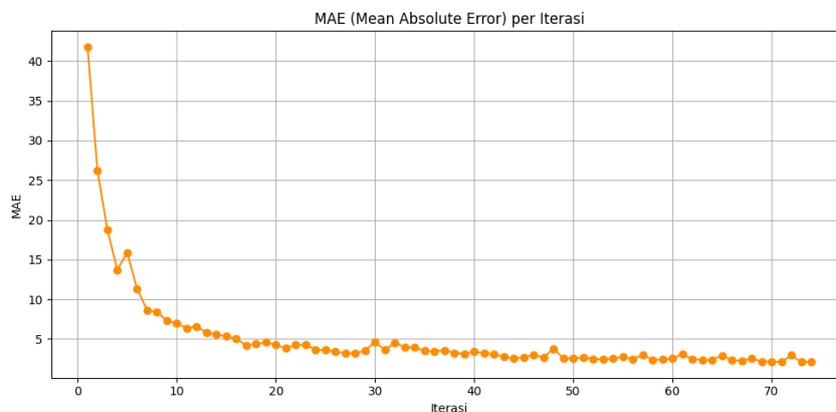
Meskipun sedikit di bawah XGBoost dalam hal  $R^2$  dan MAE, RFR tetap menjadi model yang sangat kompetitif. MAE pada *hold-out validation* Random Forest Regression cenderung kurang stabil (4.6471 dan 20.2180).

#### 4.3.1.3. Model Multi Layer Perceptron (MLP)



Gambar 4. 13 Scatter Plot Multi Layer Perceptron

MLP menunjukkan prediksi yang baik, terutama untuk *hydrogen ratio* ( $R^2 = 0.96$ ), *emission CO<sub>2</sub>* ( $R^2 = 0.94$ ), dan *NO<sub>x</sub>* ( $R^2 = 0.90$ ). Namun, akurasi menurun pada variabel *smoke* ( $R^2 = 0.78$ ).



Gambar 4. 14 Grafik MAE Multi Layer Perceptron

Pada Gambar 4.14, perubahan nilai MAE (Mean Absolute Error) terhadap jumlah iterasi selama proses pelatihan model. Terlihat bahwa pada awal pelatihan, nilai MAE cukup tinggi, yaitu sekitar 42. Namun, seiring bertambahnya iterasi, nilai MAE secara konsisten mengalami penurunan yang signifikan, yang mengindikasikan bahwa model semakin mampu mempelajari pola dari data dengan baik.

Setelah sekitar 30 iterasi, nilai MAE mulai stabil di kisaran 2 hingga 4. Ini menunjukkan bahwa proses pelatihan telah mencapai tahap konvergensi, di mana penurunan error tidak lagi

signifikan. Stabilitas ini menandakan bahwa model sudah cukup optimal dan tidak mengalami overfitting dalam jumlah iterasi yang digunakan.

Secara keseluruhan, grafik ini memberikan indikasi bahwa model berhasil belajar dengan baik dan mencapai performa yang stabil dalam meminimalkan error terhadap data yang digunakan.

```

Iter 62 | Data: 6289 | R2: 0.8161 | MAE: 2.4043
Iter 63 | Data: 6389 | R2: 0.8242 | MAE: 2.3847
Iter 64 | Data: 6489 | R2: 0.8225 | MAE: 2.3448
Iter 65 | Data: 6589 | R2: 0.8268 | MAE: 2.9193
Iter 66 | Data: 6689 | R2: 0.8342 | MAE: 2.3092
Iter 67 | Data: 6789 | R2: 0.8285 | MAE: 2.2292
Iter 68 | Data: 6889 | R2: 0.8364 | MAE: 2.5169
Iter 69 | Data: 6989 | R2: 0.8425 | MAE: 2.1604
Iter 70 | Data: 7089 | R2: 0.8235 | MAE: 2.1591
Iter 71 | Data: 7189 | R2: 0.8497 | MAE: 2.0856
Iter 72 | Data: 7289 | R2: 0.8012 | MAE: 2.9543
Iter 73 | Data: 7389 | R2: 0.8462 | MAE: 2.0810
Iter 74 | Data: 7489 | R2: 0.8552 | MAE: 2.0994

Total Waktu Komputasi: 857.04 detik (14.28 menit)

```

Gambar 4. 15 Waktu komputasi *Multi Layer Perceptron*

MLP memerlukan waktu komputasi selama 857.04 detik untuk mencapai performa optimal, yang secara signifikan lebih tinggi dibandingkan dengan waktu yang dibutuhkan oleh model Random Forest Regressor (RFR) maupun XGBoost. Waktu komputasi yang panjang ini disebabkan oleh proses pelatihan berulang yang dilakukan sebanyak 74 kali, sebagai bagian dari strategi augmentasi data untuk mencapai target performa

```

Fitur yang tersedia:
1. engine_speed
2. exhaust_temp
3. volumetric_efficiency
4. excess_air_ratio
5. bsfc

Masukkan nama fitur pertama (atau ketik 'exit' untuk keluar): excess_air_ratio
Masukkan nama fitur kedua: engine_speed
Masukkan nilai untuk excess_air_ratio: 1.540
Masukkan nilai untuk engine_speed: 1400

Input ditemukan dalam dataset asli.

Perbandingan Prediksi vs Data Aktual:
hydrogen_ratio | Prediksi: 40.7953 | Aktual: 50.0000 | Selisih: 9.2047
brake_thermal_eff | Prediksi: 18.9074 | Aktual: 25.5300 | Selisih: 6.6226
brake_power | Prediksi: 19.0937 | Aktual: 3.1000 | Selisih: 15.9937
emission_NOx | Prediksi: 18.6534 | Aktual: 5.2700 | Selisih: 13.3834
emission_CO2 | Prediksi: 964.2382 | Aktual: 784.7600 | Selisih: 259.4782
smoke | Prediksi: 10.7685 | Aktual: 0.4300 | Selisih: 10.3385

MAE untuk input ini: 52.5035

```

```

MODE VALIDASI MANUAL - UJI PREDIKSI BERULANG

Fitur yang tersedia:
1. engine_speed
2. exhaust_temp
3. volumetric_efficiency
4. excess_air_ratio
5. bsfc

Masukkan nama fitur pertama (atau ketik 'exit' untuk keluar): engine_speed
Masukkan nama fitur kedua: excess_air_ratio
Masukkan nilai untuk engine_speed:
1750
Masukkan nilai untuk excess_air_ratio: 1.504
.7924
brake_thermal_eff | Prediksi: 17.5850 | Aktual: 29.2100 | Selisih: 11.6250
brake_power | Prediksi: 18.6553 | Aktual: 4.9600 | Selisih: 13.6953
emission_NOx | Prediksi: 18.3224 | Aktual: 2.7300 | Selisih: 15.5924
emission_CO2 | Prediksi: 1173.1353 | Aktual: 1000.0000 | Selisih: 173.1353
smoke | Prediksi: 6.6798 | Aktual: 0.3500 | Selisih: 6.3298

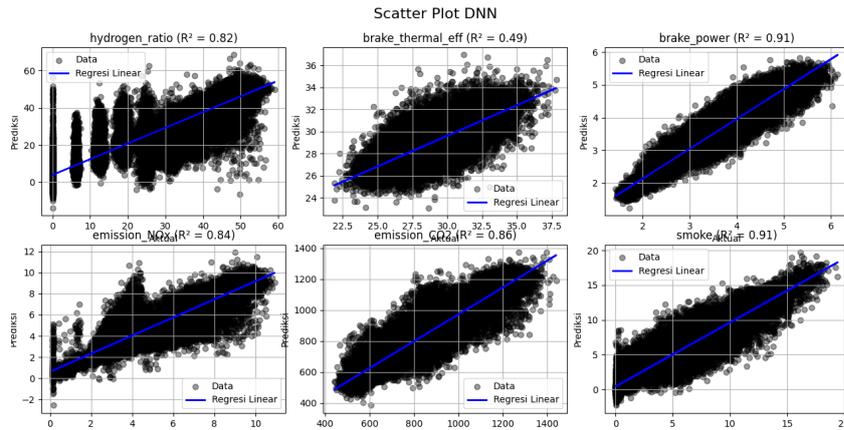
MAE untuk input ini: 38.1950

```

Gambar 4. 16 Pengujian *Hold Out Validation Multi Layer Perceptron*

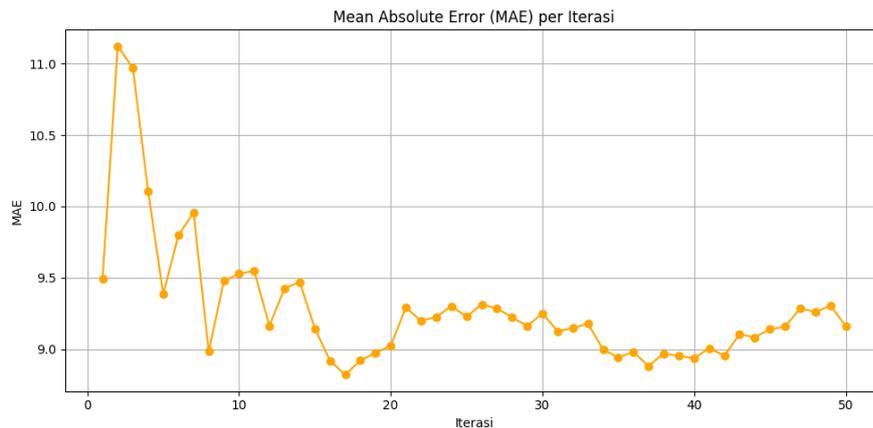
MLP memberikan prediksi yang cukup akurat pada sebagian besar variabel. Namun, performa MLP saat hold-out validation menurun drastis (MAE = 52.50 dan 38.19), mengindikasikan kurang stabilnya model ini ketika diuji pada data baru.

#### 4.3.1.4. Model Deep Neural Network



Gambar 4. 17 Scatter Plot Deep Neural Network

DNN menunjukkan prediksi kuat untuk brake power dan smoke ( $R^2 > 0.90$ ), namun lemah pada brake thermal efficiency ( $R^2 = 0.49$ ), yang menurunkan rata-rata  $R^2$  secara keseluruhan.



Gambar 4. 18 Grafik MAE Deep Neural Network

Pada Gambar 4.18, perubahan nilai MAE (Mean Absolute Error) selama proses pelatihan model Deep Neural Network (DNN). Pada awal iterasi, nilai MAE berfluktuasi cukup tinggi, berada di kisaran 9.5 hingga 11.1. Fluktuasi ini mencerminkan proses awal pelatihan di mana model masih menyesuaikan bobot dan belum menemukan pola yang stabil dari data.

Memasuki iterasi ke-15 hingga ke-50, nilai MAE cenderung menurun dan mulai stabil di kisaran 8.8 hingga 9.4. Meskipun penurunannya tidak terlalu drastis, tren ini menunjukkan bahwa model mulai mengalami proses konvergensi dan pembelajaran yang lebih konsisten.

Namun, masih terlihat sedikit fluktuasi di akhir iterasi, yang bisa mengindikasikan bahwa model belum sepenuhnya optimal atau masih terdapat ruang untuk penyempurnaan, baik dari segi arsitektur maupun parameter pelatihan. Secara umum, grafik ini menunjukkan bahwa

model DNN berhasil belajar dengan stabil, meskipun dengan variasi kecil dalam performa dari iterasi ke iterasi.

```

Iterasi ke-47
279/279 ██████████ 0s 1ms/step
R² = 0.8066 | MAE = 9.2861 | Data: 44604 sampel

Iterasi ke-48
285/285 ██████████ 0s 1ms/step
R² = 0.8127 | MAE = 9.2601 | Data: 45549 sampel

Iterasi ke-49
291/291 ██████████ 0s 932us/step
R² = 0.8076 | MAE = 9.3049 | Data: 46494 sampel

Iterasi ke-50
297/297 ██████████ 0s 965us/step
R² = 0.8077 | MAE = 9.1612 | Data: 47439 sampel

Loop Berhenti - Model Mencapai Target
Final R² Score: 0.8077
Final MAE: 9.1612
Total Waktu Komputasi: 3671.17 detik (61.19 menit)
1483/1483 ██████████ 1s 888us/step

```

Gambar 4. 19 Waktu komputasi Deep Neural Network

DNN adalah model dengan kebutuhan komputasi tertinggi (3671.17 detik), mencerminkan kompleksitas proses pelatihannya.

```

MODE VALIDASI MANUAL - UJI PREDIKSI MODEL BERULANG

Fitur yang tersedia:
1. engine_speed
2. exhaust_temp
3. volumetric_efficiency
4. excess_air_ratio
5. bsfc

Masukkan nama fitur pertama (atau ketik 'exit' untuk keluar): engine_speed
Masukkan nama fitur kedua: bsfc
Masukkan nilai untuk engine_speed: 2100
Masukkan nilai untuk bsfc: 415.680

Baris data ditemukan yang mendekati input.
1/1 ██████████ 0s 42ms/step

Perbandingan Prediksi vs Data Aktual:
hydrogen_ratio | Prediksi: 23.8525 | Aktual: 25.0000 | Selisih: 1.1475
brake_thermal_eff | Prediksi: 22.3556 | Aktual: 22.1000 | Selisih: 0.2556
brake_power | Prediksi: 4.6203 | Aktual: 4.5900 | Selisih: 0.0303
emission_NOx | Prediksi: 3.7135 | Aktual: 3.6700 | Selisih: 0.0435
emission_CO2 | Prediksi: 944.2122 | Aktual: 904.7600 | Selisih: 39.4522
smoke | Prediksi: 0.1465 | Aktual: 0.0980 | Selisih: 0.0485

MAE untuk input ini: 6.8296

```

```

Fitur yang tersedia:
1. engine_speed
2. exhaust_temp
3. volumetric_efficiency
4. excess_air_ratio
5. bsfc

Masukkan nama fitur pertama (atau ketik 'exit' untuk keluar): bsfc
Masukkan nama fitur kedua: engine_speed
Masukkan nilai untuk bsfc: 325.500
Masukkan nilai untuk engine_speed: 1100

Baris data ditemukan yang mendekati input.
1/1 ██████████ 0s 34ms/step

Perbandingan Prediksi vs Data Aktual:
hydrogen_ratio | Prediksi: 52.5676 | Aktual: 50.0000 | Selisih: 2.5676
brake_thermal_eff | Prediksi: 26.6309 | Aktual: 26.3100 | Selisih: 0.3209
brake_power | Prediksi: 2.6466 | Aktual: 2.7800 | Selisih: 0.1334
emission_NOx | Prediksi: 6.2057 | Aktual: 5.7700 | Selisih: 0.4357
emission_CO2 | Prediksi: 562.7606 | Aktual: 533.3300 | Selisih: 29.4306
smoke | Prediksi: 0.6669 | Aktual: 1.0900 | Selisih: 0.4231

MAE untuk input ini: 5.5519

```

Gambar 4. 20 Pengujian Hold Out Validation Deep Neural Network

Meskipun DNN memiliki potensi tinggi dalam menangkap hubungan non-linier yang kompleks, waktu pelatihan yang lama serta nilai MAE pada hold-out validation yang fluktuatif (MAE = 6.82 dan 5.55) menunjukkan bahwa model ini memerlukan penyempurnaan lebih lanjut dalam konfigurasinya.

#### 4.4. Pemilihan Model Terbaik dan Penerapannya

Berdasarkan hasil evaluasi performa kuantitatif dan visual terhadap empat model yang digunakan XGBoost, *Random Forest Regressor* (RFR), *Multi-Layer Perceptron* (MLP), dan *Deep Neural Network* (DNN) dapat disimpulkan bahwa model XGBoost memiliki kinerja terbaik secara keseluruhan dalam memprediksi parameter performa mesin hybrid hydrogen-diesel.

Penilaian ini didasarkan pada tiga aspek utama, yaitu akurasi prediksi ( $R^2$  dan MAE), efisiensi komputasi, dan kestabilan performa saat diuji ulang melalui hold-out validation. Model XGBoost menunjukkan nilai rata-rata  $R^2$  tertinggi (0.9538), MAE terkecil (2.7743), serta waktu pelatihan tercepat (0.39 detik). Bahkan dalam pengujian hold-out, XGBoost mempertahankan MAE yang sangat rendah (0.0130 dan 0.0014), mengindikasikan kemampuan generalisasi yang sangat kuat terhadap data baru.

