

PENGGUNAAN MACHINE LEARNING UNTUK MEMPREDIKSI PENYIMPANGAN IMPEDANSI DALAM PROSES PEMBUATAN TRANSFORMATOR DI PT. X

Kelvin Wilson Utomo¹, Julius Sentosa Setiadji², Indar Sugiarto³

^{1,2,3}Program Studi Teknik Elektro, Universitas Kristen Petra

Jl. Siwalankerto 121-131, Surabaya 60236, Indonesia

E-Mail: kelvinutomo2002@gmail.com, julius@petra.ac.id, indi@petra.ac.id

Abstrak – PT. X menghadapi tantangan dalam menjaga mutu dan kualitas produk transformator distribusi tipe oil, khususnya terkait dengan nilai impedansi. Hasil pengujian menunjukkan adanya deviasi positif dan negatif dari nilai garansi yang diperhitungkan selama desain. Nilai impedansi, yang dipengaruhi oleh tahanan resistif dan reaktansi belitan transformator, secara langsung berkaitan dengan dimensi koil transformator. Penelitian ini membuat pemodelan machine learning yang akan digunakan untuk memprediksi nilai impedansi dan hasil prediksi nilai impedansi tersebut dioptimalkan menggunakan metode feature selection dan hyperparameter tuning. Dengan memanfaatkan machine learning, diharapkan proses training data dapat dilakukan lebih cepat dan efisien untuk memprediksi nilai impedansi berdasarkan dimensi koil. Pemodelan machine learning dilakukan menggunakan beberapa algoritma machine learning seperti XGBoost, Random Forest, Adaboost, dan Multiple Linear Regression. Hasil pelatihan model machine learning berhasil memprediksi nilai impedansi berdasarkan input berupa data dimensi koil transformator. Hasil pengujian juga menunjukkan bahwa algoritma XGBoost memberikan akurasi prediksi tertinggi, diikuti oleh Random Forest, Adaboost, dan Multiple Linear Regression. Selain itu, melalui proses hyperparameter tuning, set parameter yang optimal berhasil ditemukan untuk meningkatkan kinerja model. Tahap terakhir penelitian ini melibatkan pembuatan aplikasi website menggunakan framework Streamlit, yang memungkinkan pengguna untuk melakukan prediksi nilai impedansi transformator berdasarkan input data dimensi koil, serta menganalisis hasil prediksi tersebut.

Kata Kunci – transformator, machine learning, impedansi, dimensi koil

I. PENDAHULUAN

Transformator adalah sebuah perangkat statis yang memiliki dua atau lebih lilitan. Melalui induksi elektromagnetik, transformator mengubah sistem tegangan dan arus bolak-balik menjadi sistem tegangan dan arus lainnya, biasanya dengan nilai yang berbeda, namun pada frekuensi yang sama. Hal ini bertujuan untuk mendistribusikan daya listrik [1]. Proses pembuatan transformator (trafo) di PT. X dibagi menjadi tiga tahap utama, yaitu desain, produksi, dan pengujian. Tahap desain melibatkan perhitungan sesuai dengan spesifikasi trafo yang diperlukan oleh pelanggan, baik dari segi mekanikal maupun elektrik. Selain itu, pada tahap produksi, dilakukan berbagai tahapan pengolahan trafo seperti pembuatan lilitan (winding), perakitan (assembly), dan perakitan bagian dalam transformer ke dalam tangki transformer (tanking). Terakhir, dalam tahap pengujian, trafo yang telah selesai diproduksi

menjalani serangkaian tes sesuai dengan standar kelulusan yang telah ditetapkan oleh PT. X. Tahap-tahap ini memastikan bahwa setiap trafo yang diproduksi memenuhi standar kualitas yang ketat sebelum diserahkan kepada pelanggan.

Dalam upaya menjaga mutu dan kualitas produk, PT. X memiliki beberapa tantangan salah satunya mengenai impedansi. Berdasarkan hasil pengujian di PT. X, nilai impedansi setiap trafo memiliki deviasi positif dan deviasi negatif dari garansi yang sudah diperhitungkan saat proses desain. Hal ini menyebabkan adanya ketidaksesuaian antara proses desain dan nilai impedansi aktual, yang salah satunya disebabkan oleh faktor dimensi belitan. Nilai impedansi trafo direpresentasikan oleh tahanan resistif dan reaktansi dari belitan transformator [1]. Komponen reaktansi pada transformer secara langsung berkaitan dengan leakage flux yang terjadi pada celah insulasi di antara belitan [2]. Di sisi lain, tahanan resistif pada transformer berkaitan dengan panjang dan luas penampang konduktor belitan [3]. Sehingga dapat disimpulkan bahwa dimensi koil transformator berkontribusi langsung terhadap perubahan nilai impedansi. Oleh karena itu, diperlukan suatu solusi untuk mengidentifikasi hubungan data belitan transformator dan impedansi untuk menyimpulkan deviasi yang terjadi.

Penelitian oleh Mao et al. (2020) [4] dan Valencia et al. (2021) [5] sangat relevan dengan penelitian yang dilakukan mengenai pemodelan machine learning untuk memprediksi nilai impedansi berdasarkan dimensi belitan transformator. Mao et al. [4] meneliti ketidakmampuan utilitas untuk mengetahui informasi desain transformator kritis dengan menggunakan data Frequency Response Analysis (FRA) dan model Support Vector Machine (SVM), yang berhasil mengidentifikasi jenis gulungan transformator dengan tepat. Valencia et al. [5] membandingkan empat teknik machine learning—linear regression, support vector regression, random forests, dan artificial neural networks—untuk memprediksi mechanical stress pada konduktor gulungan transformator akibat gangguan listrik tiga fase, menemukan bahwa random forest memberikan hasil paling akurat. Kedua penelitian ini menunjukkan pentingnya aplikasi machine learning dalam memahami dan memprediksi karakteristik transformator.

Pendekatan yang diajukan adalah menggunakan teknik machine learning regression untuk mengidentifikasi hubungan antara pengukuran dimensi belitan transformator dan hasil pengujian impedansi transformator. PT. X memiliki dataset yang mencakup ratusan data dimensi koil, yang diperoleh

melalui pengukuran saat proses produksi, dan data impedansi dari hasil pengujian transformator. Fitur-fitur dalam dataset dimensi koil meliputi diameter dalam dan diameter luar gulungan LV (sisi sekunder) serta diameter dalam dan diameter luar gulungan HV (sisi primer). Sementara itu, dataset impedansi mencakup fitur nilai impedansi transformator. Informasi ini sangat berguna untuk membuat model machine learning yang dapat mencari hubungan antara data pengukuran dimensi koil dan memprediksi nilai impedansi yang mungkin terjadi berdasarkan nilai input dimensi koil tersebut. Inovasi dari penelitian ini terletak pada penerapan teknik machine learning regression untuk memodelkan hubungan antara dimensi belitan transformator dan nilai impedansi transformator, yang belum banyak dieksplorasi dalam literatur sebelumnya. Penelitian ini menggunakan dataset yang kaya dan terperinci yang mencakup dimensi fisik gulungan transformator serta data nilai impedansi yang diperoleh dari pengujian aktual.

