

Predictive Maintenance Trafo Distribusi Menggunakan Machine Learning untuk Meningkatkan Keakuratan Pengambilan Keputusan

Aulia Mahdi^{1*}, Erma Suryani²

Sekolah Interdisiplin Manajemen dan Teknologi, Indonesia^{1,2}

Email: Aulia.mahdi@gmail.com^{1*}

Abstrak

PT PLN (Persero) adalah BUMN yang bergerak di bidang ketenagalistrikan, dengan tugas memberikan pelayanan terbaik kepada pelanggan di seluruh Indonesia. Untuk menjaga kinerja keandalan distribusi, PLN mengukur kinerja menggunakan KPI seperti SAIDI, SAIFI, ENS, Gangguan Penyulang 20 kV, Kubikel, dan Trafo. Dalam upaya mengurangi gangguan pada Trafo Distribusi, PLN menerapkan pemeliharaan prediktif berbasis kondisi (*Condition Based Maintenance/CBM*). Namun, *Predictive Maintenance* yang diterapkan saat ini belum cukup efektif karena belum menggunakan alat ukur canggih, database inspeksi tidak dimanfaatkan dengan baik, dan pengambilan keputusan belum berbasis pendekatan ilmiah. Penelitian ini menggunakan *Machine Learning* untuk *Predictive Maintenance* Trafo Distribusi, dengan pemodelan Unsupervised Learning menggunakan *K-Means Clustering* untuk mengelompokkan aset trafo berdasarkan indikator kesehatannya. Hasil cluster ini digunakan untuk melatih model *Supervised Learning* dengan metode XGBoost, menghasilkan prediksi akurat terkait pemeliharaan trafo. Variabel input dalam penelitian ini meliputi usia trafo, suhu, pembebanan, dan ketidakseimbangan beban trafo. Dari pengolahan data 2709 Trafo, diperoleh klasifikasi tingkat keandalan dalam 4 kelas: Trafo Sehat (46,99%), Beban Tinggi dan Rawan Gangguan (30,53%), Tua dan Rawan Gangguan (17,53%), serta Trafo Losses (4,95%). Model ini memiliki akurasi 97%, precision 92-97%, dan recall 95-98%, dengan efisiensi biaya 80,88%.

Kata Kunci: *Predictive Maintenance*, Trafo Distribusi, *Machine Learning*, *K-Means Clustering*, *Extreme Gradient Boosting* (XGBoost), *Benefit Cost Analysis*.

ABSTRACT

PT PLN (Persero) is a state-owned enterprise in the electricity sector, tasked with providing the best service to customers across Indonesia. To maintain distribution reliability, PLN measures performance using KPIs such as SAIDI, SAIFI, ENS, 20 kV feeder faults, cubicle faults, and transformer faults. In an effort to reduce distribution transformer faults, PLN implements Condition-Based Maintenance (CBM). However, the current Predictive Maintenance is not fully effective due to the lack of advanced measuring tools, underutilization of inspection databases, and decision-making not being based on a scientific approach. This study uses Machine Learning for Predictive Maintenance of Distribution Transformers, with an Unsupervised Learning model using K-Means Clustering to group transformer assets based on their health indicators. The resulting clusters are then used to train a Supervised Learning model with the XGBoost method, producing accurate predictions for transformer maintenance. The input variables in this study include transformer age, temperature, load, and load imbalance. After processing data from 2709 transformers, the reliability classification was divided into four categories: Healthy Transformers (46.99%), High Load and Prone to Failure (30.53%), Old and Prone to Failure (17.53%), and Loss Transformers (4.95%). The model achieved an accuracy of 97%, precision of 92-97%, and recall of 95-98%, with a cost efficiency of 80.88%.

Keywords: *predictive maintenance*, *distribution transformer*, *machine learning*, *k-means clustering*, *extreme gradient boosting* (xgboost), *benefit cost analysis*.