Meskipun *Random Forest Regressor* (RFR) juga memiliki performa yang kompetitif dengan skor  $R^2$  0.9529 dan MAE 3.2790, performanya pada validasi kedua (MAE = 20.2180) lebih fluktuatif dibandingkan XGBoost. Model MLP dan DNN menunjukkan performa yang layak, namun membutuhkan iterasi pelatihan yang jauh lebih banyak (masing-masing 74 dan 50 iterasi), serta mengalami penurunan performa signifikan saat diuji ulang dengan data yang tidak dikenali sebelumnya.

Tabel 4. 3 Evaluasi Kinerja Masing-Masing Model

| Model                   | $R^2$  | MAE (Training) | MAE (Hold Out 1) | MAE (Hold Out 2) | Waktu Pelatihan | Jumlah Iterasi |
|-------------------------|--------|----------------|------------------|------------------|-----------------|----------------|
| XGBoost Regressor       | 0.9538 | 2.7743         | 0.013            | 0,0014           | 0.39            | 1              |
| Random Forest Regressor | 0.9529 | 3.2780         | 4.6471           | 20.2180          | 3.18            | 1              |
| Multi-Layer Perceptron  | 0.8552 | 2.0994         | 52.5035          | 38.1950          | 857.04          | 74             |
| Deep Neural Network     | 0.8077 | 9.1612         | 6.8296           | 5.5519           | 3671.17         | 50             |

Dengan mempertimbangkan keseimbangan antara akurasi, efisiensi, dan kestabilan, maka XGBoost dipilih sebagai model terbaik untuk digunakan pada tahap simulasi selanjutnya. Model ini akan digunakan untuk melakukan simulasi berbagai skenario pengoperasian mesin hybrid, terutama dalam merespons perubahan rasio hidrogen terhadap output performa seperti efisiensi termal, emisi NO<sub>x</sub> dan CO<sub>2</sub>, serta daya mesin.

## **BAB 5**

### **HASIL SIMULASI**

#### **5.1. Desain Simulasi**

Setelah melalui serangkaian proses evaluasi dan perbandingan performa dari empat algoritma machine learning yaitu XGBoost, *Random Forest Regressor* (RFR), *Multi-Layer Perceptron* (MLP), dan *Deep Neural Network* (DNN), model XGBoost telah dipilih sebagai model terbaik berdasarkan kombinasi nilai koefisien determinasi ( $R^2$ ), nilai error rata-rata (MAE), waktu komputasi, serta kestabilan performa pada pengujian hold-out validation.

Bab ini bertujuan untuk mengimplementasikan model XGBoost dalam skenario simulasi nyata guna memetakan dan menganalisis hubungan antar parameter utama mesin hybrid hydrogen-diesel. Simulasi ini difokuskan pada pengaruh rasio campuran hidrogen terhadap efisiensi termal, emisi gas buang, dan daya mesin (*brake power*) pada berbagai kondisi operasi mesin, seperti perubahan kecepatan mesin (RPM) dan rasio udara berlebih (*excess air ratio*).

Dengan adanya simulasi ini, model yang telah dilatih diharapkan mampu merepresentasikan karakteristik pembakaran dan performa mesin berdasarkan data masukan teknis yang disediakan. Simulasi ini juga menjadi bukti bahwa pendekatan berbasis machine learning, khususnya XGBoost, memiliki potensi besar untuk diterapkan dalam proses optimasi sistem pembakaran hybrid secara non-eksperimental, dengan tetap mempertahankan tingkat akurasi yang tinggi.

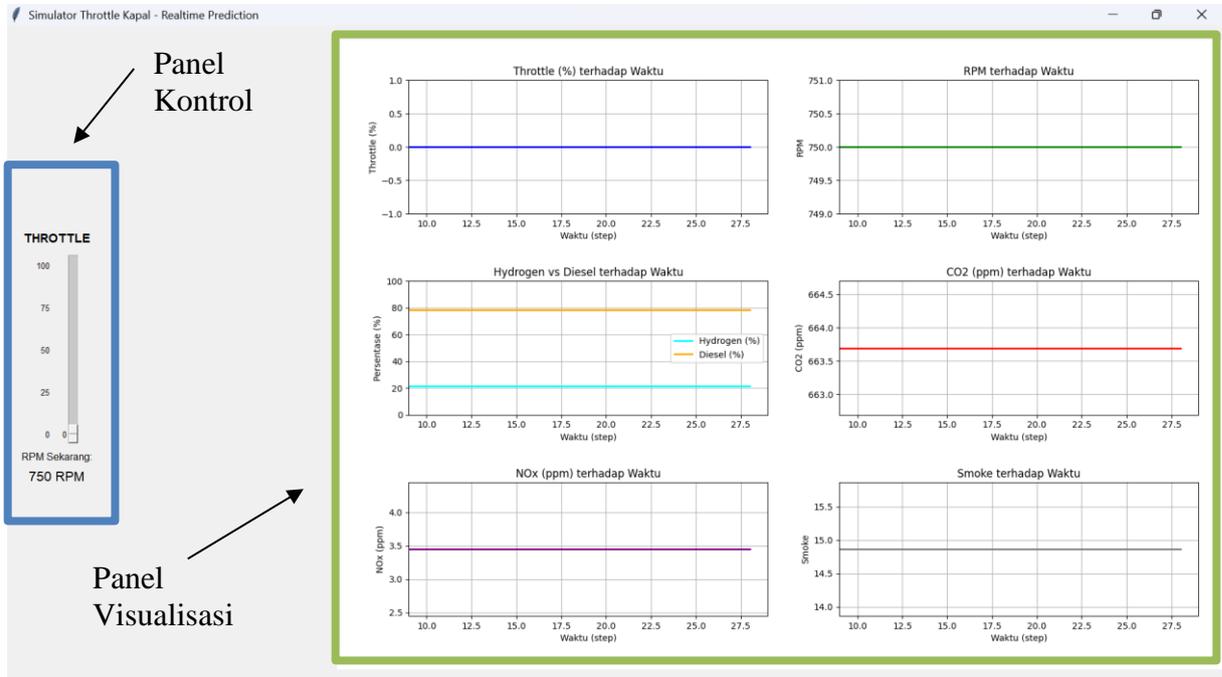
Desain simulasi dalam penelitian ini dirancang untuk memvisualisasikan secara interaktif hasil prediksi dari model XGBoost terhadap parameter-parameter penting dalam sistem pembakaran mesin hybrid hydrogen-diesel. Tujuan utama dari simulasi ini adalah menguji respons model terhadap perubahan input berupa nilai *throttle* yang merepresentasikan kecepatan putaran mesin (RPM), dan mengevaluasi perubahan output seperti rasio hidrogen, emisi CO<sub>2</sub>, emisi NO<sub>x</sub>, smoke, serta efisiensi termal dan daya mesin (*brake power*).

##### **5.1.1. Arsitektur Simulasi**

Arsitektur simulasi yang dikembangkan dalam penelitian ini bertujuan untuk menciptakan sebuah lingkungan interaktif yang merepresentasikan dinamika pengoperasian mesin kapal berbasis sistem pembakaran hybrid hidrogen-diesel. Antarmuka ini dibangun menggunakan bahasa pemrograman *Python* dengan beberapa pustaka pendukung, seperti

*Tkinter* untuk *Graphical User Interface* (GUI), *Matplotlib* untuk visualisasi dinamis, *XGBoost* sebagai inti dari model prediksi, serta *Pandas* dan *NumPy* untuk manipulasi data numerik.

Secara umum, tampilan antarmuka terdiri dari dua komponen utama, yaitu:



Gambar 5. 1 Visualisasi Simulasi

1. Panel Kontrol (*Control Panel*)

Panel ini berada di sisi kiri jendela simulasi dan berfungsi sebagai input utama pengguna. Komponen yang terdapat pada panel ini meliputi:

- Slider *throttle*: digunakan untuk mensimulasikan tingkat pembukaan *throttle* mesin dalam skala 0–100%.
- Label RPM dinamis: menampilkan nilai RPM yang dihasilkan secara *real-time* berdasarkan input *throttle* yang diberikan.

2. Panel Visualisasi (*Visualization Panel*)

Panel ini menampilkan enam grafik *real-time* yang merepresentasikan perubahan parameter output terhadap waktu. Enam parameter tersebut adalah:

- *Throttle* (%)
- RPM
- *Hydrogen vs Diesel Ratio* (%)
- *Emission CO<sub>2</sub>* (ppm)
- *Emission NO<sub>x</sub>* (ppm)
- *Smoke* (nilai penghitaman gas buang)

Salah satu keunggulan dari sistem simulasi ini adalah kemampuannya untuk menampilkan hasil prediksi model secara *real-time* melalui tampilan grafik yang dinamis dan interaktif. Dalam tampilan ini, pengguna dapat melihat bagaimana setiap perubahan pada *throttle* memengaruhi berbagai parameter mesin secara langsung.

Terdapat enam parameter utama yang divisualisasikan melalui grafik:

1. *Throttle (%)*

Grafik ini menampilkan seberapa besar *throttle* dibuka oleh pengguna. Nilai *throttle* diatur langsung melalui slider pada antarmuka, dan menjadi titik awal dari seluruh perubahan sistem.

2. RPM (*Revolutions Per Minute*)

Grafik RPM menunjukkan kecepatan putaran mesin yang terus berubah mengikuti nilai *throttle*. Namun, perubahan ini tidak langsung melonjak, melainkan terjadi secara bertahap mengikuti *ramp rate* yang disimulasikan, sehingga lebih mencerminkan kondisi mesin di dunia nyata.

3. *Hydrogen Ratio (%)*

Parameter ini menunjukkan seberapa besar proporsi hidrogen yang digunakan dalam campuran bahan bakar. Semakin tinggi rasio ini, biasanya menunjukkan bahwa sistem sedang memanfaatkan lebih banyak energi bersih dari hidrogen.

4. Emisi CO<sub>2</sub> (ppm)

Grafik ini membantu memantau seberapa banyak karbon dioksida yang dihasilkan selama proses pembakaran. Informasi ini penting untuk menilai sejauh mana mesin berhasil mengurangi emisi gas rumah kaca dengan bantuan hidrogen.

5. Emisi NO<sub>x</sub> (ppm)

NO<sub>x</sub> adalah jenis emisi yang sering terbentuk akibat pembakaran pada suhu tinggi. Melalui grafik ini, pengguna bisa melihat bagaimana perubahan pada RPM atau *hydrogen ratio* mempengaruhi emisi NO<sub>x</sub>.

6. *Smoke*

Grafik ini menunjukkan tingkat asap atau partikel hasil pembakaran. Nilai *smoke* yang tinggi bisa menjadi tanda adanya pembakaran yang tidak sempurna, sehingga bisa menjadi acuan untuk mengevaluasi efisiensi sistem.

Setiap grafik hanya menampilkan 20 data terbaru, agar tampilan tetap bersih dan fokus pada kondisi terkini. Hal ini disebut sebagai *rolling window*, dan sangat berguna untuk memantau perubahan sistem secara *real-time* tanpa harus melihat data terlalu lama ke belakang.

Pembaruan data pada grafik dilakukan setiap 300 milidetik menggunakan animasi dari *matplotlib*, sehingga perubahan visual terasa halus dan langsung merepresentasikan kondisi yang sedang terjadi.

Secara keseluruhan, fitur visualisasi ini tidak hanya membuat simulasi menjadi lebih menarik, tetapi juga membantu pengguna memahami pola hubungan antar parameter mesin secara langsung, tanpa perlu membaca angka-angka secara manual. Dengan begitu, sistem ini juga bisa berfungsi sebagai alat bantu edukasi maupun monitoring untuk sistem pembakaran berbasis AI.

Visualisasi disusun dalam layout grid 3x2 menggunakan *Matplotlib*, dengan setiap subplot menampilkan kurva dinamis yang diperbarui setiap 300 milidetik melalui *FuncAnimation*. Setiap grafik disesuaikan dengan rentang nilai masing-masing parameter agar dapat divisualisasikan secara jelas dan responsif.

Seluruh proses simulasi dijalankan dalam satu kerangka kerja *Tkinter*, yang memungkinkan integrasi antarmuka pengguna dengan backend model prediksi dalam satu sistem runtime. Arsitektur ini mendukung pemantauan respons sistem pembakaran terhadap perubahan *throttle* secara visual dan interaktif, sehingga sangat berguna untuk menganalisis pola dinamis pada sistem hybrid berbahan bakar hidrogen.

### 5.1.2. Mekanisme Simulasi

Mekanisme simulasi dalam penelitian ini dirancang untuk merepresentasikan respons sistem mesin kapal terhadap perubahan *throttle* secara real-time. Proses ini dijalankan secara iteratif dalam sebuah fungsi bernama *simulate\_step()*, yang akan dipanggil secara berkala menggunakan *FuncAnimation* dari pustaka *matplotlib.animation* dengan interval setiap 300 milidetik.

Langkah-langkah utama dalam mekanisme simulasi dapat dijelaskan sebagai berikut:

1. Pembacaan Input *Throttle*

Nilai input *throttle* dibaca dari slider vertikal yang tersedia di GUI. Nilai ini berada dalam rentang 0–100%, dan merepresentasikan seberapa besar *throttle* dibuka oleh operator.

2. Perhitungan Target RPM

Berdasarkan nilai *throttle*, target RPM dihitung menggunakan rumus linier sebagai berikut:

$$RPM_{target} = 750 + (2500 - 750) \times \frac{Throttle}{100} \quad (5.1)$$

RPM minimum diasumsikan 750 dan maksimum 2500. Nilai RPM saat ini (*current\_rpm*) akan dinaikkan atau diturunkan secara bertahap mengikuti *ramp\_rate* = 50, untuk menyimulasikan akselerasi bertahap yang realistis.

### 3. Pembuatan Input untuk Prediksi

Data input baru untuk model prediksi dibuat dengan mengambil template data asli, kemudian mengganti nilai *engine\_speed* sesuai dengan *current\_rpm* yang sedang berlangsung. Input ini kemudian diberikan ke model XGBoost yang telah dilatih sebelumnya.

### 4. Prediksi Output Mesin

Model akan memprediksi enam parameter output: *hydrogen ratio*, *brake thermal efficiency*, *brake power*, *emission CO<sub>2</sub>*, *emission NO<sub>x</sub>*, dan *smoke*. Namun, dalam tampilan GUI, hanya empat parameter utama yang divisualisasikan, yaitu *hydrogen ratio*, *emission CO<sub>2</sub>*, *emission NO<sub>x</sub>*, dan *smoke*.

### 5. Penyimpanan dan Visualisasi Data

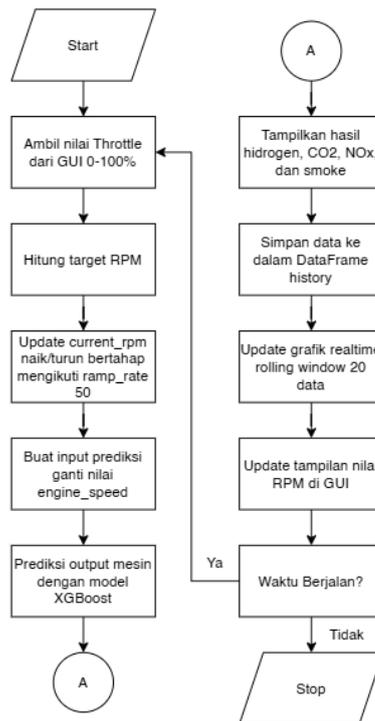
Hasil prediksi disimpan ke dalam sebuah *DataFrame historis* dan kemudian ditambahkan ke masing-masing kurva visualisasi. Data ditampilkan dalam bentuk kurva secara *real-time* yang menggambarkan tren perubahan parameter output sebagai fungsi dari waktu dan perubahan *throttle*.

### 6. Pengaturan Skala Dinamis dan *Windowing*

Untuk menjaga visualisasi tetap bersih dan informatif, setiap grafik memiliki *window size* sebesar 20 data terakhir. Ini berarti kurva akan selalu memperlihatkan dinamika parameter dalam jendela waktu yang bergerak (*rolling window*) untuk memudahkan interpretasi pergerakan data secara lokal.