II. METODOLOGI PENELITIAN


Penelitian yang dilakukan mencakup prediksi penyimpangan impedansi. Penelitian ini menggunakan dataset milik PT. X. Sistem penelitian terbagi menjadi dua bagian yang dikerjakan secara berkelompok. Penulis akan mengembangkan sebuah sistem berupa pemodelan machine learning dengan menggunakan data dimensi belitan transformator dan data hasil pengujian impedansi. Hasil pemodelan tersebut akan digunakan untuk memprediksi nilai impedansi baru berdasarkan parameter dimensi belitan transformator.

A. Teori-teori yang Dipakai Dalam Penelitian

Impedansi pada transformator terdiri dari dua komponen utama, yaitu tahanan resistif dan reaktansi. Dalam pengujian ini, beberapa batasan diterapkan untuk menyederhanakan model prediksi. Untuk komponen tahanan resistif, hambatan jenis konduktor diabaikan, yang berarti bahwa variasi dalam resistivitas bahan kawat tidak diperhitungkan dalam model prediksi. Hanya dimensi fisik belitan yang digunakan untuk menghitung impedansi resistif. Dalam komponen reaktansi, jumlah turn atau lilitan belitan juga diabaikan, biasanya jumlah lilitan berpengaruh langsung pada nilai reaktansi induktif, namun dalam pengujian ini, asumsi dibuat bahwa dimensi belitan cukup untuk mewakili efek tersebut. Daya terukur transformator (kVA) juga diabaikan dalam pengujian ini, dengan dimensi koil dianggap cukup untuk merepresentasikan parameter penting lainnya seperti area koil, radius koil, dan tinggi koil, sehingga dimensi koil dianggap mencerminkan daya terukur secara tidak langsung. Setiap pengujian menggunakan 12 fitur dimensi belitan ini untuk memprediksi nilai impedansi, mengabaikan hambatan jenis konduktor, jumlah lilitan, dan kVA.

1. Belitan Transformator


Transformator merupakan sebuah perangkat elektrik yang berfungsi untuk mendistribusikan daya antara dua atau lebih belitan menggunakan prinsip induksi elektromagnetik. Belitan transformator terdiri dari gulungan konduktor, isolasi padat, dan jalur sirkulasi minyak transformator. Dimulai dari inti transformator, belitan transformator terdiri atas beberapa elemen, antara lain Winding Cylinder LV, LV winding (gulungan sisi sekunder), Main Insulation antar winding, Winding Cylinder, Winding HV (gulungan sisi primer), dan kertas isolasi.



Gambar 1. Tampak Samping Dan Tampak Atas Belitan Transformator [6]

2. Impedansi Transformator

Impedansi transformator merupakan sebuah parameter yang menggambarkan total hambatan terhadap arus bolak-balik (AC) yang mengalir melalui transformator. Berdasarkan interpretasi sirkuit transformator menggunakan rangkaian ekuivalen, nilai impedansi merepresentasikan tahanan resistif dan reaktansi [1]. Nilai tahanan resistif berasal dari panjang konduktor, jenis konduktor dan luas penampang konduktor yang digunakan. Di sisi lain, reaktansi terdiri dari 2 jenis yakni reaktansi induktif dan reaktansi kapasitif. Reaktansi induktif berhubungan dengan jumlah turn belitan transformator dan leakage flux [2], sedangkan reaktansi kapasitif berhubungan dengan isolasi transformator seperti jarak antar belitan dan bahan isolasi yang digunakan. Pada rangkaian ekuivalen transformator, reaktansi kapasitif seringkali diabaikan karena jumlahnya relatif kecil apabila dibandingkan dengan reaktansi induktif.



Gambar 2. Rangkaian Ekuivalen Transformator [7]

Keterangan:

- R_1 : tahanan resistif pada sisi primer
- jX_1 : reaktansi induktif pada sisi primer
- R_2 : tahanan resistif pada sisi sekunder
- jX_2 : reaktansi induktif pada sisi sekunder
- R_{C1} : tahanan resistif pada inti besi
- L_{m1} : reaktansi induktif pada inti besi
- I_0 : terdiri dari I_c dan I_m
- I_c : arus rugi-rugi
- I_m : arus medan magnet
- I_1 : arus pada sisi primer
- I_2 : arus pada sisi sekunder
- E_1 : tegangan pada sisi primer
- E_2 : tegangan pada sisi sekunder

3. Tahanan Resistif dan Reaktansi Belitan Transformator

Salah satu bagian impedansi transformator yang memiliki nilai paling besar adalah tahanan resistif pada tiap belitan transformator. Hal ini dikarenakan belitan transformator merupakan komponen yang paling besar dalam sebuah transformator. Nilai resistif pada kawat belitan dapat dihitung menggunakan rumus berikut [3]:

$$R = \rho \cdot \frac{L}{A} \quad (1)$$

Keterangan:

- R : tahanan konduktor
- ρ : resistivitas bahan kawat
- L : panjang kawat
- A : luas penampang kawat

Semakin banyak jumlah turn pada belitan transformator maka rugi tembaga yang dihasilkan semakin besar. Dalam pengujian hubung singkat, nilai rugi tembaga dapat dihitung dengan rumus berikut [3]:

$$P = I^2 R \quad (2)$$

Keterangan:

- R : tahanan konduktor
- P : rugi tembaga
- I : arus nominal

Induktansi koil dapat dihitung dengan rumus berikut [3]:

$$L_{\text{coil}} = \frac{\mu_r \mu_0 N^2 A}{l} = \frac{\mu_r \mu_0 N^2 \pi r^2}{l} \quad (3)$$

Keterangan:

- L_{coil} : induktansi koil (H)
- μ_r : relative permeability inti besi
- μ_0 : permeability of free space $4\pi \times 10^{-7}$ (H/m)
- N : jumlah lilitan/belitan
- A : koil area (m²)
- r : koil radius (m)
- l : panjang vertikal/tinggi koil (m)

Kapasitansi koil dapat dihitung dengan rumus berikut [3]:

$$C = 0.0885 \left(\frac{K(N_{\text{turn}}-1)(MLT)(G)}{d} \right) \quad (4)$$

Keterangan:

- K : Dielectric Constant
- MLT : Mean Length Turn
- N_{turn} : jumlah lilitan/belitan
- G : foil width, cm
- d : layer insulation thickness, cm

Tabel 1. Dielektrik Konstan [3]

Material	K
Kapton	3.2 – 3.5
Mylar	3 – 3.5
Kraft Paper	1.5 – 3.0
Fish Paper	1.5 – 3.0
Nomex	1.6 – 2.9

Rumus-rumus di atas berhubungan dengan komponen-komponen impedansi dalam transformator dan memberikan cara untuk menghitung total impedansi (Z) dalam sebuah rangkaian AC yang melibatkan elemen resistif, induktif, dan

kapasitif. Berikut adalah rumus untuk menghitung nilai impedansi [3]:

$$Z = R + j(X_L - X_C) \quad (5)$$

$$X_L = \omega L \quad (6)$$

$$X_C = \frac{1}{\omega C} \quad (7)$$

Keterangan:

- Z : impedansi (Ω)
- R : tahanan resistif (Ω)
- X_L : reaktansi induktif (Ω)
- X_C : reaktansi kapasitif (Ω)
- ω : omega atau kecepatan sudut (rad/s)
- L : induktor (H)
- C : kapasitor (F)

4. Standar Impedansi Transformator

Tabel 2. Toleransi Impedansi [1]

Item	Tolerance
1. Measured short-circuit impedance for: - an auto-connected pair of winding, or - a specified second pair of separate windings in a multi-winding transformer a) principal tapping b) any other tapping of the pair	$\pm 10\%$ of the specified value $\pm 10\%$ of the design value for that tapping

Standar toleransi impedansi untuk transformator yang diizinkan adalah $\pm 10\%$ dari nilai yang ditentukan atau $\pm 10\%$ dari nilai desain untuk tapping tersebut. Hal ini berlaku untuk pasangan belitan yang terhubung secara otomatis, atau pasangan belitan terpisah kedua yang ditentukan dalam transformator multi-belitan, baik pada tapping utama maupun tapping lainnya dari pasangan tersebut. Toleransi ini memberikan kelonggaran yang wajar bagi variasi dalam proses manufaktur dan operasional, memastikan bahwa performa transformator tetap berada dalam batas-batas yang dapat diterima meskipun terdapat variasi minor dalam nilai impedansi.