Pendahuluan

Industri ketenagalistrikan di seluruh penjuru dunia memegang peranan penting dalam keberlangsungan perekonomian di suatu negara. Tidak berbeda dengan di Indonesia, industri ketenagalistrikan dipegang oleh BUMN yaitu PT PLN (Persero) yang selain bertugas untuk mencari keuntungan, juga memiliki tugas sebagai *public service obligation* dengan memberikan pelayanan yang terbaik kepada pelanggan di seluruh pelosok negeri. PLN sendiri dalam operasinya terbagi dalam 3 fungsi yaitu Pembangkit, Transmisi dan Distribusi. Setelah adanya reorganisasi struktur PLN, unit pembangkit saat ini dikelola oleh *sub holding* PLN, sedangkan unit transmisi dan distribusi dikelola langsung oleh PLN *holding*. Perbedaan bidang transmisi dan distribusi adalah bidang transmisi mengelola sistem Tegangan Ekstra Tinggi (TET) 500 kV hingga Tegangan Tinggi (TT) 150 kV dan 70 kV, sedangkan bidang distribusi mengelola Tegangan Menengah (TM) 20 kV hingga Tegangan Rendah (TR) 220 V. Salah 1 unit distribusi yang ada di PLN yaitu Unit Induk Distribusi (UID) Banten, yang membawahi 6 Unit Pelaksana Pelayanan Pelanggan atau disingkat UP3 dan 1 Unit Pelaksana Pengatur Distribusi atau disingkat UP2D, serta 9 Unit Layanan Pelanggan (ULP).

UP2D Banten dalam proses bisnisnya harus mendukung kinerja keandalan operasi antara lain menurunkan SAIDI (*System Average Interruption Duration Index*) dan SAIFI (*System Average Interruption Frequency Index*) (Honarmand, 2015), menurunkan ENS (*Energy Not Served*), menurunkan gangguan penyulang 20 kV, menurunkan gangguan kubikel serta menurunkan gangguan Trafo Distribusi. Dalam penelitian ini difokuskan dalam pengelolaan Trafo Distribusi yang terkait kepada 4 kinerja keandalan operasi seperti dijelaskan sebelumnya yaitu SAIDI, SAIFI, ENS dan gangguan Trafo Distribusi. Dengan mencegah terjadinya gangguan Trafo Distribusi, maka secara tidak langsung akan mengurangi frekuensi gangguan per pelanggan (SAIFI), mengurangi durasi padam gangguan per pelanggan (SAIDI), serta mengurangi energi tak tersalurkan (ENS) yang mengakibatkan berkurangnya penjualan PLN.

Strategi pemeliharaan ada beberapa tipe yaitu pemeliharaan penggantian, pemeliharaan korektif atau perbaikan, pemeliharaan preventif yang terbagi menjadi pemeliharaan berbasis kondisi dan pemeliharaan prediktif (Fitriyan & Syairudin, 2016; Sodikin & Jati, 2022). Menurut Edaran Direksi PT PLN (Persero) No: 0017.E/DIR/2014 mengenai Metode Pemeliharaan Trafo Distribusi berbasis Kaidah Manajemen Aset, pengelolaan pemeliharaan aset operasi di PLN juga mengikuti pola tersebut yaitu *Breakdown Maintenance* yaitu penggantian aset operasi setelah usia ekonomisnya habis yang ditandai dengan gangguan, *planned maintenance* yaitu pemeliharaan aset operasi terencana untuk mencegah terjadinya gangguan dengan berbasis waktu atau disebut *Time-Based Maintenance*, *Preventive Maintenance* yaitu pemeliharaan pencegahan terhadap aset operasi yang berbasis pada kondisi atau disebut juga *Condition-Based Maintenance*. Menurut Moleda et al. (2023), *Predictive Maintenance* adalah tipe pemeliharaan CBM yang memprediksi kinerja peralatan masa depan berdasarkan indikator saat ini dan indikator dari data historis. *Predictive Maintenance* berbasis kondisi tersebut menjadi metode pemeliharaan yang ingin dituju PLN saat ini, yang pada prakteknya masih belum berjalan dengan sempurna.

Keberhasilan *Predictive Maintenance* berbasis kondisi ini didapatkan dari aktivitas pendahuluan berupa inspeksi gardu. Inspeksi gardu yang ideal adalah menggunakan peralatan ukur atau sensor yang canggih sehingga didapatkan parameter hasil inspeksi yang valid dan akurat yang dapat berguna untuk parameterisasi *Health Index* Trafo Distribusi (Tran et al., 2020). Selain belum efektifnya inspeksi gardu akibat belum semuanya dilakukan dengan peralatan memadai, terdapat masalah lain yaitu parameter hasil inspeksi gardu belum dimanfaatkan dengan baik di dalam aplikasi aset manajemen PLN yang dalam penelitian ini merujuk pada aplikasi Master Jardi (Jaringan Distribusi). Database pemeliharaan hanyalah sebagai media penyimpanan, namun tidak digunakan untuk bahan analisis yang semestinya,