### 7. Pembaruan GUI

Nilai RPM ditampilkan secara dinamis di GUI setiap kali berubah. Semua grafik diperbarui menggunakan *set\_data()* dan *draw()* agar animasi tetap berjalan dengan lancar.



Gambar 5. 2 Flowchart Simulasi

Dengan mekanisme ini, simulasi mampu merepresentasikan perilaku sistem mesin hybrid secara interaktif, memperlihatkan hubungan antara throttle, RPM, dan output performa mesin seperti emisi dan efisiensi.

### 5.1.3. Integrasi Model Prediktif

Model prediktif XGBoost yang telah melalui proses pelatihan dan augmentasi data kemudian diintegrasikan secara langsung ke dalam simulasi menggunakan pustaka MultiOutputRegressor dari *scikit-learn*. Model ini telah dilatih untuk memprediksi enam parameter kinerja mesin berdasarkan fitur-fitur input, seperti kecepatan mesin (*engine speed*), *excess air ratio*, dan *volumetric efficiency*. Namun dalam implementasi simulasi, input yang digunakan difokuskan pada variabel RPM yang dinamis terhadap input *throttle*.

Model yang telah dilatih kemudian digunakan secara berulang (*real-time loop*) untuk menghasilkan prediksi pada setiap langkah waktu. Proses prediksi dilakukan terhadap satu baris input, yang dibentuk berdasarkan template data awal dan dimodifikasi sesuai dengan nilai RPM terkini. Proses ini menggunakan perintah pada gambar 5.3

```

input_row = template_row.copy()
input_row['engine_speed'] = current_rpm
pred = model.predict(pd.DataFrame([input_row]))[0]
  
```

Gambar 5. 3 Cuplikan kode proses pembentukan input prediksi model

Dari hasil prediksi pred, diambil empat nilai output utama yang divisualisasikan, yaitu:

- *Hydrogen vs Diesel Ratio* (%)
- Emission CO<sub>2</sub> (ppm)
- Emission NO<sub>x</sub> (ppm)
- Smoke (opacity index)

Empat parameter tersebut dipilih karena memiliki signifikansi paling tinggi dalam menunjukkan performa mesin berbasis hidrogen-diesel, terutama dalam konteks efisiensi pembakaran dan emisi gas buang.

Model ini bekerja secara sinkron dengan GUI menggunakan pembaruan waktu tetap (300 ms per frame), dan hasil prediksi digunakan untuk memperbarui grafik serta nilai RPM yang ditampilkan. Integrasi ini memungkinkan simulasi interaktif yang merepresentasikan secara realistis perubahan performa mesin akibat pengaturan throttle oleh operator.

Proses ini juga mencerminkan penerapan nyata dari model *Machine Learning* yang telah dilatih pada data historis dan kemudian diterapkan dalam sistem *decision support* berbasis antarmuka.

## 5.2. Skenario simulasi

Simulasi dilakukan untuk mengevaluasi performa sistem kontrol hybrid hydrogen-diesel engine terhadap variasi kondisi operasional kapal, yang diklasifikasikan berdasarkan rentang persentase throttle (%). Nilai throttle dihitung dari basis RPM minimum 750 (idle, 0%) hingga maksimum 2500 (full throttle, 100%).

Berikut lima skenario utama yang diuji:

### a. Skenario 1 – Kapal Bermanuver (Throttle Fluktuatif 10–30%)

Kondisi ini menggambarkan saat kapal sedang bermanuver, seperti saat masuk/keluar pelabuhan. Throttle berubah-ubah secara cepat antara 10%–30%, yang ekuivalen dengan RPM sekitar 925–1275.

- Fokus: Menilai adaptasi model terhadap perubahan beban mendadak dan kontrol bahan bakar real-time.

### b. Skenario 2 – Kapal Stabil dengan *Throttle* Meningkat Bertahap (30%–80%)

Throttle dinaikkan secara perlahan dari 30% (sekitar 1275 RPM) ke 80% (sekitar 2150 RPM), meniru kondisi kapal yang baru keluar dari pelabuhan menuju kecepatan jelajah.

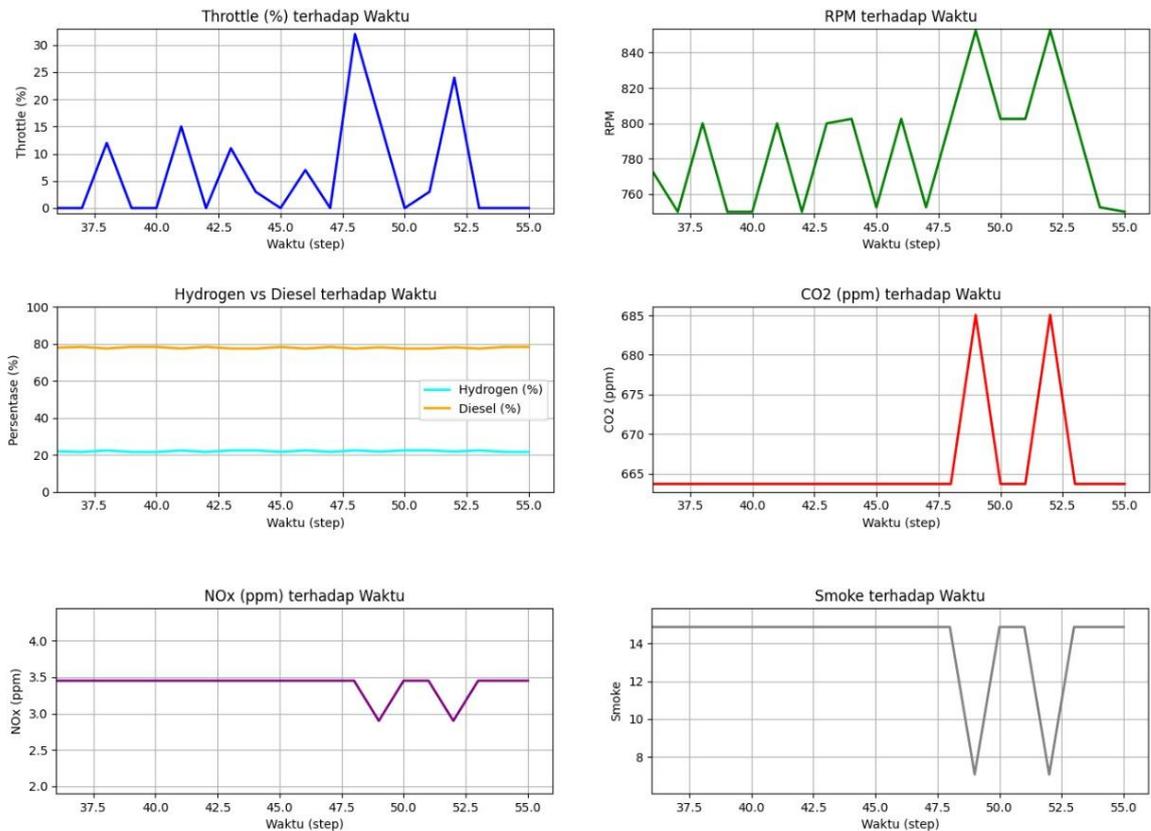
- Fokus: Melihat prediksi model saat kondisi mesin transisi dari beban ringan ke penuh secara stabil.

- c. Skenario 3 – Kapal Menurunkan *Throttle* Secara Bertahap (80%–30%)
- Throttle diturunkan perlahan dari 80% ke 30% saat kapal bersiap memasuki pelabuhan atau memperlambat kecepatan.
- Fokus: Evaluasi terhadap performa prediksi saat mesin mengalami deselerasi secara terkontrol.
- d. Skenario 4 – Kapal Berlayar Konstan (*Throttle* Stabil di 80%)
- Throttle dipertahankan secara konstan pada 80% (sekitar 2150 RPM) dalam waktu lama, menggambarkan kondisi pelayaran efisien di laut lepas.
- Fokus: Pengujian akurasi dan konsistensi prediksi model dalam kondisi steady-state optimal.
- e. Skenario 5 – Lonjakan Beban Mendadak (Naik ke 90% dalam 1 Siklus)
- Throttle secara tiba-tiba melonjak dari 50% ke 90% (RPM sekitar 2350) akibat kondisi lingkungan seperti arus laut kuat atau kebutuhan akselerasi mendadak.
- Fokus: Uji ketahanan model terhadap perubahan ekstrem dan simulasi prediksi emisi pada tekanan tinggi.
- f. Skenario 6 – Terjadi Manuver Kecepatan Tinggi (Posisi *Throttle* naik-turun 80-100%)
- Throttle mengalami fluktuasi cepat antara 80% hingga 100% dalam waktu singkat, mensimulasikan kondisi manuver kecepatan tinggi seperti saat menghindari objek di laut, melakukan belokan tajam, atau skenario patroli dengan respon cepat. RPM diperkirakan berada di atas 2400 dan mengalami perubahan dinamis secara berulang.
- Fokus: Uji responsivitas sistem terhadap perubahan throttle yang berulang-ulang, validasi kestabilan prediksi rasio hidrogen dan emisi selama manuver ekstrem.

### 5.3. Hasil Simulasi

Simulasi yang dikembangkan menggunakan antarmuka grafis (GUI) tidak hanya menjalankan prediksi secara real-time berdasarkan masukan throttle, tetapi juga menampilkan hasil keluaran berupa tren dari parameter performa mesin hybrid. Evaluasi dilakukan berdasarkan interpretasi dari kurva-kurva yang divisualisasikan terhadap waktu.

### 5.3.1. Hasil Simulasi Case 1 (Ketika kapal bermanuver (RPM naik-turun))



Gambar 5. 4 Grafik ketika kapal sedang melakukan maneuver (RPM tidak stabil)

Pada Gambar 5.4, enam parameter penting yang menggambarkan karakteristik performa mesin kapal saat mengalami kondisi manuver, di mana terjadi fluktuasi beban dan kecepatan putar mesin. Grafik RPM terhadap waktu menunjukkan pola yang tidak stabil. Ketidakstabilan ini mencerminkan kondisi riil kapal saat bermanuver, di mana sistem propulsi mengalami perubahan beban mendadak akibat pergerakan arah, percepatan, maupun perlambatan kapal.

Ketidakteraturan RPM tersebut berkorelasi erat dengan grafik throttle (%) terhadap waktu, yang menunjukkan perubahan tajam sebagai respons sistem kendali untuk mempertahankan daya dorong yang dibutuhkan selama manuver. *Throttle* mengalami fluktuasi dari nilai terendah hingga puncaknya sebesar 30%, menandakan upaya kompensasi otomatis dari sistem kontrol mesin.

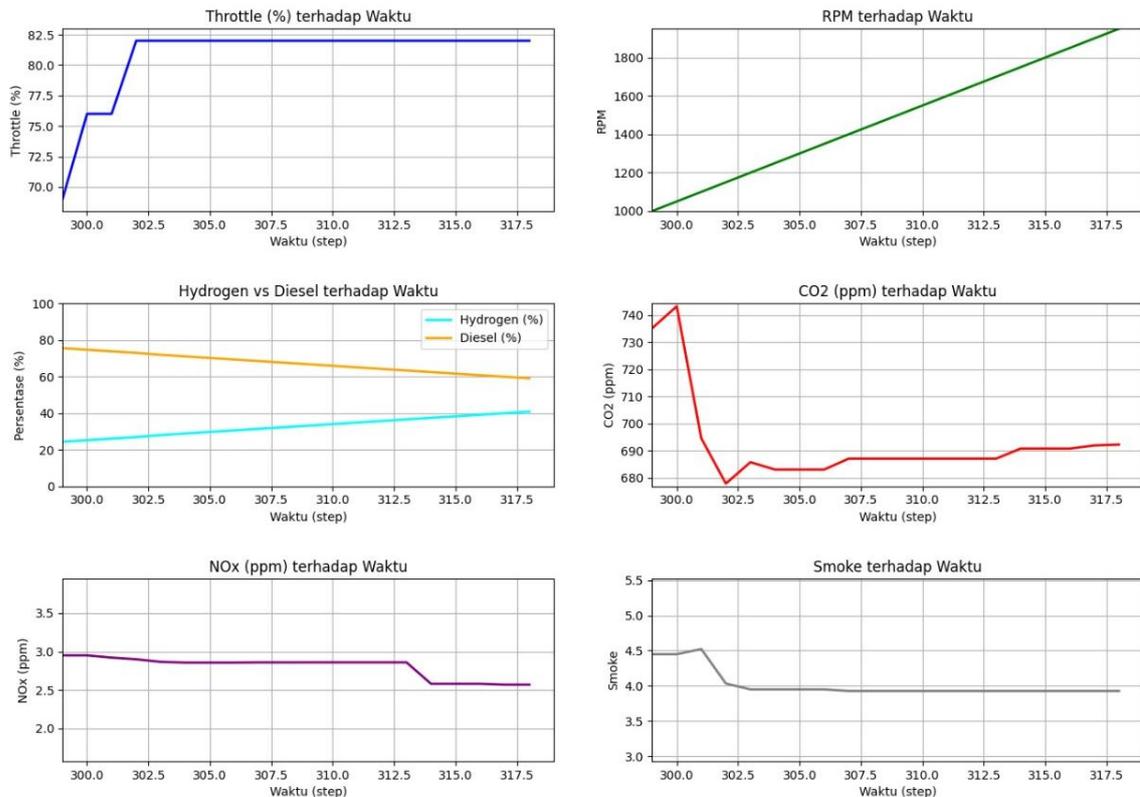
Meskipun terdapat dinamika pada RPM dan *throttle*, grafik rasio campuran hidrogen dan diesel terhadap waktu memperlihatkan bahwa komposisi bahan bakar dijaga tetap konstan, yakni sekitar 18–19% untuk hidrogen dan 81–82% untuk diesel. Dalam konteks ini, tingginya proporsi diesel dibanding hidrogen dipilih untuk menjamin kestabilan pembakaran, mengingat

diesel memiliki karakteristik penyalaan yang lebih stabil terutama saat terjadi fluktuasi beban. Sebaliknya, hidrogen yang memiliki sifat sangat reaktif dan lebih sensitif terhadap variasi kondisi operasi, dijaga pada level yang lebih rendah agar tidak memperparah instabilitas pembakaran.

Dampak dari kondisi manuver ini juga tercermin pada grafik emisi CO<sub>2</sub>, di mana terlihat adanya lonjakan kadar CO<sub>2</sub> hingga 685 ppm pada titik-titik tertentu ketika RPM dan *throttle* meningkat. Hal ini dapat dijelaskan sebagai hasil dari peningkatan laju pembakaran akibat suplai bahan bakar yang lebih tinggi. Sementara itu, kadar NO<sub>x</sub> cenderung stabil pada kisaran 3.4 ppm, dengan sedikit penurunan sesaat yang kemungkinan disebabkan oleh turunnya suhu pembakaran ketika *throttle* menurun.

Adapun grafik smoke (partikulat asap) memperlihatkan fluktuasi cukup signifikan, dengan nilai minimum sekitar 7 dan maksimum mencapai 15. Indeks ini menggambarkan variasi dalam kualitas pembakaran, di mana pada saat *throttle* rendah dan pembakaran tidak sempurna, terjadi peningkatan produksi asap. Sebaliknya, saat *throttle* tinggi, pembakaran cenderung lebih sempurna dan smoke sedikit menurun.

### 5.3.2. Hasil Simulasi Case 2 (Ketika kapal dalam keadaan stabil naik)



Gambar 5. 5 Grafik ketika kapal dalam keadaan stabil naik

Pada Gambar 5.5, performa mesin dan emisi pada kondisi operasi servis speed, yaitu kondisi ketika kapal berada pada kecepatan jelajah konstan dan sistem propulsi berada dalam keadaan stabil. Grafik *Throttle (%)* terhadap Waktu menunjukkan kenaikan konstan. Kenaikan *throttle* di awal ini mencerminkan transisi dari kondisi idle atau kecepatan rendah menuju kecepatan jelajah, yang kemudian dijaga secara stabil.

Sejalan dengan itu, grafik RPM terhadap Waktu memperlihatkan peningkatan bertahap dan konsisten tanpa adanya fluktuasi. Hal ini menunjukkan bahwa sistem mesin merespons *throttle* dengan baik dan mencapai kestabilan rotasi, menandakan efisiensi operasi yang optimal dalam kondisi *servis speed*.