Tabel 3. Standar Minimum Short-Circuit Impedance Berdasarkan KVA [8].

Short-circuit impedance at rated current		
Rated power		Minimum short-circuit impedance
kVA		%
Up to	630	4,0
631 to	1 250	5,0
1 251 to	2 500	6,0
2 501 to	6 300	7,0
6 301 to	25 000	8,0
25 001 to	40 000	10,0
40 001 to	63 000	11,0
63 001 to	100 000	12,5
Above	100 000	>12,5

NOTE 1 Values for rated power greater than 100 000 kVA are generally subjected to agreement between manufacturer and purchaser.
 NOTE 2 In case of single-phase units connected to form a three-phase bank, the value of rated power applies to three-phase bank rating.

Selain nilai toleransi impedansi, nilai minimum impedansi hubung singkat memiliki standar untuk transformator dengan dua belitan terpisah pada arus nominal. Nilai-nilai ini bervariasi tergantung pada daya terukur (*rated power*) transformator yang dinyatakan dalam kVA. Untuk transformator dengan daya terukur hingga 630 kVA, impedansi hubung singkat minimum adalah 4%. Nilai ini meningkat seiring dengan peningkatan daya terukur, dengan transformator dalam rentang daya 1.251 hingga 2.500 kVA memiliki impedansi minimum 6%.

5. Machine Learning

Machine learning dapat didefinisikan sebagai kumpulan metode yang dapat secara otomatis mendeteksi pola dalam data, dan kemudian menggunakan pola yang ditemukan untuk memprediksi data di masa depan, atau untuk melakukan jenis pengambilan keputusan lain dalam situasi ketidakpastian [9]. Machine learning secara umum diklasifikasikan menjadi empat kategori, yakni Supervised Learning, Unsupervised Learning, Semi-Supervised Learning dan Reinforcement Learning [10].

- Multiple Linear Regression


Suatu metode machine learning yang dibuat berdasarkan analisis statistik dan digunakan untuk mengukur hubungan antara dua atau lebih variabel independen (prediktor) terhadap satu variabel dependen (respon). Metode ini merupakan perluasan dari linear regression sederhana yang hanya melibatkan satu variabel independen. Persamaan multiple linear regression dapat dijelaskan sebagai berikut [11]:

$$Y = \beta + \beta_0X_1 + \dots + \beta_nX_n + \epsilon \tag{8}$$

di mana Y adalah variabel prediktor atau target dan Xn adalah variabel independen. Di sisi lain, β adalah intercept β_n dan ϵ adalah koefisien atau istilah error masing-masing [11].

- XGBoost

Extreme Gradient Boosting (XGBoost) merupakan sebuah algoritma machine learning ensemble yang memiliki kelebihan berupa keunggulan fleksibilitas tinggi, prediksi yang kuat, kemampuan generalisasi yang tinggi, skalabilitas tinggi, efisiensi pelatihan model yang tinggi, dan ketahanan yang besar [12]. Algoritma ini merupakan pengembangan dari algoritma Gradient Boosting.




Gambar 3. Ilustrasi Konsep Gradient Boosting [13]

- Random Forest

Random Forest merupakan metode machine learning yang berupa gabungan model decision tree [14]. Output dari metode

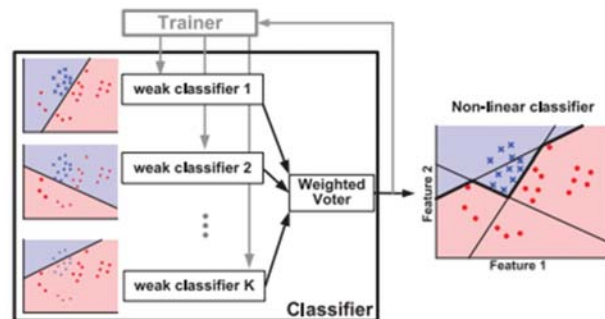
ini merupakan nilai rata-rata dari hasil prediksi tiap pohon. Cara kerja Random Forest adalah dengan membangun banyak decision tree pada subset data yang diambil secara acak. Setiap pohon memberikan prediksi, dan hasil prediksi dari semua pohon digabungkan untuk menghasilkan prediksi akhir. Random Forest memiliki kecepatan komputasi yang tinggi karena decision tree dapat dibangun secara independen dan paralel. Hal ini membuatnya efisien untuk dataset yang besar. Random Forest juga dapat mengurangi overfitting menggunakan teknik bootstrap aggregating (bagging). Teknik bagging membantu mengurangi overfitting dengan menciptakan decision tree yang beragam.



Gambar 4. Ilustrasi Algoritma Random Forest [14]

- Adaboost

Adaptive Boosting (Adaboost) merupakan sebuah metode untuk meningkatkan hasil prediksi dalam machine learning. Seperti halnya metode gradient boosting, Adaboost juga menggunakan weak learners, namun biasanya diterapkan pada permasalahan klasifikasi. Algoritma AdaBoost secara efektif menghasilkan batas keputusan yang terbentuk dari beberapa klasifikasi lemah, sehingga mencapai penyesuaian pada tingkat klasifikasi yang kuat [15]. Meskipun demikian, Adaboost dapat disesuaikan atau diadaptasi untuk menyelesaikan permasalahan regresi.



Gambar 5. Ilustrasi Dari Algoritma Adaboost Untuk Membuat Klasifier Kuat Berdasarkan Beberapa Klasifier Lemah Yang Linear [15]


B. Pengambilan Data

Dataset yang digunakan pada penelitian ini merupakan dataset ukuran dimensi koil transformator distribusi dan dataset hasil pengujian impedansi tahun 2023 dan 2024 yang diproduksi PT. X.

Belitan transformator diukur secara bertahap sesuai proses winding belitan. Proses winding belitan transformator distribusi dimulai dari bagian dalam, yaitu LV Winding, kemudian dilanjutkan dengan HV Winding. Tahapan

pengukuran dimensi belitan transformator adalah sebagai berikut:

1. Inner Diameter LV
2. Outer Diameter LV
3. Inner Diameter HV
4. Outer Diameter HV



Gambar 6. Tampak Atas Belitan Transformator dan Tampak Samping Belitan Transformator

Selain itu, parameter pengukuran dimensi belitan transformator meliputi Panjang, Lebar, dan Tinggi. Pada gambar 8, garis sumbu Y mewakili panjang, garis sumbu X mewakili lebar, dan garis sumbu Z mewakili tinggi. Jadi, setiap tahap pengukuran diukur sebanyak 3 kali. Pengukuran dilakukan menggunakan alat ukur jangka sorong untuk memastikan presisi panjang dan lebar koil transformator.