sehingga beberapa keputusan operasi tidak akurat. Misalkan mengenai keputusan operasi apakah trafo tersebut perlu dilakukan pemeliharaan serta level urgensi pelaksanaan pemeliharaannya. Keputusan lainnya adalah apakah pemeliharaan tersebut efektif untuk aset yang memang sudah sekiranya layak dilakukan penggantian baru dikarenakan memiliki probabilitas tinggi terjadinya gangguan. Keputusan operasi yang salah bisa mengakibatkan terjadinya gangguan trafo yang seharusnya bisa diprediksi dan dicegah, sehingga apabila terjadi gangguan trafo, maka PLN akan menanggung beban ENS yang mengurangi penjualan PLN dan berdampak pada buruknya pelayanan kepada pelanggan. Keputusan yang tidak tepat juga berdampak pada *Cost Efficiency* anggaran operasi, yang seharusnya mempertimbangkan dengan tepat mana trafo yang tidak perlu dipelihara, mana trafo yang wajib dipelihara, mana trafo yang wajib dilakukan penggantian baru dan mana trafo yang masih dalam kondisi layak pakai.

Predictive Maintenance pada Trafo Distribusi membutuhkan beberapa indikator yang didapatkan dari inspeksi rutin periode 3 atau 6 bulanan. Beberapa indikator yang didapatkan dari inspeksi ini adalah identitas asset (nama Gardu Distribusi, Unit PLN yang menaungi, alamat), no seri Trafo, tahun pembuatan Trafo, jenis Trafo, kapasitas Trafo (kVA), dan hasil ukur berupa suhu Trafo (body Trafo, bushing TM, bushing TR dalam °C), tegangan output Trafo (220 VAC), arus/beban Trafo (fase R, S, T dalam Ampere), serta hasil inspeksi visual berupa kondisi body Trafo normal atau tidak (Setiawan, 2022), kondisi minyak Trafo bocor atau tidak yang mempengaruhi kondisi isolasi minyak Trafo yang diukur dalam *Break Down Voltage* (BDV) (Sutaryono, 2015), kondisi packing Trafo (retak atau tidak) dan suara Trafo (dengung atau tidak) dimana menurut IEEE (*Institute of Electrical and Electronics Engineers*) standar dengung yang memiliki *health index* baik untuk trafo 7 power 50 adalah 39-42 dB. Beberapa indikator yang dipilih dalam penelitian ini adalah pertama Suhu Trafo, dengan parameter suhu rendah menggambarkan *health index* yang baik dan suhu tinggi menggambarkan *health index* yang buruk (Ballal et al., 2017; Nelson et al., 2014). Yang kedua adalah Umur Trafo, dengan pertimbangan semakin meningkatnya umur operasi sebuah trafo, maka *health index* dari sebuah trafo tersebut akan mengalami penurunan dan trafo baru mempunyai umur yang dapat diandalkan sekitar 15-30 tahun dan untuk trafo servis sekitar 15-20 tahun (Tamma et al., 2021). Yang ketiga adalah Persentase Beban Trafo, dengan pertimbangan bahwa menurut Sukadana, dkk (2021), gangguan yang terjadi ketika beban transformator mencapai 90% ke atas adalah 80% lebih banyak dibandingkan ketika beban transformator berada di kisaran 50-60%. Yang keempat adalah Persentase Ketidakseimbangan Beban Trafo, dengan pertimbangan bahwa status operasi trafo distribusi yang tidak seimbang akan mempengaruhi umur trafo dan menambah rugi-rugi trafo selain serangkaian masalah seperti penurunan tegangan jaringan, kedipan, faktor daya rendah, dan rugi-rugi saluran meningkat (Pan et al., 2019).