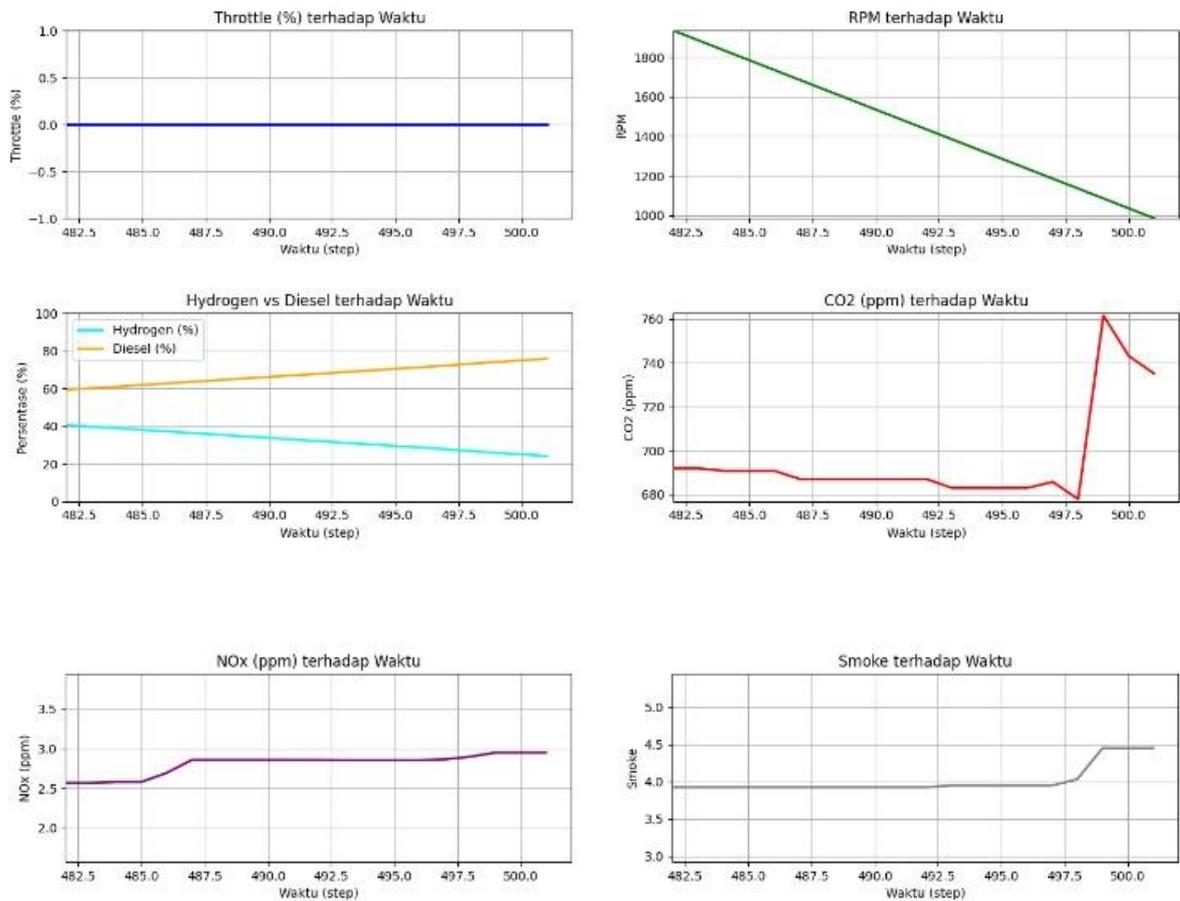
Kondisi ini juga dikaitkan dengan komposisi campuran bahan bakar yang ditampilkan dalam grafik Hydrogen vs Diesel terhadap Waktu. Terlihat bahwa selama periode ini, proporsi hidrogen mengalami peningkatan dari sekitar 30% ke hampir 50%, sedangkan proporsi diesel secara bersamaan menurun dari sekitar 70% ke 55%. Artinya, dalam kondisi stabil, sistem mampu meningkatkan penggunaan hidrogen sebagai bahan bakar alternatif secara progresif, menggantikan sebagian besar porsi diesel tanpa menyebabkan gangguan pada kestabilan sistem.

Perubahan komposisi ini memberikan pengaruh positif terhadap emisi gas buang. Grafik CO<sub>2</sub> (ppm) terhadap Waktu menunjukkan penurunan drastis dari nilai awal sekitar 740 ppm ke angka stabil di kisaran 680–690 ppm. Hal ini menunjukkan bahwa peningkatan porsi hidrogen dalam campuran bahan bakar membantu mengurangi produksi CO<sub>2</sub> karena sifat hidrogen yang tidak menghasilkan emisi karbon selama proses pembakaran.

Selanjutnya, grafik NO<sub>x</sub> (ppm) terhadap Waktu memperlihatkan penurunan bertahap dari sekitar 3.2 ppm menjadi 2.5 ppm. Meskipun hidrogen diketahui dapat meningkatkan temperatur pembakaran yang berpotensi menaikkan NO<sub>x</sub>, pada kondisi servis speed ini justru terjadi penurunan. Hal ini kemungkinan disebabkan oleh rasio campuran udara-bahan bakar yang lebih optimal serta kestabilan operasi mesin yang mengurangi terjadinya pembakaran tidak sempurna pada suhu tinggi.

Pada grafik Smoke terhadap Waktu, terlihat tren penurunan dari 4.5 ke sekitar 3.5. Nilai ini menunjukkan bahwa penggunaan hidrogen yang semakin dominan membantu mengurangi partikel-partikel karbon yang tidak terbakar (asap), mengingat hidrogen terbakar lebih bersih dibandingkan diesel.

### 5.3.3. Hasil Simulasi Case 3 (Ketika kapal dalam keadaan stabil turun)



Gambar 5. 6 Grafik kondisi mesin kapal dalam keadaan turun stabil

Pada Gambar 5.6, performa mesin dan karakteristik emisi selama fase perlambatan kapal. Grafik *Throttle* (%) terhadap Waktu menunjukkan nilai konstan di angka 0%, yang menandakan bahwa suplai tenaga dari pengemudi telah dihentikan, dan sistem hanya mengandalkan inersia serta sisa energi kinetik mesin untuk menurunkan kecepatan kapal secara alami.

Sebagai respons, grafik RPM terhadap Waktu menunjukkan tren penurunan linear. Hal ini menggambarkan perlambatan yang terkendali dan konsisten, yang lazim terjadi saat kapal mengurangi kecepatan menuju titik berhenti.

Dalam kondisi ini, komposisi bahan bakar mengalami perubahan bertahap, sebagaimana ditunjukkan pada grafik Hydrogen vs Diesel terhadap Waktu. Proporsi hidrogen menunjukkan tren menurun dari sekitar 38% menuju 28%, sedangkan proporsi diesel meningkat dari sekitar 62% ke lebih dari 70%. Perubahan ini bersifat logis, karena pada beban rendah dan RPM turun, sistem cenderung meningkatkan penggunaan diesel yang lebih stabil

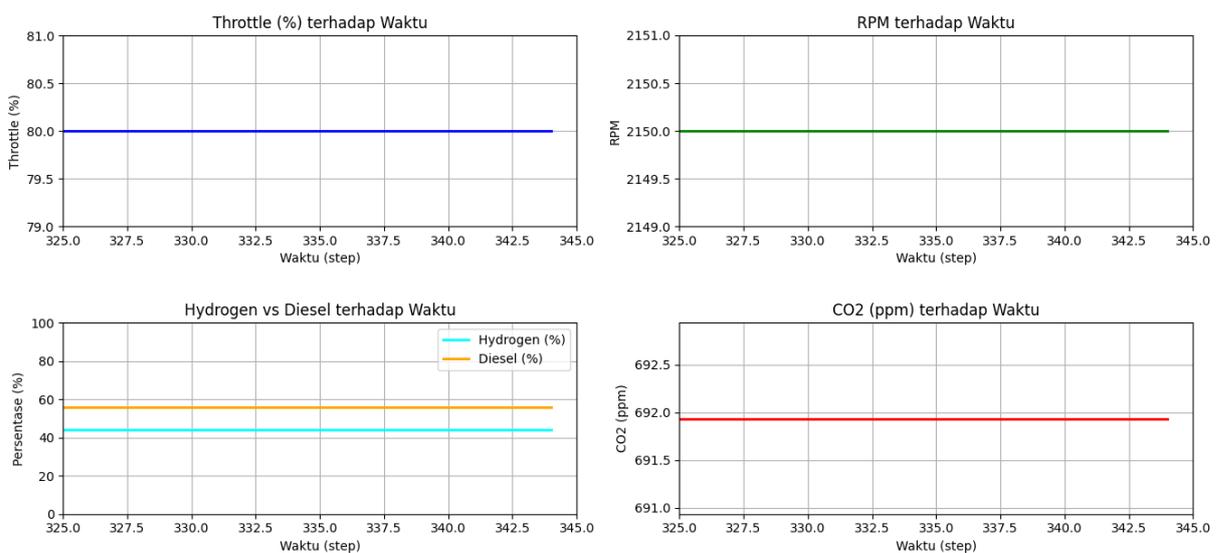
untuk menjaga kontinuitas pembakaran, sementara hydrogen yang lebih reaktif dan sensitif terhadap variasi dikurangi untuk menghindari ketidakseimbangan pembakaran.

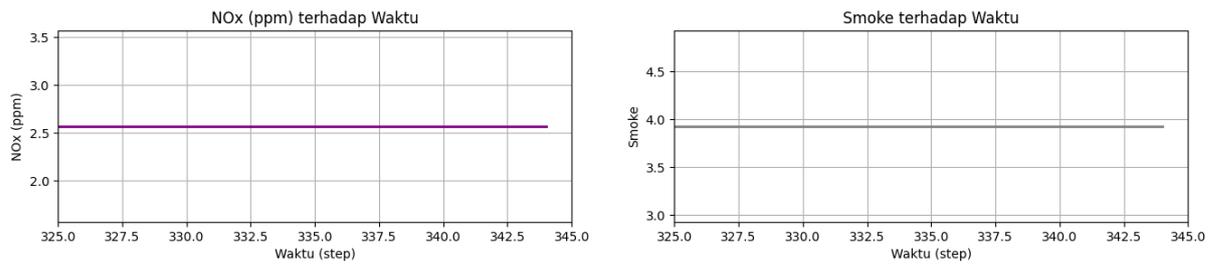
Perubahan ini berdampak pada emisi gas buang, sebagaimana ditunjukkan pada grafik CO<sub>2</sub> (ppm) terhadap Waktu). Meskipun kadar CO<sub>2</sub> relatif stabil di angka sekitar 680–690 ppm, pada akhir rentang waktu terjadi lonjakan tajam hingga 755 ppm. Lonjakan ini kemungkinan besar merupakan respons terhadap peralihan mendadak pada sistem pembakaran ketika proporsi hidrogen menurun drastis, atau karena pembakaran tidak sempurna akibat penurunan temperatur ruang bakar.

Sementara itu, grafik NO<sub>x</sub> (ppm) terhadap Waktu menunjukkan peningkatan bertahap dari sekitar 2.4 ppm ke 3.3 ppm. Meskipun penurunan RPM biasanya menurunkan suhu pembakaran, peningkatan proporsi diesel (yang cenderung menghasilkan lebih banyak NO<sub>x</sub>) dapat menjadi penyebab utama kenaikan ini. Selain itu, turbulensi sisa selama deselerasi juga dapat menciptakan area pembakaran yang lebih panas secara lokal, meningkatkan pembentukan NO<sub>x</sub>.

Smoke terhadap waktu menunjukkan tren kenaikan dari sekitar 3.8 ke 5.0. Peningkatan ini menunjukkan bahwa selama proses perlambatan, kualitas pembakaran menurun, terutama saat proporsi hidrogen ditekan dan diesel menjadi dominan. Pembakaran diesel dalam kondisi suhu ruang bakar yang menurun dan kecepatan rendah cenderung menghasilkan partikel asap lebih banyak karena *incomplete combustion*.

#### 5.3.4. Hasil Simulasi Case 4 (Ketika kapal dalam keadaan *service speed*)





Gambar 5. 7 Grafik kondisi mesin kapal dalam keadaan stabil

Pada Gambar 5.7, memperlihatkan enam parameter kunci yang merepresentasikan kondisi kerja mesin kapal *hybrid hydrogen-diesel* saat beroperasi dalam mode *steady-state* dengan throttle konstan pada 80 persen, yang ekuivalen dengan 2150 RPM. Kondisi ini menggambarkan situasi di mana kapal sedang berada dalam pelayaran stabil dengan kecepatan jelajah.

Grafik *throttle* (%) terhadap waktu dan RPM terhadap waktu menunjukkan garis lurus yang sangat stabil, mengindikasikan bahwa tidak terjadi fluktuasi dalam input mesin maupun output putaran poros. Hal ini menunjukkan bahwa sistem kontrol bahan bakar berhasil menjaga kestabilan suplai energi secara konsisten sesuai kebutuhan operasi pelayaran jangka panjang.

Selanjutnya, grafik komposisi hydrogen vs diesel terhadap waktu menunjukkan bahwa proporsi bahan bakar juga dijaga tetap konstan sepanjang waktu, yakni sekitar 45 persen untuk hidrogen dan 55 persen untuk diesel. Rasio ini dipilih untuk menciptakan keseimbangan antara efisiensi termal dan kestabilan pembakaran. Penggunaan hidrogen dalam proporsi cukup tinggi pada kondisi *steady-state* dimungkinkan karena sistem mesin tidak mengalami gangguan beban mendadak, sehingga risiko ketidakstabilan pembakaran relatif rendah.

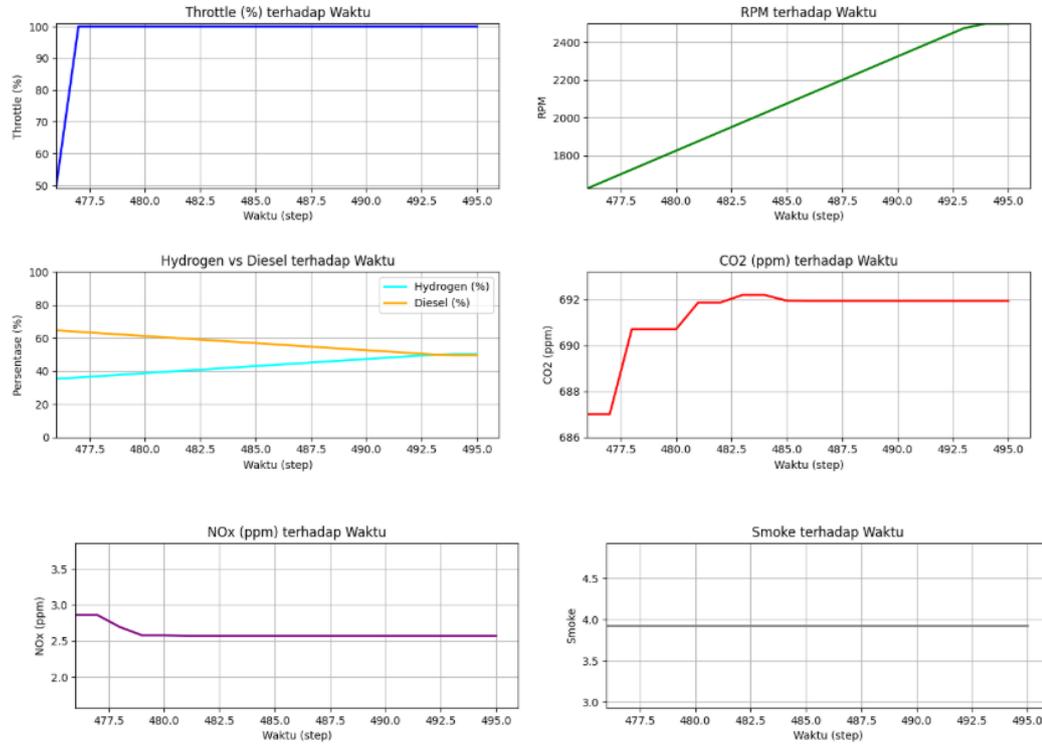
Grafik CO<sub>2</sub> terhadap waktu memperlihatkan emisi karbon dioksida yang stabil di angka 692 ppm, menandakan bahwa pembakaran berjalan secara efisien dan tidak terdapat lonjakan konsumsi bahan bakar yang berlebihan. Begitu juga grafik NOx terhadap waktu yang memperlihatkan nilai tetap pada kisaran 2,6 ppm, mencerminkan suhu pembakaran yang terkontrol dan tidak terjadi kenaikan drastis dalam temperatur ruang bakar.