C. Data Preprocessing

SN	Inner Diameter	Inner Diameter	Inner Diameter	Outer Diameter	Outer Diameter	Outer Diameter	Inner Diameter	Inner Diameter	Inner Diameter	Outer Diameter	Outer Diameter	Outer Diameter
	Length LV	Width LV	Height LV	Length LV	Width LV	Height LV	Length HV	Width HV	Height HV	Length HV	Width HV	Height HV
Coil 1	269	213	750	438	325	752	438	328	752	584	462	752
Coil 2	269	215	750	435	325	752	437	327	752	584	443	750
Coil 3	212	163	350	340	260	352	340	260	353	462	341	353
Coil 4	213	163	350	338	257	352	434	334	352	546	341	353
Coil 5	213	163	350	338	257	352	340	260	352	460	343	353
Coil 6	301	223	380	433	306	380	435	307	380	570	415	380
Coil 7	301	223	380	433	306	380	433	310	380	570	405	380
Coil 8	303	223	380	432	310	382	432	310	382	562	405	382
Coil 9	303	224	382	432	310	382	435	310	382	579	400	384

Gambar 7. Contoh Dataset Pengukuran Dimensi Koil Transformator

TR KODE	Capacity (KVA)	Frek (HZ)	Voltage		Vector Group	Date of test	% Imp. at(75°C)
			HV (Volt)	LV (Volt)			
Trafo 1	2000	50	20000	400	Dyn5	1-Sep-23	7.08
Trafo 2	2500	50	20000	400	Dyn5	1-Sep-23	7.16
Trafo 3	1250	50	6600	400	Dyn11	1-Sep-23	4.80
Trafo 4	2000	60	13800	480	Dyn1	4-Sep-23	5.96
Trafo 5	630	60	13800	480	Dyn1	4-Sep-23	3.86
Trafo 6	2000	50	11000	6600	Dyn11	5-Sep-23	5.58
Trafo 7	200	50	20000	400	YNyn0	5-Sep-23	4.00
Trafo 8	2500	50	20000	400	Dyn5	5-Sep-23	7.17
Trafo 9	1000	50	20000	595	Dy5	6-Sep-23	4.87
Trafo 10	400	50	20000	400	YNyn0	7-Sep-23	3.90

Gambar 8. Contoh Dataset Impedansi

Persiapan data dalam dunia machine learning adalah proses penting untuk mempersiapkan data mentah agar dapat digunakan secara efektif oleh model machine learning. Pre-processing dilakukan untuk menyiapkan dataset yang akan digunakan sebagai data training dan data testing. Pre-processing yang dilakukan meliputi data cleaning, data integration, dan data exploration. Output yang dihasilkan

dalam proses ini adalah final data yang akan digunakan dalam proses data modeling.

D. Pembuatan Pemodelan Machine Learning

Pada penelitian ini pemodelan machine learning yang akan digunakan ada empat, yaitu random forest, XG Boost, multiple linear regression, dan adaboost. Nantinya, hasil dari keempat model ini akan dievaluasi performanya dan dipilih satu model terbaik untuk diimplementasikan pada aplikasi website. Keempat model tersebut dipilih karena cocok untuk menyelesaikan masalah regresi. Selain itu, machine learning yang ingin diterapkan pada penelitian ini merupakan supervised learning karena dataset sudah memiliki label. Keempat model machine learning ini merupakan algoritma machine learning boosting. Dari teori penunjang, algoritma machine learning boosting memiliki performa yang lebih baik dari bagging untuk mengatasi masalah regresi dengan dataset yang memiliki bias.

1. Import Dataset

Langkah pertama dalam membuat pemodelan pada platform kaggle adalah menelusuri dan mengimpor dataset dari direktori '/kaggle/input' beserta semua subdirektori.

2. Import Library yang Diperlukan

Proses selanjutnya adalah menggunakan berbagai library Python untuk mengimplementasikan dan mengevaluasi model machine learning secara efektif. Library machine learning yang digunakan termasuk scikit-learn, yang menyediakan algoritma seperti Random Forest, XGBoost, Multiple Linear Regression, dan AdaBoost. Library ini juga digunakan untuk membagi dataset menjadi training set dan test set serta menghitung metrik evaluasi seperti Mean Absolute Error (MAE) dan Mean Squared Error (MSE). Selain itu, library visualisasi seperti Matplotlib digunakan untuk membuat grafik, sementara Seaborn digunakan khususnya untuk visualisasi data statistik, memudahkan pembuatan plot yang lebih kompleks dan menarik. Dengan berbagai library tersebut, proses analisis data dan pembangunan model machine learning dapat dilakukan dari awal hingga akhir, termasuk data preprocessing, pelatihan model, evaluasi kinerja model, dan visualisasi hasil.

3. Functions

Proses yang ketiga adalah membuat berbagai fungsi seperti check_score dan apply_regressor. Fungsi apply_regressor menerima parameter berupa estimator (model), data latih (x_train, y_train), dan data uji (x_test, y_test). Fungsi ini pertama-tama akan melatih model menggunakan data latih. Setelah model dilatih, fungsi ini akan memprediksi nilai target pada data uji dan menghitung skor performa model menggunakan fungsi check_score. Hasil prediksi dan skor performa kemudian dikembalikan oleh fungsi ini. Sementara itu, fungsi check_score digunakan untuk mengevaluasi performa model yang telah dilatih. Dengan menggunakan data uji (x_test, y_test), fungsi ini memprediksi nilai target dan kemudian menghitung metrik evaluasi seperti Mean Absolute Error (MAE), Mean Squared Error (MSE), dan R-squared (R2S). Hasil prediksi dan skor performa kemudian dikembalikan oleh fungsi ini.

4. Data Split

Proses ini menggunakan perintah train_test_split untuk memisahkan dataset menjadi subset pelatihan (training set) dan subset pengujian (test set) untuk evaluasi model. Pembagian ini

penting untuk mengukur kinerja model dengan benar dan mencegah overfitting. Dalam penelitian ini akan dibagi dataset dengan porsi data training sebesar 80% dan data testing sebesar 20%.

5. Membuat Pemodelan

Setelah melakukan data split, dataset akan dimodelkan menggunakan setiap algoritma. Pada proses training, data yang telah disiapkan akan di-load untuk dilatih menggunakan metode Random Forest, XGBoost, Multiple Linear Regression, dan AdaBoost. Setelah proses pelatihan selesai, model yang telah dilatih akan disimpan agar dapat digunakan pada tahap selanjutnya, yaitu proses testing. Pada tahap testing, data yang telah disiapkan untuk pengujian akan di-load dan diuji menggunakan model yang sudah dilatih sebelumnya. Jadi, data training set akan digunakan sebagai input pemodelan dan data test set akan digunakan untuk menguji hasil prediksi pemodelan tersebut.

E. Meningkatkan Akurasi Pemodelan

Meningkatkan akurasi pemodelan data melibatkan berbagai teknik dan langkah yang dapat diambil selama proses pengembangan model. Dalam penelitian ini, dua metode yang digunakan adalah Feature Selection dan hyperparameter tuning.

Feature Selection merupakan proses pemilihan subset fitur yang paling relevan dan penting dari sekumpulan fitur yang tersedia dalam dataset berdasarkan analisa feature importance. Hal ini bertujuan untuk mengurangi dimensi data, menghilangkan noise, serta mempercepat proses pembelajaran model.

Hyperparameter tuning merupakan proses penentuan parameter terbaik dari sebuah model machine learning, yang dilakukan dengan mencari kombinasi nilai yang optimal untuk setiap parameter yang dimiliki oleh model tersebut. Salah satu metode yang umum digunakan untuk melakukan hyperparameter tuning adalah dengan menggunakan teknik grid search. Grid search membantu mencari kombinasi nilai yang optimal dari sekumpulan pilihan nilai yang telah ditentukan sebelumnya untuk setiap parameter yang dimiliki oleh model. Metode ini akan menggunakan value dari setiap parameter dan melakukan training pada setiap kombinasi parameter. Skor dari kombinasi terbaik dapat diaplikasikan pada model.


F. Implementasi Cross Validation

Setelah melakukan hyperparameter tuning, langkah selanjutnya dalam pengembangan model adalah melakukan cross-validation. Salah satu metode cross-validation yang umum digunakan adalah K-Fold Cross Validation. Algoritma ini membagi dataset menjadi beberapa subset dengan ukuran yang sama, yang disebut lipatan atau fold. Tiap fold digunakan secara bergantian sebagai subset uji, sementara lipatan lainnya digunakan sebagai subset pelatihan. Proses ini diulang untuk setiap lipatan, dan hasil validasi dihitung dengan mengambil rata-rata dari hasil evaluasi model pada tiap lipatan. Langkah ini membantu mengurangi risiko overfitting dan memungkinkan identifikasi masalah yang muncul pada setiap lipatan.

G. Pembuatan Aplikasi Website

Flowchart di atas menggambarkan proses untuk memprediksi impedansi kumparan. Proses dimulai dengan tahap "Start", di mana pengguna diminta untuk memasukkan data dimensi kumparan. Setelah memasukkan data, dilakukan validasi data.

Jika data sudah valid, maka proses akan melanjutkan ke tahap prediksi impedansi. Namun, jika data tidak valid, pengguna akan diminta untuk memasukkan data dimensi kumparan kembali. Setelah proses validasi data, dilakukan prediksi impedansi berdasarkan data dimensi kumparan yang telah dimasukkan. Hasil prediksi akan direkam dalam riwayat prediksi. Selanjutnya, dilakukan visualisasi plot untuk hasil prediksi. Aplikasi Website dibuat menggunakan framework Streamlit.



Gambar 9. Flowchart Aplikasi Website

III. HASIL DAN PEMBAHASAN

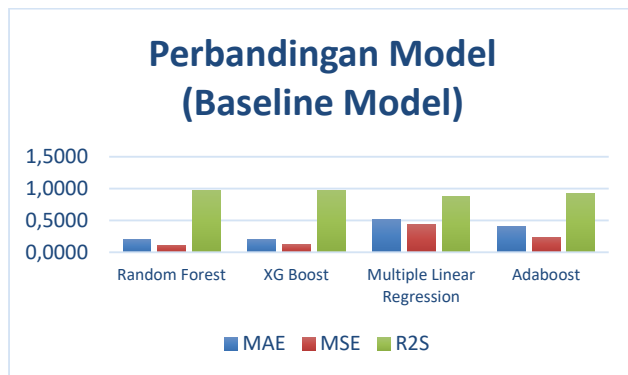
Pada bagian ini akan dijelaskan mengenai hasil prediksi pemodelan tiap algoritma machine learning, baik secara baseline model, setelah Feature Selection, dan setelah hyperparameter tuning. Bab ini juga menjelaskan pengujian model machine learning menggunakan metode K-fold cross validation.

A. Evaluasi Akurasi dan Prediksi Baseline Model

Evaluasi kinerja baseline dari berbagai model machine learning dilakukan untuk memahami performa model sebelum dilakukan penyesuaian lebih lanjut melalui feature selection atau hyperparameter tuning. Baseline Model merupakan pemodelan machine learning tanpa pengaturan tiap nilai parameter atau menggunakan nilai default. Baseline model ini

memberikan gambaran tentang seberapa baik model dapat memprediksi target variabel tanpa adanya penyesuaian atau tuning tambahan terhadap hyperparameter maupun proses lainnya.

Evaluasi dilakukan menggunakan beberapa metrik kinerja, yaitu Mean Absolute Error (MAE), Mean Squared Error (MSE), dan Coefficient of Determination (R²S). MAE mengukur rata-rata selisih absolut antara nilai prediksi dan nilai sebenarnya, memberikan gambaran umum tentang ukuran kesalahan prediksi. MSE mengukur rata-rata kuadrat selisih antara nilai prediksi dan nilai sebenarnya, dengan penekanan pada kesalahan besar. R²S menunjukkan seberapa baik model dapat menjelaskan variabilitas data target, dengan nilai berkisar antara 0 hingga 1, semakin mendekati 1 semakin baik. Ketiga metrik ini penting dalam mengevaluasi kinerja model, dengan MAE dan MSE memberikan informasi tentang seberapa akurat prediksi model, sementara R²S memberikan gambaran tentang seberapa baik model dapat menjelaskan variasi dalam data.



Gambar 10. Grafik Perbandingan Hasil Metrik Evaluasi Tiap Model dalam Kondisi *Baseline*

Dari gambar 12, hasil evaluasi menunjukkan bahwa model *XGBoost* dan *Random Forest* memiliki nilai MAE dan MSE yang lebih rendah dibandingkan *Multiple Linear Regression* dan *Adaboost*. Nilai MAE yang tercatat adalah 0.1963 untuk *Random Forest* dan 0.1934 untuk *XGBoost*, sementara nilai MSE adalah 0.1143 untuk *Random Forest* dan 0.1167 untuk *XGBoost*. R²S untuk kedua model ini juga sangat tinggi, dengan nilai 0.9658 untuk *Random Forest* dan 0.9650 untuk *XGBoost*. Sebaliknya, *Multiple Linear Regression* dan *Adaboost* menunjukkan nilai R²S yang lebih rendah, yakni 0.8703 dan 0.9286.

Analisa dari hasil evaluasi ini dapat disimpulkan bahwa *Random Forest* dan *XGBoost* memiliki performa yang lebih baik sebagai *baseline model* dibandingkan dengan *Multiple Linear Regression* dan *Adaboost*. Kedua model ini tidak hanya menunjukkan MAE dan MSE yang lebih rendah, tetapi juga nilai R²S yang lebih tinggi, menandakan kemampuan yang superior dalam memprediksi dan menjelaskan variabilitas data. Hasil ini memberikan gambaran yang jelas tentang keefektifan model sebelum dilakukan pengoptimalan lebih lanjut.

Tabel 4 menampilkan hasil prediksi nilai impedansi dari beberapa model regresi yang telah diterapkan. Kolom "DATA Number" menunjukkan nomor urut data, sementara kolom "IMP" berisi nilai impedansi aktual. Kolom-kolom berikutnya, yakni "RF Pred", "XGB Pred", "MLR Pred", dan "ADA Pred", masing-masing berisi prediksi nilai impedansi yang dihasilkan oleh tiap model. Hasil *baseline* model menunjukkan bahwa performa prediksi dari keempat model tersebut cukup baik, dengan nilai prediksi yang mendekati data aktual.