Terakhir, grafik smoke terhadap waktu memperlihatkan nilai tetap di sekitar 4, menandakan bahwa proses pembakaran berlangsung mendekati kondisi ideal, dengan sedikit sisa partikulat yang terbentuk. Stabilitas pada parameter *smoke* ini memperkuat indikasi bahwa kondisi operasi kapal berada dalam efisiensi pembakaran optimal dengan kombinasi bahan bakar hydrogen-diesel yang seimbang.

Secara keseluruhan, grafik ini menunjukkan bahwa pada kondisi *steady-state* dengan throttle tinggi dan stabil, sistem *hybrid hydrogen-diesel* mampu menghasilkan efisiensi yang

konsisten, emisi yang terkendali, serta pembakaran yang bersih, menjadikan konfigurasi ini ideal untuk operasi jelajah jarak jauh yang membutuhkan performa stabil dan emisi rendah.

### 5.3.5. Hasil Simulasi Case 5 (Ketika kapal dalam keadaan Lonjakan Mendadak)



Gambar 5. 8 Grafik kondisi mesin kapal dalam keadaan Lonjakan Beban Mendadak

Pada Gambar 5.8, respons sistem mesin hybrid hydrogen-diesel saat kapal mengalami lonjakan beban mendadak. Situasi ini menggambarkan kondisi ketika kapal tiba-tiba membutuhkan peningkatan daya dorong secara signifikan, misalnya saat menghadapi arus laut kuat atau melakukan akselerasi cepat untuk menghindari rintangan.

Grafik throttle (%) terhadap waktu menunjukkan peningkatan tajam dari sekitar 50 persen ke 100 persen hanya dalam waktu kurang dari dua step waktu. Peningkatan throttle ini secara langsung berpengaruh pada grafik RPM terhadap waktu yang juga menunjukkan akselerasi cepat dari sekitar 1600 RPM ke atas 2400 RPM. Kenaikan ini mencerminkan respons cepat dari sistem propulsi dalam menghadapi permintaan daya tinggi.

Seiring dengan lonjakan beban, sistem kontrol bahan bakar secara adaptif mengubah komposisi campuran. Grafik hydrogen vs diesel menunjukkan tren yang menarik, di mana persentase hydrogen meningkat dari sekitar 38 persen menuju 50 persen, sedangkan diesel mengalami penurunan dari sekitar 62 persen menjadi seimbang 50 persen. Penyesuaian ini bertujuan untuk memberikan lebih banyak energi dari hidrogen yang memiliki nilai kalor tinggi

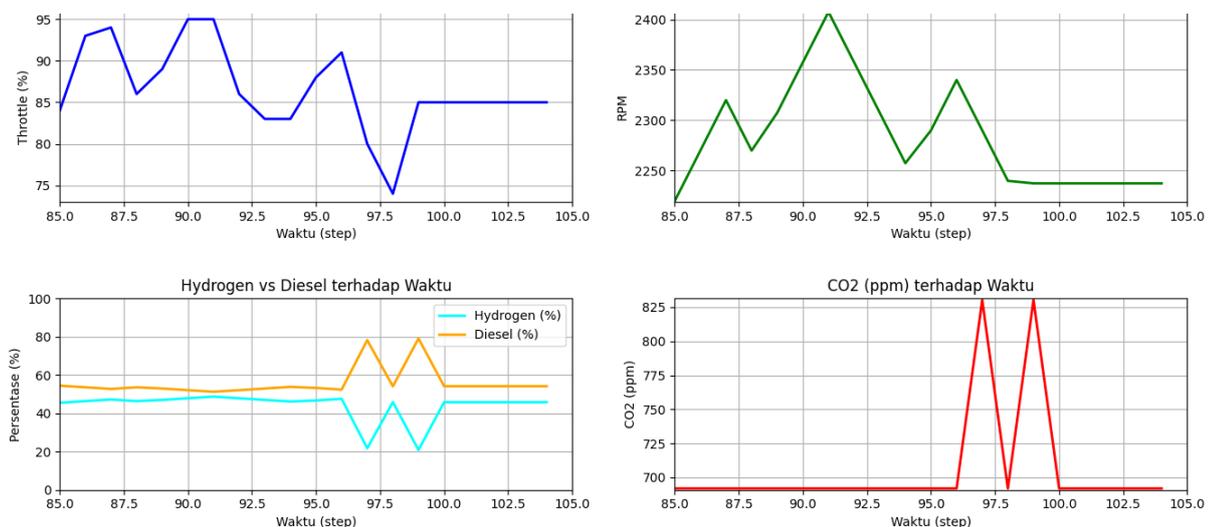
dan respon pembakaran yang cepat, sehingga mesin dapat menghasilkan daya tambahan dengan efisiensi yang lebih baik.

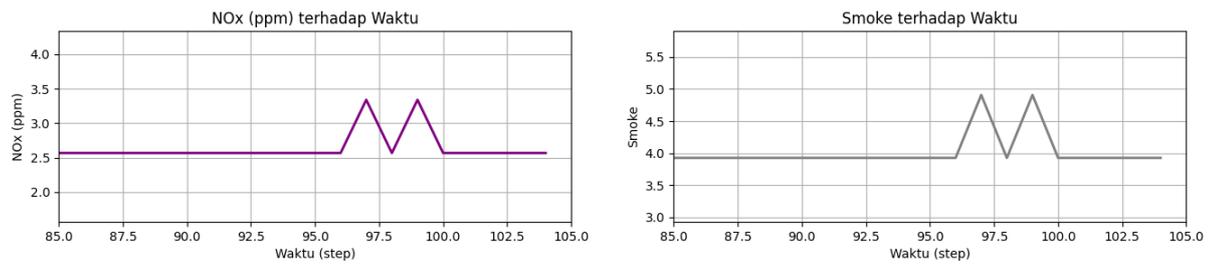
Pada grafik CO<sub>2</sub> terhadap waktu terlihat adanya kenaikan bertahap dari 686 ppm menjadi 692 ppm. Hal ini menunjukkan peningkatan laju pembakaran akibat penambahan suplai bahan bakar, terutama dari sisi hidrogen. Meskipun nilai CO<sub>2</sub> meningkat, tetap berada dalam batas yang relatif stabil, yang menunjukkan bahwa pembakaran masih berlangsung secara efisien.

Sebaliknya, grafik NO<sub>x</sub> menunjukkan penurunan dari sekitar 3 ppm menjadi 2,6 ppm. Hal ini dapat diinterpretasikan sebagai hasil dari penggunaan hidrogen yang lebih tinggi, karena pembakaran hidrogen yang bersih cenderung menghasilkan lebih sedikit emisi NO<sub>x</sub> dibandingkan diesel, meskipun pada suhu tinggi. Grafik smoke juga menunjukkan kondisi yang relatif stabil, dengan nilai sekitar 4, menandakan bahwa meskipun beban meningkat, kualitas pembakaran tetap terjaga tanpa peningkatan signifikan pada emisi partikulat.

Secara keseluruhan, grafik ini memperlihatkan bahwa sistem mesin hybrid mampu merespons lonjakan beban secara cepat dan adaptif dengan meningkatkan suplai hidrogen dan mempertahankan stabilitas emisi. Ini menunjukkan bahwa integrasi sistem kontrol otomatis pada mesin hybrid memberikan keuntungan signifikan dalam menghadapi perubahan kondisi operasi yang ekstrem di lapangan.

### 5.3.6. Hasil Simulasi Case 6 (Ketika kapal dalam keadaan Manuver Ekstrem)





Gambar 5. 9 Grafik kondisi mesin kapal dalam keadaan Manuver Ekstrem

Pada Gambar 5.9, ditampilkan respons sistem mesin hybrid hydrogen-diesel ketika kapal mengalami manuver kecepatan tinggi, ditandai dengan fluktuasi throttle antara 80% hingga 100% dalam beberapa step waktu. Kondisi ini mencerminkan skenario operasional di mana kapal harus bermanuver dengan cepat, seperti saat menghindari tabrakan, melakukan perubahan arah mendadak, atau beroperasi di kondisi perairan sempit dan berbahaya.

Grafik *Throttle* (%) terhadap waktu menunjukkan fluktuasi signifikan dan berulang antara nilai tinggi, khususnya di rentang 85% hingga hampir 100%. Fluktuasi ini diikuti oleh RPM yang juga berubah-ubah dengan cepat, berkisar antara 2250 hingga lebih dari 2400 RPM, menandakan bahwa sistem propulsi berusaha mengikuti permintaan daya dorong secara dinamis.

Grafik Hydrogen vs Diesel terhadap waktu menunjukkan pola invers di mana saat *throttle* tidak stabil dan tinggi, rasio hidrogen justru menurun drastis hingga di bawah 30%, sementara penggunaan diesel meningkat secara signifikan. Ini merupakan mekanisme protektif dari sistem kontrol mesin yang dirancang untuk mengurangi penggunaan hidrogen dalam kondisi tidak stabil demi menghindari risiko seperti misfire atau knocking akibat sifat pembakaran hidrogen yang sangat cepat.

Konsekuensi dari penurunan hidrogen ini terlihat pada grafik emisi CO<sub>2</sub>, NO<sub>x</sub>, dan smoke:

- Emisi CO<sub>2</sub> meningkat tajam dari kondisi normal sekitar 690 ppm hingga menyentuh puncak di atas 820 ppm. Kenaikan ini merupakan indikasi bahwa sistem bergeser ke penggunaan bahan bakar fosil (diesel) yang menghasilkan lebih banyak karbon dioksida saat dibakar.
- Emisi NO<sub>x</sub> juga mengalami lonjakan, dari sekitar 2.6 ppm menjadi lebih dari 3.2 ppm. Hal ini konsisten dengan peningkatan temperatur pembakaran dan karakteristik emisi dari diesel saat dominan.

- Grafik smoke menunjukkan peningkatan moderat, mengindikasikan terjadinya pembakaran yang lebih kotor dibanding saat dominan hidrogen, meskipun masih dalam batas yang dapat diterima.

Secara keseluruhan, Gambar 5.9 memperlihatkan bahwa sistem hybrid memiliki respons adaptif terhadap kondisi ekstrem. Dalam kondisi throttle tinggi dan fluktuatif, sistem secara otomatis menurunkan suplai hidrogen untuk menjaga kestabilan operasi dan menghindari risiko pembakaran tidak sempurna. Sebagai gantinya, sistem mengandalkan diesel yang lebih stabil, meskipun dengan kompromi berupa peningkatan emisi.

#### 5.4. Rasio Hidrogen Optimal dalam Simulasi

Berdasarkan enam skenario simulasi yang telah dianalisis, dapat disimpulkan bahwa rasio optimal penggunaan hidrogen pada sistem mesin hybrid hydrogen-diesel sangat bergantung pada kondisi operasional kapal. Sistem kontrol bahan bakar cerdas berperan penting dalam mengatur komposisi hidrogen dan diesel untuk menjaga efisiensi pembakaran, kestabilan mesin, dan emisi gas buang pada tingkat yang aman dan terkendali.

Tabel 5.1 merangkum perbandingan rasio hidrogen, performa sistem, dan karakteristik emisi pada setiap kondisi operasional yang diuji.

Tabel 5. 1 Rasio Hidrogen dan Diesel terhadap Kondisi Operasi

| Kasus | Kondisi Operasional             | Rasio Hidrogen (%) | Rasio Diesel (%) | Keterangan   |
|-------|---------------------------------|--------------------|------------------|--|
| 1     | Manuver Ringan (RPM fluktuatif) | 18-19              | 81-82            | Hidrogen rendah untuk menjaga kestabilan pembakaran saat beban tidak stabil. |
| 2     | Naik Stabil                     | 30-50              | 70-55            | Hidrogen meningkat secara bertahap untuk efisiensi tanpa ganggu kestabilan.  |
| 3     | Turun Stabil                    | 28-38              | 62-72            | Hidrogen dikurangi saat RPM turun, fokus ke kestabilan menggunakan diesel.   |
| 4     | Service Speed Stabil            | 45                 | 55               | Komposisi tetap, efisiensi optimal & emisi rendah. Cocok untuk jelajah jauh. |

| Kasus | Kondisi Operasional                        | Rasio Hidrogen (%) | Rasio Diesel (%) | Keterangan   |
|-------|--|--------------------|------------------|--|
| 5     | Lonjakan Beban Mendadak                    | 30-50              | 62-50            | Hidrogen dinaikkan untuk daya ekstra saat akselerasi cepat.                  |
| 6     | Manuver Ekstrem ( <i>Throttle</i> 80–100%) | <30                | >70              | Rasio diesel meningkat untuk menjaga kestabilan pembakaran, emisi meningkat. |

Berdasarkan hasil simulasi, rasio hidrogen optimal dalam mesin hybrid hydrogen-diesel sangat bergantung pada kondisi operasional kapal. Pada kondisi stabil seperti pada kasus 4 dan sebagian kasus 2, rasio hidrogen di kisaran 45–50% terbukti memberikan efisiensi termal tinggi dan emisi rendah. Sebaliknya, pada kondisi perlambatan (kasus 3) dan manuver ringan (kasus 1), rasio hidrogen diturunkan untuk menjaga kestabilan pembakaran di RPM rendah.

Pada kondisi akselerasi mendadak (kasus 5), rasio hidrogen ditingkatkan untuk meningkatkan daya dorong secara cepat dan efisien. Sementara itu, pada manuver ekstrem (kasus 6), rasio diesel meningkat untuk menjaga kestabilan pembakaran, namun diikuti oleh peningkatan emisi CO<sub>2</sub>, NO<sub>x</sub>, dan partikulat.

Dengan demikian, rasio hidrogen optimal bersifat adaptif. Rentang 45–50% cocok untuk operasi stabil dan efisien, sedangkan rasio di bawah 30% lebih aman untuk kondisi ekstrem dan tidak stabil.

Halaman ini sengaja dikosongkan

## **BAB 6**

### **KESIMPULAN DAN SARAN**

#### **6.1. Kesimpulan**

Berdasarkan hasil pengujian dan simulasi yang telah dilakukan, diperoleh beberapa poin penting sebagai berikut:

1. Model *Machine Learning* untuk Penentuan Komposisi Optimal Hidrogen-Diesel Berdasarkan RPM

Penelitian ini berhasil membangun model prediktif berbasis *Machine Learning* yang mampu menentukan komposisi campuran bahan bakar hidrogen-diesel secara otomatis berdasarkan input putaran mesin (RPM). Model menggunakan fitur input seperti *engine speed* (RPM), serta menghasilkan enam variabel output, termasuk *hydrogen ratio*, *brake thermal efficiency*, *brake power*, *emission CO<sub>2</sub>*, *emission NO<sub>x</sub>*, dan *smoke*.

Melalui proses augmentasi data dan pelatihan bertahap, model mampu mengenali pola bahwa kenaikan RPM menyebabkan peningkatan kebutuhan hidrogen, namun juga mempengaruhi tingkat emisi dan efisiensi pembakaran. Model secara konsisten memprediksi rasio hidrogen dalam rentang optimal 20%–50%, yang terbukti dapat menurunkan emisi CO<sub>2</sub> secara signifikan tanpa mengorbankan *brake power* maupun efisiensi termal.

2. Model *Machine Learning* Paling Efektif dan Akurat

Dari keempat model yang diuji (*XGBoost*, *Random Forest Regressor*, *Multi-Layer Perceptron*, dan *Deep Neural Network*), model *XGBoost* terbukti paling akurat dan efisien. Hasil evaluasi performa menunjukkan bahwa *XGBoost* menghasilkan:

- a. Rata-rata  $R^2$  (Koefisien Determinasi): 0.9538
- b. *Mean Absolute Error* (MAE): 2.7743
- c. Waktu komputasi pelatihan: 0.39 detik
- d. *Hold-out validation* MAE: 0.0130 dan 0.0014

Parameter evaluasi ini menunjukkan bahwa *XGBoost* tidak hanya cepat dan akurat, tetapi juga stabil saat diuji pada data yang belum pernah dilihat sebelumnya. Model ini mampu secara efektif menghubungkan variabel RPM terhadap rasio hidrogen dan parameter performa mesin lainnya, menjadikannya model paling unggul untuk skenario ini.