Tabel 4. Contoh Hasil Prediksi Tiap Model pada Kondisi *Baseline*

DATA Number	IMP	RF Pred	XGB Pred	MLR Pred	ADA Pred
848	6.88709	6.826178	7.464867	6.188916	6.781234
333	5.288051	5.519987	5.291631	5.826074	5.277932
280	4.86616	4.886763	4.971755	4.812028	4.631027
30	3.716762	3.816447	3.842352	4.412267	4.613198
168	4.581522	4.628013	4.622544	4.853868	4.931729
23	3.696138	4.474369	4.320682	4.237749	4.288084
294	4.919434	4.886763	4.971755	4.812028	4.631027
479	7.307048	7.069393	7.272127	6.900931	6.54181
483	7.356536	7.319907	7.229014	6.266265	6.620489
669	9.912558	10.05965	10.05251	10.06682	10.00813
539	4.908753	4.917222	4.893288	4.522854	4.790569
381	6.099614	5.553088	5.942299	5.720373	5.425812

Keterangan:

IMP : Nilai Impedansi Aktual

RF Pred : Nilai Impedansi yang diprediksi menggunakan Model Random Forest

XGB Pred : Nilai Impedansi yang diprediksi menggunakan Model XGBoost

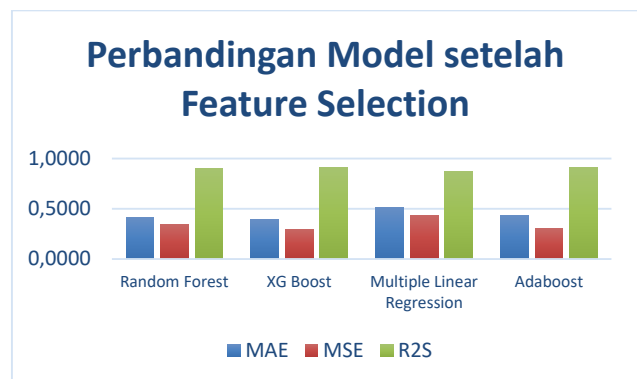
MLR Pred : Nilai Impedansi yang diprediksi menggunakan Model Multiple Linear Regression

ADA Pred : Nilai Impedansi yang diprediksi menggunakan Model Adaboost

B. Evaluasi Akurasi dan Prediksi setelah Feature Selection

Evaluasi pemodelan setelah dilakukan *feature selection* bertujuan untuk menilai dampak proses *feature selection* terhadap akurasi pemodelan. Selain itu, *feature selection* dapat mengidentifikasi fitur-fitur yang paling relevan dan informatif, dengan harapan dapat meningkatkan akurasi model, mengurangi *overfitting* dan *noise*, serta mengoptimalkan penggunaan waktu komputasi dan sumber daya.

Proses *feature selection* dilakukan dengan mengevaluasi relevansi setiap fitur terhadap target variabel. Fitur-fitur yang dinilai penting, berdasarkan nilai *threshold* seperti *importance score*, dipertahankan dalam model. Sebaliknya, fitur-fitur yang tidak memenuhi *threshold* dihapus. Evaluasi kinerja model setelah *feature selection* dilakukan menggunakan metrik Mean Absolute Error (MAE), Mean Squared Error (MSE), dan Coefficient of Determination (R²S) untuk membandingkan akurasi prediksi model.



Gambar 11. Grafik Perbandingan Hasil Metrik Evaluasi tiap Model dalam setelah dilakukan *Feature Selection*

Setelah proses Feature Selection, model XGBoost dan Random Forest tetap menunjukkan nilai MAE dan MSE yang lebih rendah dibandingkan dengan Multiple Linear Regression dan Adaboost. Nilai MAE dan MSE yang rendah pada XGBoost dan Random Forest menandakan bahwa prediksi model ini lebih akurat dengan kesalahan yang lebih kecil. Selain itu, nilai R2S untuk kedua model ini tetap tinggi, menunjukkan kemampuan yang baik dalam menjelaskan variasi data. Namun, dibandingkan dengan performa baseline sebelum feature selection, terjadi penurunan performa pada model XGBoost dan Random Forest setelah dilakukan feature selection. Nilai MAE dan MSE untuk kedua model ini meningkat, menunjukkan adanya peningkatan kesalahan prediksi.

Walaupun feature selection biasanya bertujuan untuk menyederhanakan model, dalam kasus ini, proses tersebut ternyata mengakibatkan penurunan akurasi model. Peningkatan kesalahan prediksi yang terlihat setelah feature selection mungkin disebabkan oleh penghapusan fitur-fitur yang sebenarnya mengandung informasi penting. Oleh karena itu, meskipun feature selection dapat memperbaiki kinerja model dengan memilih fitur yang relevan, dalam konteks ini, proses tersebut tampaknya malah menurunkan akurasi model. Evaluasi ini menyoroti pentingnya pertimbangan cermat dalam memilih fitur, terutama dalam konteks jumlah data yang terbatas.

C. Evaluasi Akurasi dan Prediksi Setelah Hyperparameter Tuning

Tujuan evaluasi hyperparameter tuning adalah untuk menilai dampak dari proses hyperparameter tuning terhadap akurasi pemodelan. Hyperparameter tuning bertujuan untuk mengoptimalkan parameter-parameter kunci dari model machine learning agar dapat meningkatkan kinerja model. Penyesuaian ini diharapkan dapat menghasilkan peningkatan akurasi, konsistensi hasil prediksi, dan mengurangi overfitting atau underfitting.

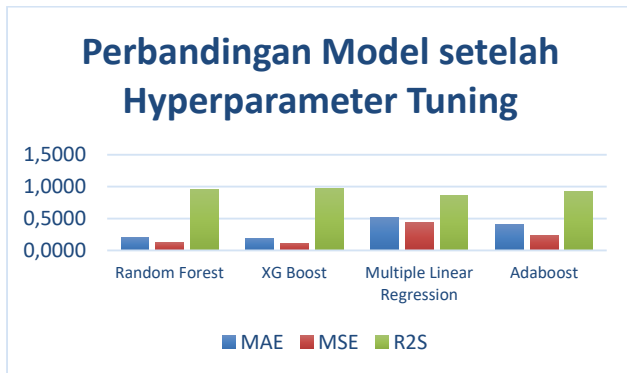
Proses hyperparameter tuning dilakukan menggunakan metode grid search. Dalam grid search, sebuah sekumpulan nilai parameter yang mungkin ditentukan sebelumnya dicoba secara sistematis. Setiap kombinasi nilai parameter dievaluasi dengan membangun dan menguji model untuk menemukan kombinasi yang memberikan kinerja terbaik berdasarkan metrik evaluasi seperti Mean Squared Error (MSE) dan Mean Absolute Error (MAE). Hasil tuning mengacu pada parameter-parameter optimal yang ditemukan untuk setiap model guna memperoleh nilai MSE terbaik.