### 3. Kemampuan Adaptasi Model terhadap Data RPM dari Simulasi Pelayaran

Model XGBoost yang dikembangkan mampu menyesuaikan prediksi rasio bahan bakar dan emisi secara adaptif terhadap perubahan RPM dan kondisi pelayaran. Pada kasus pelayaran stabil (kasus 2 dan 4), peningkatan RPM diiringi oleh kenaikan rasio hidrogen hingga 45–50%, yang menurunkan emisi CO<sub>2</sub>, NO<sub>x</sub>, dan smoke secara konsisten. Hal ini menunjukkan efisiensi tinggi dan pembakaran bersih pada kondisi steady-state.

Sebaliknya, saat manuver ringan dan ekstrem (kasus 1 dan 6), RPM dan throttle berfluktuasi tajam. Model secara otomatis menurunkan rasio hidrogen hingga di bawah 30% dan meningkatkan diesel untuk menjaga kestabilan pembakaran. Dampaknya, emisi CO<sub>2</sub>, NO<sub>x</sub>, dan smoke meningkat, terutama saat throttle tinggi dan tidak stabil.

Pada lonjakan beban mendadak (kasus 5), hidrogen ditingkatkan sebagai booster untuk mendongkrak tenaga dengan cepat. Emisi tetap terkendali meskipun daya dorong meningkat tajam.

Secara keseluruhan, model menunjukkan respons adaptif yang realistis: hidrogen digunakan maksimal pada kondisi stabil, namun dikurangi saat sistem berada dalam kondisi tidak stabil. Model ini terbukti efektif dalam menjaga efisiensi dan kestabilan performa mesin hybrid hydrogen-diesel di berbagai kondisi pelayaran.

## 6.2. Saran

Berdasarkan hasil penelitian dan pengembangan simulasi sistem pembakaran hybrid hydrogen–diesel menggunakan pendekatan *Machine Learning*, berikut beberapa saran yang dapat dipertimbangkan untuk pengembangan lebih lanjut:

#### 1. Implementasi pada Sistem Fisik Nyata

Penelitian ini masih berbasis simulasi. Oleh karena itu, sangat disarankan agar model yang telah dikembangkan diuji lebih lanjut pada mesin atau sistem nyata (*testbed engine*) untuk memverifikasi akurasi model dalam kondisi operasional sebenarnya.

#### 2. Integrasi dengan Sensor *Real-Time* dan ECU

Model prediktif berbasis AI memiliki potensi besar jika diintegrasikan langsung dengan sistem kendali mesin (ECU) dan sensor *real-time*. Pengembangan sistem kontrol berbasis prediksi akan memungkinkan penyesuaian otomatis komposisi bahan bakar berdasarkan beban dan kondisi lingkungan.

#### 3. Pengembangan Model Adaptif dan Reinforcement Learning

Untuk meningkatkan kemampuan adaptasi terhadap perubahan kondisi operasional ekstrem, ke depan disarankan untuk mengeksplorasi pendekatan seperti *Reinforcement*

*Learning* atau *Adaptive Neural Networks*, yang dapat belajar dan memperbarui diri dari data baru secara kontinu.

4. Ekspansi Variabel Input

Penambahan variabel input seperti temperatur *intake*, tekanan *boost*, suhu gas buang, dan *load* mesin akan membantu model mengenali konteks yang lebih kompleks dan memperkuat prediksi terutama dalam variasi beban tinggi.

5. Studi Ekonomi dan Kelayakan Teknis

Selain sisi teknis, analisis keekonomian dan *feasibility* dari implementasi bahan bakar hidrogen pada kapal perlu dikaji. Aspek seperti biaya penyimpanan hidrogen, ketersediaan infrastruktur, dan regulasi perlu dimasukkan dalam pengembangan sistem skala industri.

6. Visualisasi dan Antarmuka Lebih Interaktif

Simulasi GUI yang telah dibuat dapat terus dikembangkan menjadi aplikasi edukatif atau prototipe software untuk pelatihan operator kapal, dengan visualisasi prediktif yang lebih informatif, termasuk alarm risiko emisi atau *knocking*.

Halaman ini sengaja dikosongkan

## DAFTAR PUSTAKA

- A. Onorati, R. Payri, B.M. Vaglieco, A.K. Agarwal, C. Bae, G. Bruneaux, M. Canakci, M. Gavaises, M. Günthner, C. Hasse, S. Kokjohn, S-C. Kong, Y. Moriyoshi, R. Novella, A. Pesyridis, R. Reitz, T. Ryan, R. Wagner, H. Zhao. (2020). The role of hydrogen for future internal combustion engines.
- Ali, O., Jamil, M., Khan, W.A. & Raza, S., *Machine Learning for Internal Combustion Engine Optimization with Hydrogen-Blended Fuels: A Literature Review*, *Energies*, vol. 18, no. 6, p. 1391, 2023. Tersedia di: <https://www.mdpi.com/1996-1073/18/6/1391> [Diakses 2 Jul 2025].
- Behdad Shadidi, Gholamhassan Najafi, Talal Yusaf. (2021). A Review of Hydrogen as a Fuel in Internal Combustion Engines.
- Benesty, J., Chen, J., Huang, Y., & Cohen, I. (2009). Pearson correlation coefficient. *Noise Reduction in Speech Processing*, 1–4. Springer. [https://doi.org/10.1007/978-3-642-00296-0\\_5](https://doi.org/10.1007/978-3-642-00296-0_5)
- Changwei Ji, Shuofeng Wang. (2022). Experimental study on combustion and emissions performance of a hybrid hydrogen–gasoline engine at lean burn limits.
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623. <https://doi.org/10.7717/peerj-cs.623>
- Diamantopoulou, M. J. (2022). Simulation of over-bark tree bole diameters, through the RFR (Random Forest Regression) algorithm. *Folia Oecologica*, 49(2), 93–101.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Gritsenko, D., & Peuralahti, Y. (2013). Governing shipping externalities: Baltic ports in the process of SOx emission reduction. *Maritime Studies*, 12, 10.
- Hastie, T., Tibshirani, R., & Friedman, J. (2017). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer.

- Ibrahim S. Seddiek, Mohamed M. Elgohary, Nader R. Ammar. (2015). The hydrogen-fuelled internal combustion engines for marine applications with a case study.
- Lamas, M. I., Rodriguez, C. G., Rodriguez, J. D., et al. (2013). Internal modifications to reduce pollutant emissions from marine engines: A numerical approach. *International Journal of Naval Architecture and Ocean Engineering*, 5(4), 493-501.
- Natekin, A., & Knoll, A. (2013). Gradient boosting machines, a tutorial. *Frontiers in Neurorobotics*, 7, 21. <https://doi.org/10.3389/fnbot.2013.00021>
- Prasad, A. M., Iverson, L. R., & Liaw, A. (2006). Newer classification and regression techniques: Bagging and random forests for ecological prediction. *Ecosystems*, 9(2), 181–199.
- Rupp, M., Schneider, L. & Pischinger, S., *Hybrid Reinforcement Learning and Model Predictive Control for Adaptive Control of Hydrogen-Diesel Dual-Fuel Combustion*, arXiv preprint arXiv:2504.16875, 2024. Tersedia di: <https://arxiv.org/abs/2504.16875> [Diakses 2 Jul 2025].
- Sarikoc, A., Ergeneman, M., Yilmaz, I. (2021). Combustion and emission characteristics of a hydrogen-diesel dual fuel engine at varying hydrogen ratios. *International Journal of Hydrogen Energy*, 46(12), 8472–8483.
- Seddiek, I. S., Mosleh, M., & Banawan, A. A. (2013). Fuel saving and emissions cut through shore-side power concept for high-speed crafts at the Red Sea in Egypt. *Journal of Marine Science and Application*, 12(4), 463-472.
- Shaimaa Seyam, Ibrahim Dincer, Martin Agelin-Chaab. (2022). An innovative study on a hybridized ship powering system with fuel cells using hydrogen and clean fuel blends.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 60. <https://doi.org/10.1186/s40537-019-0197-0>
- Wen, L., Gao, L., & Li, X. (2021). A new data augmentation method for fault diagnosis based on Gaussian noise and neural networks. *Neurocomputing*, 419, 139–151. <https://doi.org/10.1016/j.neucom.2020.07.105>
- Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79–82. <https://doi.org/10.3354/cr030079>
- Xie, Y., Hussain, A. & Zhang, Y., *Data Augmentation in Predictive Maintenance Applicable to Hydrogen Combustion Engines: A Review*, Artificial Intelligence Review, 2024.

Tersedia di: <https://link.springer.com/article/10.1007/s10462-024-11021-9> [Diakses 2 Jul 2025].

Zhang, Y., Li, C., & Liu, J. (2021). Augmented data modeling using neural networks for performance prediction in complex systems. *Expert Systems with Applications*, 174, 114751. <https://doi.org/10.1016/j.eswa.2021.114751>

Zhao Wang, Yikun Wang, Sheida Afshan, Johanna Hjalmarsson. (2020). A review of metallic tanks for H<sub>2</sub> storage with a view to application in future green shipping.

Halaman ini sengaja dikosongkan

## LAMPIRAN

Lampiran 1 Dataset Kinerja Mesin

Lampiran 2 *Scatter Plot* Masing-Masing Model

Lampiran 3 *Mean Absolute Error* (MAE) Masing-Masing Model

Lampiran 4 Waktu Komputasi Masing-Masing Model

Lampiran 5 Hasil *Hold Out Validation* Masing-Masing Model

# LAMPIRAN 1

## DATASET KINERJA MESIN

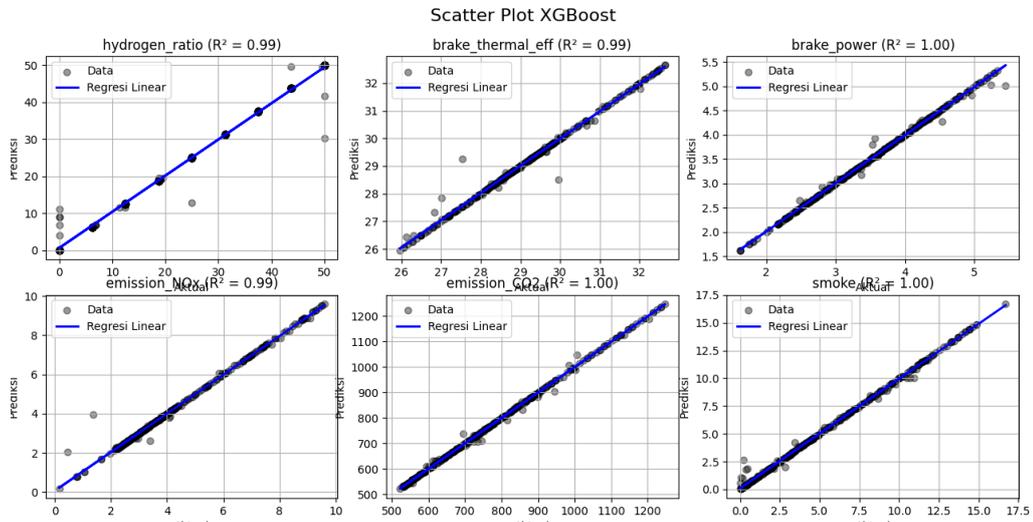
Table 1 Dataset Kinerja Mesin

| Engine speed | Hydrogen ratio | Exhaust temp | Volumetric efficiency | Excess air ratio | Brake thermal eff | bsfc    | Emission CO2 | Emission NOx |
|--------------|----------------|--------------|-----------------------|------------------|-------------------|---------|--------------|--------------|
| 750          | 0              | 270.59       | 71.75                 | 1.168            | 30                | 286.27  | 838.1        | 3.059        |
| 809          | 0              | 193.806      | 83.197                | 1.588            | 29.210            | 295.418 | 777.258      | 2.917        |
| 850          | 0              | 205.854      | 83.023                | 1.595            | 28.841            | 296.586 | 792.223      | 2.820        |
| 891          | 0              | 217.901      | 82.849                | 1.603            | 28.734            | 297.754 | 807.188      | 2.737        |
| 900          | 0              | 274.500      | 75.240                | 1.496            | 28.680            | 305.880 | 842.432      | 2.734        |
| 974          | 0              | 233.886      | 83.186                | 1.591            | 28.627            | 303.730 | 854.170      | 2.731        |
| 1015         | 0              | 246.399      | 83.078                | 1.608            | 28.163            | 303.919 | 865.909      | 2.730        |
| 1056         | 0              | 258.912      | 82.970                | 1.625            | 28.127            | 304.109 | 880.950      | 2.730        |
| 1100         | 0              | 286.270      | 80.950                | 1.550            | 28.091            | 298.040 | 895.240      | 2.619        |
| 1135         | 0              | 286.920      | 81.730                | 1.643            | 28.032            | 304.086 | 898.211      | 2.577        |
| 1179         | 0              | 288.880      | 82.880                | 1.691            | 27.890            | 305.558 | 903.568      | 2.536        |
| 1223         | 0              | 290.840      | 84.030                | 1.739            | 27.532            | 307.029 | 908.924      | 2.494        |
| 1400         | 0              | 333.730      | 82.540                | 1.712            | 27.357            | 305.880 | 919.047      | 2.452        |
| 1488         | 0              | 326.980      | 84.070                | 1.793            | 27.182            | 309.705 | 928.212      | 2.410        |
| 1599         | 0              | 336.864      | 84.618                | 1.835            | 27.007            | 311.568 | 936.903      | 2.368        |
| 1709         | 0              | 346.748      | 85.166                | 1.877            | 26.832            | 313.430 | 945.593      | 2.327        |
| 1750         | 0              | 396.070      | 75.870                | 1.544            | 26.657            | 290.196 | 983.293      | 2.285        |
| 1860         | 0              | 384.044      | 81.887                | 1.794            | 26.482            | 306.000 | 995.031      | 2.243        |
| 1950         | 0              | 396.557      | 81.779                | 1.811            | 26.307            | 306.190 | 1000.000     | 2.201        |
| 2039         | 0              | 409.070      | 81.670                | 1.828            | 26.132            | 306.379 | 1006.770     | 2.160        |
| 2100         | 0              | 450.980      | 70.160                | 1.296            | 25.957            | 358.830 | 1247.620     | 2.118        |
| 750          | 25             | 262.740      | 66.660                | 1.232            | 32.646            | 309.800 | 533.166      | 4.310        |
| 809          | 25             | 183.439      | 88.366                | 1.794            | 32.485            | 499.810 | 538.368      | 3.876        |
| 850          | 25             | 192.605      | 87.865                | 1.782            | 32.293            | 503.345 | 545.798      | 3.861        |
| 891          | 25             | 201.772      | 87.364                | 1.770            | 32.006            | 506.879 | 555.533      | 3.846        |
| 900          | 25             | 262.740      | 75.240                | 1.420            | 31.940            | 317.650 | 558.431      | 3.838        |
| 974          | 25             | 207.154      | 89.268                | 1.830            | 31.711            | 562.139 | 570.319      | 3.820        |
| 1015         | 25             | 217.616      | 88.476                | 1.810            | 31.528            | 560.854 | 572.699      | 3.819        |
| 1056         | 25             | 228.077      | 87.684                | 1.790            | 31.077            | 559.569 | 592.490      | 3.680        |
| 1100         | 25             | 279.590      | 80.950                | 1.504            | 30.659            | 307.840 | 614.662      | 3.623        |
| 1135         | 25             | 235.317      | 88.082                | 1.837            | 30.650            | 640.481 | 629.803      | 3.566        |
| 1179         | 25             | 247.644      | 87.020                | 1.805            | 30.416            | 627.812 | 658.232      | 3.508        |
| 1223         | 25             | 259.971      | 85.958                | 1.772            | 30.183            | 615.144 | 686.662      | 3.451        |
| 1400         | 25             | 286.270      | 82.540                | 1.630            | 29.950            | 313.720 | 695.240      | 3.393        |
| 1488         | 25             | 277.641      | 85.013                | 1.763            | 29.716            | 734.184 | 700.000      | 3.336        |
| 1599         | 25             | 291.465      | 83.699                | 1.718            | 29.483            | 690.578 | 728.570      | 3.278        |
| 1709         | 25             | 305.289      | 82.384                | 1.674            | 29.250            | 646.971 | 730.410      | 3.221        |
| 1750         | 25             | 339.210      | 75.780                | 1.504            | 29.017            | 617.640 | 730.698      | 3.164        |
| 1860         | 25             | 325.816      | 81.981                | 1.628            | 28.783            | 510.974 | 730.986      | 3.106        |
| 1950         | 25             | 330.228      | 82.619                | 1.647            | 28.550            | 526.268 | 752.380      | 3.049        |
| 2039         | 25             | 334.639      | 83.258                | 1.665            | 28.317            | 541.561 | 762.900      | 2.991        |
| 2100         | 25             | 403.920      | 68.570                | 1.264            | 28.083            | 384.313 | 904.760      | 2.934        |
| 750          | 50             | 249.010      | 61.270                | 1.280            | 30.140            | 337.250 | 521.552      | 9.600        |
| 809          | 50             | 191.498      | 72.867                | 1.741            | 30.007            | 246.233 | 533.330      | 8.800        |
| 850          | 50             | 199.631      | 72.770                | 1.730            | 29.816            | 252.013 | 533.330      | 7.363        |
| 891          | 50             | 207.764      | 72.673                | 1.719            | 29.797            | 257.792 | 534.780      | 7.165        |
| 900          | 50             | 254.900      | 68.250                | 1.410            | 29.785            | 337.250 | 548.008      | 6.967        |
| 974          | 50             | 214.279      | 73.561                | 1.771            | 29.563            | 250.933 | 563.583      | 6.062        |
| 1015         | 50             | 223.387      | 73.356                | 1.753            | 29.492            | 258.555 | 577.899      | 5.915        |
| 1056         | 50             | 232.495      | 73.151                | 1.734            | 29.435            | 266.177 | 592.215      | 4.992        |
| 1100         | 50             | 254.900      | 71.430                | 1.504            | 29.344            | 325.500 | 604.760      | 4.387        |
| 1135         | 50             | 246.278      | 73.246                | 1.768            | 28.890            | 264.186 | 645.247      | 3.783        |
| 1179         | 50             | 255.991      | 72.973                | 1.740            | 28.670            | 274.158 | 656.236      | 3.178        |
| 1223         | 50             | 265.703      | 72.699                | 1.712            | 27.964            | 284.130 | 667.225      | 2.867        |
| 1400         | 50             | 278.430      | 75.870                | 1.540            | 27.905            | 333.330 | 675.929      | 2.574        |