Setelah proses hyperparameter tuning, beberapa model menunjukkan peningkatan kecil dalam metrik evaluasi seperti R2S dan penurunan MSE, seperti pada model XGBoost. Namun, model lain seperti Random Forest dan Adaboost mengalami penurunan kecil dalam nilai R2S dan peningkatan dalam MAE dan MSE. Secara umum, performa model setelah tuning tidak mengalami perubahan signifikan dibandingkan dengan baseline, dengan hasil yang cenderung serupa.

Meskipun hyperparameter tuning bertujuan untuk mengoptimalkan kinerja model, hasilnya dalam kasus ini tidak menunjukkan perubahan yang signifikan. Beberapa model mengalami sedikit peningkatan dalam akurasi, tetapi beberapa model lain menunjukkan penurunan dalam metrik evaluasi utama. Hal ini menunjukkan bahwa, meskipun tuning parameter dapat memperbaiki performa model, perubahan yang terjadi dalam evaluasi ini tidak cukup signifikan untuk menunjukkan peningkatan besar dari baseline. Evaluasi ini menyoroti pentingnya penyesuaian parameter yang hati-hati dan pengujian lebih lanjut untuk memaksimalkan potensi model.

Dengan menggunakan fungsi GridSearch, model dapat menemukan parameter yang optimal untuk setiap algoritma yang digunakan. Berikut adalah daftar parameter optimal untuk masing-masing model untuk mendapatkan nilai Mean Squared Error (MSE) terbaik:

1. Random Forest
 - n_estimators : 50
 - max_depth : 10
 - min_samples_split : 2
 - min_samples_leaf : 1
 - MSE : 0.146094791
2. XGBoost
 - learning_rate : 0.1
 - n_estimators : 300
 - max_depth : 7
 - gamma : 0
 - subsample : 0.6
 - colsample_bytree : 0.6
3. Multiple Linear Regression
 - fit_intercept : TRUE
4. Adaboost
 - n_estimators : 200
 - learning_rate : 0.1



Gambar 12. Grafik Perbandingan Hasil Metrik Evaluasi tiap Model setelah dilakukan *Hyperparameter Tuning*

Tabel 5. Rekap Nilai MAE tiap Model pada Semua Kondisi

No	Nama Model	Kondisi	MAE
1	XG Boost	Baseline	0.1934
2	XG Boost	Hyperparameter Tuning	0.1935
3	Random Forest	Baseline	0.1963
4	Random Forest	Hyperparameter Tuning	0.2040
5	XG Boost	Feature Selection	0.3905
6	Adaboost	Baseline	0.4032
7	Adaboost	Hyperparameter Tuning	0.4039
8	Random Forest	Feature Selection	0.4168
9	Adaboost	Feature Selection	0.4358
10	Multiple Linear Regression	Feature Selection	0.5178
11	Multiple Linear Regression	Hyperparameter Tuning	0.5178
12	Multiple Linear Regression	Baseline	0.5179

D. Penentuan Model Terbaik

Model terbaik yang dipilih adalah XGBoost dalam kondisi baseline karena memiliki nilai MAE terkecil. Keempat model machine learning, terutama XGBoost dan Random Forest, memiliki potensi yang kuat untuk digunakan dalam memprediksi nilai impedansi berdasarkan data input berupa dimensi koil transformator karena menunjukkan kinerja prediksi yang bagus. Hal ini ditunjukkan dari XGBoost kondisi Baseline Model (dengan nilai semua parameter model adalah default) yang memiliki nilai metrik evaluasi tertinggi dengan nilai MAE sebesar 0,1934.

E. Hasil Pengujian Cross Validation

Pengujian menggunakan k-fold cross validation berfungsi untuk memastikan bahwa model dapat memberikan kinerja yang konsisten dan andal pada berbagai subset data, serta mengidentifikasi potensi overfitting yang mungkin terjadi pada data latihan.

Metode k-fold cross validation melibatkan pembagian dataset menjadi k subset yang disebut folds. Model dilatih pada k-1 fold dan diuji pada fold yang tersisa. Proses ini diulang k kali, dengan setiap fold digunakan sekali sebagai data uji dan sisanya sebagai data latih. Metrik evaluasi, seperti Mean Absolute Error (MAE), Mean Squared Error (MSE), dan R2S, dihitung untuk setiap fold. Hasil dari semua fold kemudian dirata-ratakan untuk memberikan gambaran tentang performa model secara keseluruhan dan memastikan bahwa model tidak overfit atau underfit pada data tertentu.

Hasil dari k-fold cross validation menunjukkan bahwa nilai metrik evaluasi untuk setiap fold relatif konsisten di seluruh fold. Jika nilai metrik, seperti MAE dan MSE, serta nilai R2S, tidak berbeda jauh di antara fold, ini menunjukkan bahwa model memiliki kinerja yang stabil dan dapat diandalkan pada berbagai subset data. Konsistensi ini mengindikasikan bahwa model dapat mengidentifikasi variabilitas data dengan baik pada data baru.

Tabel 6. Hasil K-Fold Cross Validation dari Model Random Forest pada Kondisi Baseline

Fold	MAE	MSE	R2S
1	0.188960	0.094405	0.976478
2	0.234668	0.224055	0.922108
3	0.198798	0.122075	0.966350
4	0.223487	0.185822	0.960132
5	0.221153	0.137239	0.962979
Mean	0.213413	0.152719	0.957609
Variance	0.000356	0.002691	0.000432
Std Deviation	0.018873	0.051875	0.020784

Tabel 7. Hasil K-Fold Cross Validation dari Model Random Forest pada Kondisi Hyperparameter Tuning

Fold	MAE	MSE	R2S
1	0.192089	0.098136	0.975549
2	0.250239	0.236465	0.917794
3	0.190056	0.111932	0.969146
4	0.239589	0.240981	0.948298
5	0.237381	0.163589	0.955871
Mean	0.221871	0.170220	0.953331
Variance	0.000815	0.004508	0.000510
Std Deviation	0.028541	0.067144	0.022574

Tabel 8. Hasil K-Fold Cross Validation dari Model XGBoost pada Kondisi Baseline

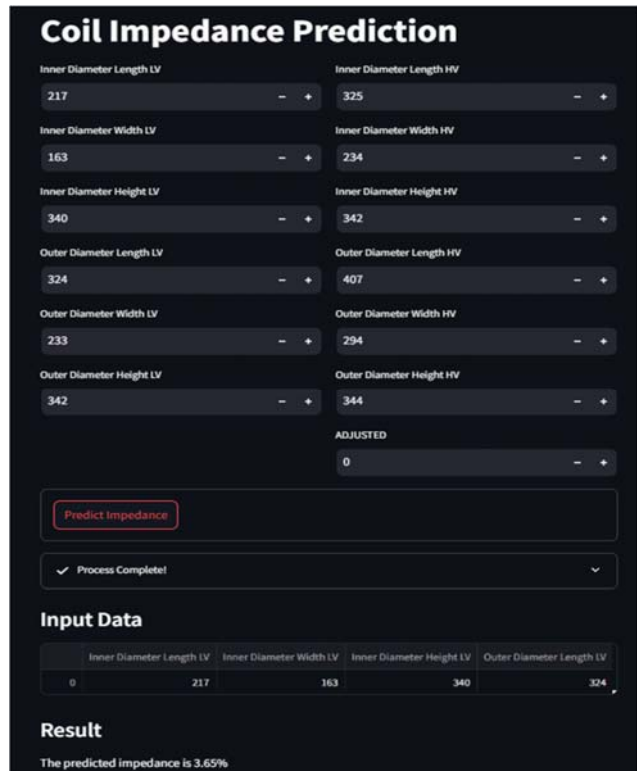
Fold	MAE	MSE	R2S
1	0.205345	0.102893	0.974364
2	0.225143	0.234839	0.918359
3	0.172565	0.083133	0.977084
4	0.190275	0.177963	0.961818
5	0.275626	0.303317	0.918179
Mean	0.213791	0.180429	0.949961
Variance	0.001569	0.008387	0.000870
Std Deviation	0.039612	0.091578	0.029498

Tabel 9. Hasil K-Fold Cross Validation dari Model XGBoost pada Kondisi Hyperparameter Tuning

Fold	MAE	MSE	R2S
1	0.178556	0.077840	0.980606
2	0.201365	0.179359	0.937647
3	0.156435	0.071587	0.980267
4	0.179093	0.143651	0.969180
5	0.216636	0.137035	0.963034
Mean	0.186417	0.121894	0.966147
Variance	0.000538	0.002119	0.000310
Std Deviation	0.023189	0.046034	0.017604

Analisis hasil k-fold cross validation mengungkapkan bahwa model yang diuji menunjukkan stabilitas yang baik jika nilai metrik evaluasi konsisten di seluruh fold. Jika terdapat perbedaan signifikan dalam metrik evaluasi antara fold, ini mungkin menunjukkan bahwa model terlalu bergantung pada karakteristik spesifik dari data latihan dan tidak dapat mengeneraliskan dengan baik. Oleh karena itu, konsistensi hasil di seluruh fold sangat penting untuk menilai keandalan.

F. Pengujian Aplikasi Website



Gambar 13. Halaman Koil Impedance Prediction

Pada halaman "coil impedance prediction", pengguna dapat memasukkan data input berupa dimensi koil transformer. Berdasarkan data input tersebut, aplikasi akan menggunakan model machine learning XGBoost, yang telah menghasilkan akurasi prediksi terbaik, untuk melakukan prediksi impedansi. Model ini telah dilatih menggunakan data impedansi dari periode awal 2023 hingga April 2024. Selain melakukan prediksi, aplikasi juga akan menganalisis pengaruh dari tiap parameter dimensi koil terhadap nilai impedansi.

IV. KESIMPULAN

Penelitian ini menunjukkan bahwa penggunaan model machine learning regresi berhasil memprediksi nilai impedansi berdasarkan dimensi koil transformator. Berdasarkan pelatihan dan validasi yang dilakukan menggunakan dataset dimensi koil dan dataset impedansi dari PT. X, ditemukan bahwa model XGBoost dan Random Forest menunjukkan performa terbaik. Model XGBoost, dalam kondisi Baseline Model dengan semua parameter default, menunjukkan nilai metrik evaluasi yang sangat baik dengan MAE sebesar 0,1935, MSE sebesar 0,1144, dan R2S sebesar 0,9657. Pengujian cross-validation untuk model XGBoost terbaik juga menunjukkan rata-rata skor yang mengesankan dengan Mean MAE sebesar 0,213791, Mean MSE sebesar 0,180429, dan Mean R2S sebesar 0,949961. Berdasarkan proses hyperparameter tuning yang dilakukan, diperoleh set parameter yang dapat mengoptimalkan kinerja keempat model dengan menggunakan metode grid search. Sistem yang didesain menggunakan model XGBoost dengan hasil akurasi terbaik mampu diimplementasikan pada aplikasi berbasis web. Aplikasi ini dapat memprediksi data input baru serta melakukan analisa grafik pengaruh setiap parameternya, memberikan alat yang efektif untuk penggunaan praktis dalam industri.

DAFTAR PUSTAKA

- [1] International Electrotechnical Commission., & International Electrotechnical Commission. Technical Committee 14. Power transformers. Part 1, General = Transformateurs de puissance. Partie 1, Généralités. International Electrotechnical Commission, 2011.
- [2] Dawood, K., Işık, F., & Kömürgöz, G. "Analysis and optimization of leakage impedance in a transformer with additional winding: A numerical and experimental study". *Alexandria Engineering Journal*, 61(12), 11291–11300, 2022. Available at: <https://doi.org/10.1016/j.aej.2022.05.014>
- [3] McLyman, C. W. T. *Transformer and inductor design handbook*. Marcel Dekker, 2004.
- [4] Mao, X., Wang, Z., Crossley, P., Jarman, P., Fieldsend-Roxborough, A., & Wilson, G. "Transformer winding type recognition based on FRA data and a support vector machine model". *High Voltage*, 5(6), 2020. Available at: <https://doi.org/10.1049/hve.2019.0294>
- [5] Valencia, F., Arcos, H., & Quilumba, F. "Comparison of Machine learning Algorithms for the Prediction of Mechanical Stress in Three-Phase Power Transformer Winding Conductors". *Journal of Electrical and Computer Engineering*, 2021. <https://doi.org/10.1155/2021/4657696>
- [6] Del Vecchio, R. M., Poulin, B., Feghali, P. T., Shah, D. M., & Ahuja, R. *Transformer Design Principles Third Edition*, 2018 .
- [7] Tumbelaka, Hanny Hosiana, TE4413: Mesin-Mesin Listrik - *Materi Transformer* [PDF]. Universitas Kristen Petra, 2023.
- [8] International Electrotechnical Commission.. IEC 60076-5: 2006 Power transformers – Part 5: Ability to withstand short circuit. Iec, 2006.
- [9] Murphy, K. P. "Machine learning: a probabilistic perspective (adaptive computation and machine learning series)". In *Mit Press*. ISBN (Vol. 621485037), 2012.
- [10] Dangeti, P. "Statistics for Machine learning: Techniques for exploring supervised, unsupervised, and reinforcement learning models with Python and R". In Packt Publishing, 2017.
- [11] Rath, S., Tripathy, A., & Tripathy, A. R., *Prediction of new active cases of coronavirus disease (COVID-19) pandemic using multiple linear regression model. Diabetes and Metabolic Syndrome: Clinical Research and Reviews*, 14(5), 2020. Available at: <https://doi.org/10.1016/j.dsx.2020.07.045>
- [12] Zhang, P., Jia, Y., & Shang, Y. "Research and application of XGBoost in imbalanced data". *International Journal of Distributed Sensor Networks*, 18(6), 2022. Available at: <https://doi.org/10.1177/15501329221106935>
- [13] Baturynska, I., & Martinsen, K. "Prediction of geometry deviations in additive manufactured parts: comparison of linear regression with machine learning algorithms". *Journal of Intelligent Manufacturing*, 32(1), 2021. Available at: <https://doi.org/10.1007/s10845-020-01567-0>
- [14] Gao, G., Wang, M., Huang, H., & Tang, W.. Agricultural "Irrigation Area Prediction based on Improved Random Forest Model". *Journal Research Square*, 34(32), 2021
- [15] Wang, Z., Zhang, J., & Verma, N. "Realizing Low-Energy Classification Systems by Implementing Matrix Multiplication Directly Within an ADC". *IEEE Transactions on Biomedical Circuits and Systems*, 9(6), 2021. Available at: <https://doi.org/10.1109/TBCAS.2015.2500101>