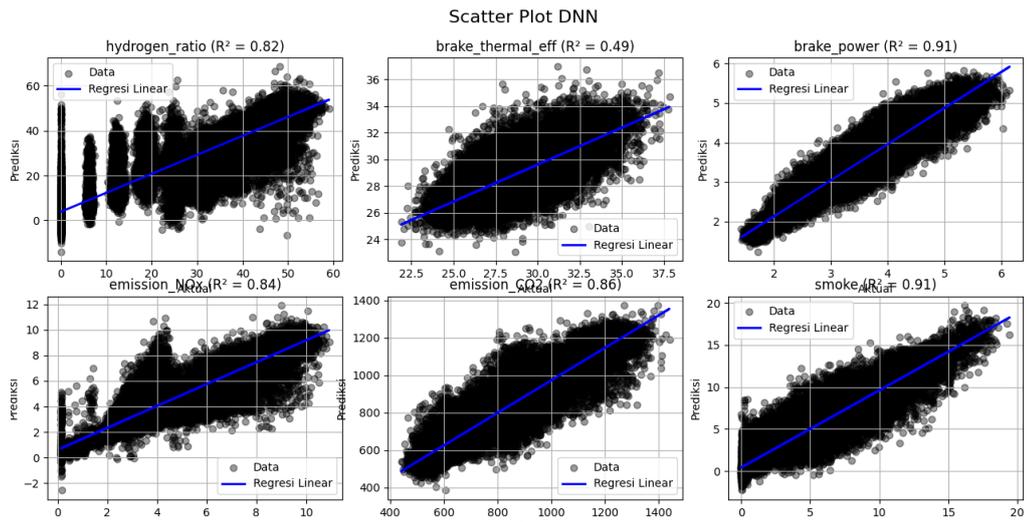
| <b>Engine speed</b> | <b>Hydrogen ratio</b> | <b>Exhaust temp</b> | <b>Volumetric efficiency</b> | <b>Excess air ratio</b> | <b>Brake thermal eff</b> | <b>bsfc</b> | <b>Emission CO2</b> | <b>Emission NOx</b> |
|---------------------|-----------------------|---------------------|------------------------------|-------------------------|--------------------------|-------------|---------------------|---------------------|
| 1488                | 50                    | 283.620             | 70.428                       | 1.728                   | 28.065                   | 284.460     | 689.762             | 2.263               |
| 1599                | 50                    | 293.656             | 70.523                       | 1.685                   | 27.889                   | 298.635     | 703.595             | 1.969               |
| 1709                | 50                    | 303.691             | 70.618                       | 1.641                   | 27.714                   | 312.810     | 704.760             | 1.658               |
| 1750                | 50                    | 330.980             | 66.980                       | 1.504                   | 27.538                   | 345.100     | 723.809             | 1.365               |
| 1860                | 50                    | 315.825             | 73.044                       | 1.578                   | 27.363                   | 338.337     | 728.213             | 1.054               |
| 1950                | 50                    | 320.512             | 73.520                       | 1.592                   | 27.187                   | 338.631     | 740.237             | 0.760               |
| 2039                | 50                    | 325.198             | 73.996                       | 1.607                   | 27.012                   | 338.926     | 752.261             | 0.449               |
| 2100                | 50                    | 376.470             | 66.980                       | 1.272                   | 26.836                   | 415.680     | 780.950             | 0.156               |

## LAMPIRAN 2

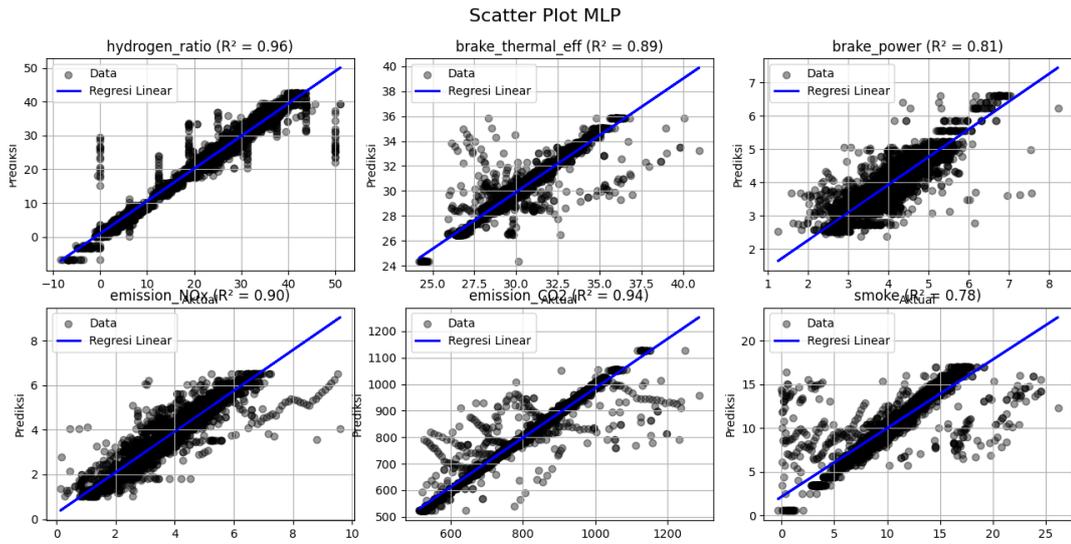
### SCATTER PLOT MASING MASING MODEL



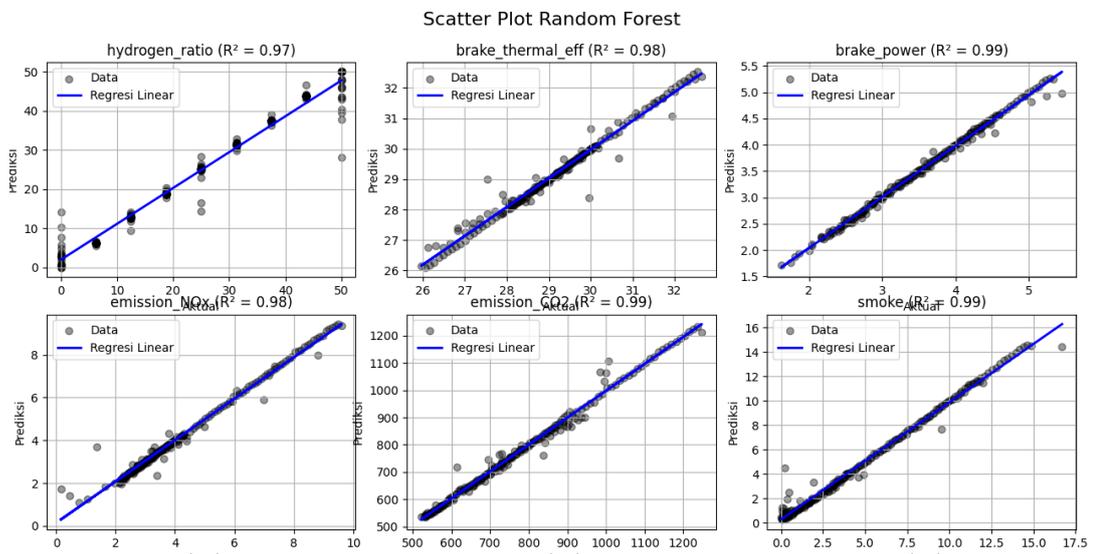
Gambar 1 Scatter Plot XGBoost



Gambar 2 Scatter Plot DNN



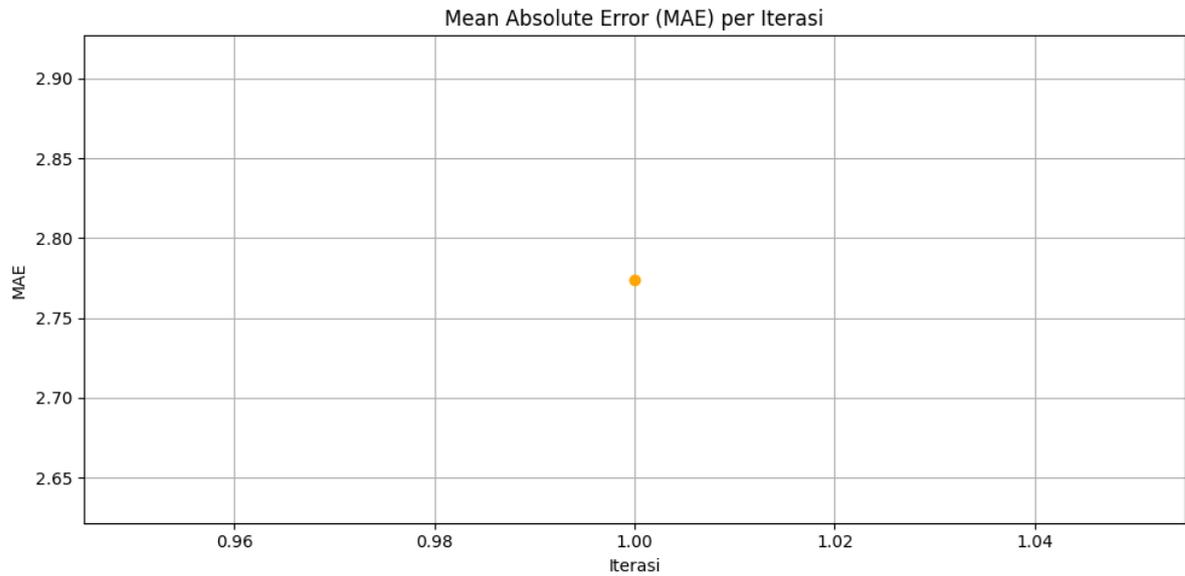
**Gambar 3 Scatter Plot MLP**



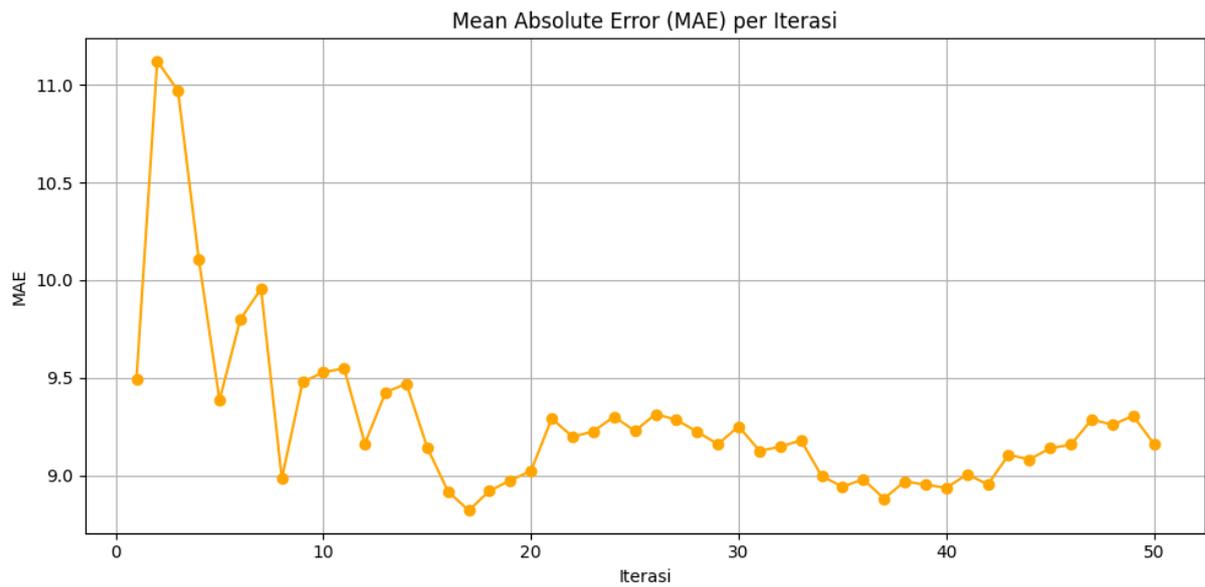
**Gambar 4 Scatter Plot RFR**

### LAMPIRAN 3

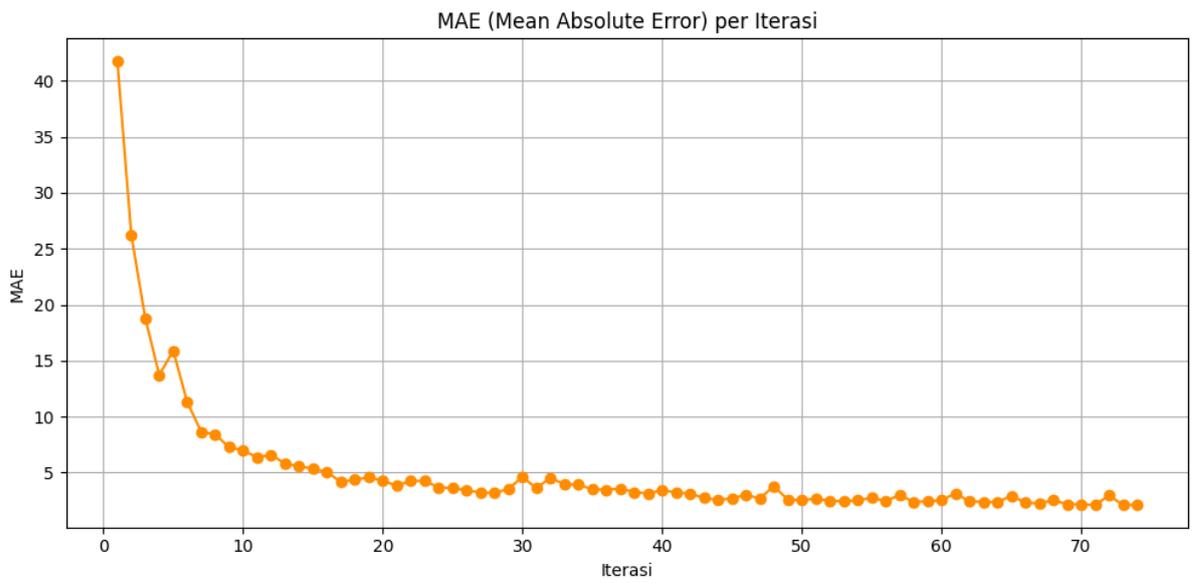
## MEAN ABSOLUTE ERROR (MAE) MASING MASING MODEL



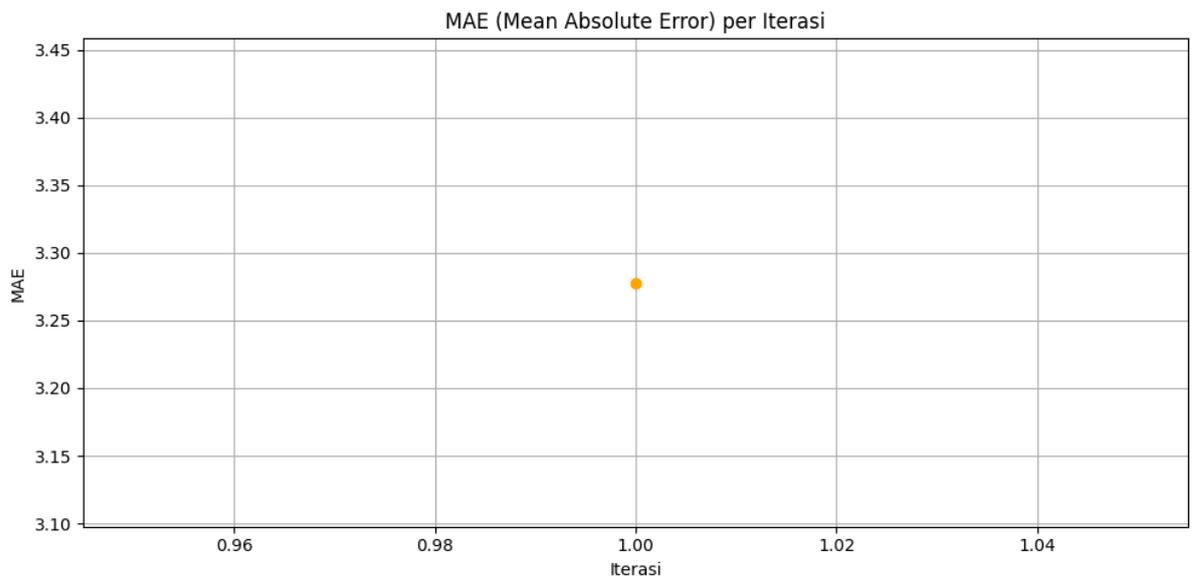
Gambar 5 Waktu Komputasi XGB Regressor



Gambar 6 Waktu Komputasi Deep Neural Network



Gambar 7 Waktu Komputasi Multi Layer Perceptron



Gambar 8 Waktu Komputasi Random Forest Regressor



```
PS C:\Users\Nicholas> & C:/Users/Nicholas/AppData/Local/Programs/Python/Python38-64/Scripts/python.exe op.py"

Iterasi ke-1
R2: 0.9538 | MAE: 2.7743 | Jumlah data: 189

Riwayat Hasil Tiap Iterasi:
Iterasi 1: R2 = 0.9538, MAE = 2.7743, Data = 189

Total Waktu Komputasi: 0.39 detik (0.01 menit)
PS C:\Users\Nicholas>
```

Gambar 11 Waktu Komputasi XGB Regressor

```
Iterasi ke-47
279/279 ██████████ 0s 1ms/step
R2 = 0.8066 | MAE = 9.2861 | Data: 44604 sampel

Iterasi ke-48
285/285 ██████████ 0s 1ms/step
R2 = 0.8127 | MAE = 9.2601 | Data: 45549 sampel

Iterasi ke-49
291/291 ██████████ 0s 932us/step
R2 = 0.8076 | MAE = 9.3049 | Data: 46494 sampel

Iterasi ke-50
297/297 ██████████ 0s 965us/step
R2 = 0.8077 | MAE = 9.1612 | Data: 47439 sampel

Loop Berhenti - Model Mencapai Target
Final R2 Score: 0.8077
Final MAE: 9.1612
Total Waktu Komputasi: 3671.17 detik (61.19 menit)
1483/1483 ██████████ 1s 888us/step
```

Gambar 12 Waktu Komputasi Deep Neural Network

## LAMPIRAN 5

### HASIL HOLD-OUT VALIDATION MASING-MASING MODEL

```
MODE VALIDASI MANUAL - UJI PREDIKSI MODEL BERULANG

Fitur yang tersedia:
1. engine_speed
2. exhaust_temp
3. volumetric_efficiency
4. excess_air_ratio
5. bsfc

Masukkan nama fitur pertama (atau ketik 'exit' untuk keluar): engine_speed
Masukkan nama fitur kedua: bsfc
Masukkan nilai untuk engine_speed: 2100
Masukkan nilai untuk bsfc: 415.680

Baris data ditemukan yang mendekati input.
1/1 ████████████████████ 0s 42ms/step

Perbandingan Prediksi vs Data Aktual:
hydrogen_ratio | Prediksi: 23.8525 | Aktual: 25.0000 | Selisih: 1.1475
brake_thermal_eff | Prediksi: 22.3556 | Aktual: 22.1000 | Selisih: 0.2556
brake_power | Prediksi: 4.6203 | Aktual: 4.5900 | Selisih: 0.0303
emission_NOx | Prediksi: 3.7135 | Aktual: 3.6700 | Selisih: 0.0435
emission_CO2 | Prediksi: 944.2122 | Aktual: 904.7600 | Selisih: 39.4522
smoke | Prediksi: 0.1465 | Aktual: 0.0980 | Selisih: 0.0485

MAE untuk input ini: 6.8296
```

Gambar 13 Hold Out Validation Deep Neural Network 1

```
Fitur yang tersedia:
1. engine_speed
2. exhaust_temp
3. volumetric_efficiency
4. excess_air_ratio
5. bsfc

Masukkan nama fitur pertama (atau ketik 'exit' untuk keluar): bsfc
Masukkan nama fitur kedua: engine_speed
Masukkan nilai untuk bsfc: 325.500
Masukkan nilai untuk engine_speed: 1100

Baris data ditemukan yang mendekati input.
1/1 ████████████████████ 0s 34ms/step

Perbandingan Prediksi vs Data Aktual:
hydrogen_ratio | Prediksi: 52.5676 | Aktual: 50.0000 | Selisih: 2.5676
brake_thermal_eff | Prediksi: 26.6309 | Aktual: 26.3100 | Selisih: 0.3209
brake_power | Prediksi: 2.6466 | Aktual: 2.7800 | Selisih: 0.1334
emission_NOx | Prediksi: 6.2057 | Aktual: 5.7700 | Selisih: 0.4357
emission_CO2 | Prediksi: 562.7606 | Aktual: 533.3300 | Selisih: 29.4306
smoke | Prediksi: 0.6669 | Aktual: 1.0900 | Selisih: 0.4231

MAE untuk input ini: 5.5519
```

Gambar 14 Hold Out Validation Deep Neural Network 2

```

Fitur yang tersedia:
1. engine_speed
2. exhaust_temp
3. volumetric_efficiency
4. excess_air_ratio
5. bsfc

Masukkan nama fitur pertama (atau ketik 'exit' untuk keluar): excess_air_ratio
Masukkan nama fitur kedua: engine_speed
Masukkan nilai untuk excess_air_ratio: 1.540
Masukkan nilai untuk engine_speed: 1400

Input ditemukan dalam dataset asli.

Perbandingan Prediksi vs Data Aktual:
hydrogen_ratio      | Prediksi: 40.7953 | Aktual: 50.0000 | Selisih: 9.2047
brake_thermal_eff   | Prediksi: 18.9074 | Aktual: 25.5300 | Selisih: 6.6226
brake_power          | Prediksi: 19.0937 | Aktual: 3.1000  | Selisih: 15.9937
emission_NOx        | Prediksi: 18.6534 | Aktual: 5.2700  | Selisih: 13.3834
emission_CO2        | Prediksi: 964.2382 | Aktual: 704.7600 | Selisih: 259.4782
smoke                | Prediksi: 10.7685 | Aktual: 0.4300  | Selisih: 10.3385

MAE untuk input ini: 52.5035

```

Gambar 15 Hold Out Validation Multi Layer Perceptron 1

```

MODE VALIDASI MANUAL - UJI PREDIKSI BERULANG

Fitur yang tersedia:
1. engine_speed
2. exhaust_temp
3. volumetric_efficiency
4. excess_air_ratio
5. bsfc

Masukkan nama fitur pertama (atau ketik 'exit' untuk keluar): engine_speed
Masukkan nama fitur kedua: excess_air_ratio
Masukkan nilai untuk engine_speed:
1750
Masukkan nilai untuk excess_air_ratio: 1.504
.7924
brake_thermal_eff   | Prediksi: 17.5850 | Aktual: 29.2100 | Selisih: 11.6250
brake_power          | Prediksi: 18.6553 | Aktual: 4.9600  | Selisih: 13.6953
emission_NOx        | Prediksi: 18.3224 | Aktual: 2.7300  | Selisih: 15.5924
emission_CO2        | Prediksi: 1173.1353 | Aktual: 1000.0000 | Selisih: 173.1353
smoke                | Prediksi: 6.6798  | Aktual: 0.3500  | Selisih: 6.3298

MAE untuk input ini: 38.1950

```

Gambar 16 Hold Out Validation Multi Layer Perceptron 2

```

MODE VALIDASI MANUAL - UJI PREDIKSI MODEL BERULANG

Fitur yang tersedia:
1. engine_speed
2. exhaust_temp
3. volumetric_efficiency
4. excess_air_ratio
5. bsfc

Masukkan nama fitur pertama (atau ketik 'exit' untuk keluar): bsfc
Masukkan nama fitur kedua: engine_speed
Masukkan nilai untuk bsfc: 313.720
Masukkan nilai untuk engine_speed: 1400

Baris data ditemukan yang mendekati input.

Perbandingan Prediksi vs Data Aktual:
hydrogen_ratio      | Prediksi: 24.0900 | Aktual: 25.0000 | Selisih: 0.9100
brake_thermal_eff   | Prediksi: 26.8882 | Aktual: 26.8400 | Selisih: 0.0482
brake_power         | Prediksi: 3.4170  | Aktual: 3.5300  | Selisih: 0.1130
emission_NOx       | Prediksi: 3.6082  | Aktual: 3.6700  | Selisih: 0.0618
emission_CO2       | Prediksi: 721.8037 | Aktual: 695.2400 | Selisih: 26.5637
smoke              | Prediksi: 0.6360  | Aktual: 0.4500  | Selisih: 0.1860

MAE untuk input ini: 4.6471

```

Gambar 17 Hold Out Validation Random Forest Regressor 1

```

Fitur yang tersedia:
1. engine_speed
2. exhaust_temp
3. volumetric_efficiency
4. excess_air_ratio
5. bsfc

Masukkan nama fitur pertama (atau ketik 'exit' untuk keluar): exhaust_temp
Masukkan nama fitur kedua: engine_speed
Masukkan nilai untuk exhaust_temp: 254.9
Masukkan nilai untuk engine_speed: 900

Baris data ditemukan yang mendekati input.

Perbandingan Prediksi vs Data Aktual:
hydrogen_ratio      | Prediksi: 38.0564 | Aktual: 50.0000 | Selisih: 11.9436
brake_thermal_eff   | Prediksi: 24.4959 | Aktual: 25.2600 | Selisih: 0.7641
brake_power         | Prediksi: 2.4246  | Aktual: 2.2700  | Selisih: 0.1546
emission_NOx       | Prediksi: 5.3508  | Aktual: 8.8000  | Selisih: 3.4492
emission_CO2       | Prediksi: 707.7517 | Aktual: 604.7600 | Selisih: 102.9917
smoke              | Prediksi: 5.9346  | Aktual: 3.9300  | Selisih: 2.0046

MAE untuk input ini: 20.2180

```

Gambar 18 Hold Out Validation Random Forest Regressor 2

```
MODE VALIDASI MANUAL - UJI PREDIKSI BERULANG

Fitur yang tersedia:
1. engine_speed
2. exhaust_temp
3. volumetric_efficiency
4. excess_air_ratio
5. bsfc

Masukkan nama fitur pertama (atau ketik 'exit' untuk keluar): bsfc
Masukkan nama fitur kedua: engine_speed
Masukkan nilai untuk bsfc: 337.25
Masukkan nilai untuk engine_speed: 750

Baris data ditemukan yang mendekati input.

Perbandingan Prediksi vs Data Aktual:
hydrogen_ratio | Prediksi: 50.0001 | Aktual: 50.0000 | Selisih: 0.0001
brake_thermal_eff | Prediksi: 17.3884 | Aktual: 17.3860 | Selisih: 0.0024
brake_power | Prediksi: 2.3895 | Aktual: 2.3900 | Selisih: 0.0005
emission_NOx | Prediksi: 9.5983 | Aktual: 9.6000 | Selisih: 0.0017
emission_CO2 | Prediksi: 533.4009 | Aktual: 533.3300 | Selisih: 0.0709
smoke | Prediksi: 11.9975 | Aktual: 12.0000 | Selisih: 0.0025

MAE untuk input ini: 0.0130
```

Gambar 19 Hold Out Validation XGB Regressor 1

```
Fitur yang tersedia:
1. engine_speed
2. exhaust_temp
3. volumetric_efficiency
4. excess_air_ratio
5. bsfc

Masukkan nama fitur pertama (atau ketik 'exit' untuk keluar): bsfc
Masukkan nama fitur kedua: engine_speed
Masukkan nilai untuk bsfc: 307.840
Masukkan nilai untuk engine_speed: 1100

Baris data ditemukan yang mendekati input.

Perbandingan Prediksi vs Data Aktual:
hydrogen_ratio | Prediksi: 24.9998 | Aktual: 25.0000 | Selisih: 0.0002
brake_thermal_eff | Prediksi: 27.6307 | Aktual: 27.6300 | Selisih: 0.0007
brake_power | Prediksi: 2.9495 | Aktual: 2.9500 | Selisih: 0.0005
emission_NOx | Prediksi: 3.7598 | Aktual: 3.7600 | Selisih: 0.0002
emission_CO2 | Prediksi: 700.0062 | Aktual: 700.0000 | Selisih: 0.0062
smoke | Prediksi: 1.1203 | Aktual: 1.1200 | Selisih: 0.0003

MAE untuk input ini: 0.0014
```

Gambar 20 Hold Out Validation XGB Regressor 2

## BIODATA PENULIS



Satria lahir di Surakarta pada tanggal 23 Desember 2003. Penulis merupakan anak pertama dari tiga bersuadara. Pendidikan dasar ditempuh di Santo Yoseph, Ujung Menteng , Jakarta Timur, kemudian melanjutkan ke jenjang menengah di SMPK Penabur Harapan Indah dan SMA Pangudi Luhur Van Lith, Muntilan. Saat ini, penulis sedang menempuh pendidikan tinggi di Departemen Teknik Perkapalan, Fakultas Teknologi Kelautan, Institut Teknologi Sepuluh Nopember (ITS) Surabaya.

Selama masa studi, penulis aktif dalam berbagai kegiatan kemahasiswaan, di antaranya menjabat sebagai Kepala Departemen Hubungan Masyarakat HIMATEKPAL ITS. Penulis juga turut berkontribusi dalam berbagai program strategis, seperti penyelenggaraan *Study Excursion* ke Jakarta dengan kunjungan ke Pertamina International Shipping dan PT Jasa Peralatan Pelabuhan Indonesia, serta menjadi salah satu panitia inti dalam rangkaian acara peringatan 8 Winduan Teknik Perkapalan ITS.

Dalam bidang akademik, penulis mengembangkan penelitian mengenai efisiensi bahan bakar kapal melalui simulasi komposisi hidrogen-diesel dengan metode kecerdasan buatan (AI). Penelitian ini bertujuan untuk mencari konfigurasi optimal bahan bakar guna meningkatkan performa mesin kapal sekaligus mengurangi emisi.

Email: [nicholassatria01@gmail.com](mailto:nicholassatria01@gmail.com)