Beberapa penelitian terkait *Predictive Maintenance* Trafo atau *Fault Prediction* Trafo telah dilakukan oleh beberapa peneliti sebelumnya. Dalam penelitian Vasiliki Vita et al. (2023), *Artificial Intelligence* (AI) diterapkan untuk memperkirakan pemeliharaan yang diperlukan untuk Trafo Distribusi dengan mengevaluasi kondisi Trafo yang digunakan dan memprediksi kapan waktu pemeliharaannya yang akan dilakukan. Strategi ini menjanjikan pengurangan biaya dibandingkan pemeliharaan preventif rutin atau berbasis waktu, karena pemeliharaan hanya dilakukan bila diperlukan. Metodologi yang digunakan adalah model prediksi *clustering K-means* untuk pengelompokan trafo berdasarkan *health index* yang dilanjutkan dengan metode klasifikasi menggunakan SVM (*Support Vector Machine*) untuk mengidentifikasi dengan akurasi tinggi jumlah transformator yang beresiko terjadi gangguan. Dalam penelitian ini terbukti bahwa metode *Machine Learning* (ML) untuk deteksi dini masalah teknis dapat membantu operator sistem distribusi meningkatkan jumlah trafo yang dipilih sebagai target prioritas untuk pemeliharaan prediktif. Keberhasilan pemeliharaan prediktif ini akan

meningkatkan keandalan kinerja trafo distribusi yang akan bermanfaat bagi kepuasan pelanggan. Menurut prediksi gangguan trafo pada tahun 2021, terdapat 852 trafo akan mengalami kegagalan fungsi, dengan 820 trafo berada di pedesaan Cauca, sesuai dengan statistik kegagalan sebelumnya, dengan prediksi Trafo 10 kVA akan menjadi yang paling rentan, diikuti oleh 5 kVA, trafo kVA dan 15 kVA.

Penelitian lain terkait pemeliharaan prediktif Trafo Distribusi adalah terkait evaluasi kesehatan dan keandalannya menggunakan *Machine Learning*. Dalam penelitian Zhikai Xing et al., (2023), evaluasi kesehatan merupakan metode yang efektif untuk mendeteksi kondisi kesehatan trafo daya. Penelitian yang dilakukan menggunakan *Deep Learning Neural Network* (DLNN) untuk mendeteksi *Health Evaluation* (HE) suatu trafo daya. Tahap pertama, *Echo State Network* (ESN) menghasilkan data yang terkait dengan data asli untuk penyelesaian masalah sampel kecil. Tahap berikutnya, fitur-fitur penting diekstraksi oleh DLNN yang berisi *Improved Deep Residual Shrinkage Networks* (IDRSN) dan *One-Dimension Convolution Neural Network* (1DCNN). Terakhir, status kesehatan trafo daya diperoleh dari lapisan Concat dan lapisan Softmax. Hasil DLNN akan diverifikasi oleh dataset *Dissolved Gas Analysis* (DGA) dari data real trafo daya. Hasil percobaan ini memberikan kesimpulan bahwa metode yang diusulkan memperoleh kinerja yang lebih baik daripada metode *Neural Network* terbaru dan metode *health assessment* trafo daya.

Pada penelitian ini diusulkan penggunaan *Machine Learning* dalam pelaksanaan proses bisnis *Predictive Maintenance* Trafo Distribusi di lingkungan PT PLN (Persero) UID Banten dan UID Jakarta Raya. Perbedaan penelitian ini dibandingkan dengan penelitian sebelumnya adalah penggunaan 2 tahap *Machine Learning* dalam pembuatan model. Metode *Machine Learning* tahap pertama yang akan digunakan adalah *K-means Clustering* yang bertujuan untuk memetakan cluster trafo berdasarkan kondisi kesehatannya, dan menganalisa grup cluster yang memiliki probabilitas tinggi terjadinya gangguan trafo. Selanjutnya hasil cluster menjadi label untuk tahap dua yaitu klasifikasi menggunakan *Extreme Gradient Boosting* (XGBoost) untuk mendapatkan prediksi yang akurat mengenai target operasi pemeliharaan ataupun penggantian aset baru. Klasifikasi XGBoost digunakan di penelitian ini karena algoritma ini merupakan salah satu algoritma pembelajaran mesin yang paling populer dan banyak digunakan dalam berbagai kompetisi dan proyek-proyek di kehidupan nyata (J. Li et al., 2022; M. Li et al., 2020; W. Li et al., 2019; Mitchell & Frank, 2017). Algoritma ini sendiri mulai populer sekitar tahun 2016, ketika Tianqi Chen dan Carlos Guestrin mempublikasikan makalah mereka tentang XGBoost: Sistem Pendorong Pohon yang Dapat Diskalakan. Penggunaan *Machine Learning* 2 tahap dan menggunakan klasifikasi XGBoost ini belum pernah dilakukan dalam proses bisnis *Predictive Maintenance* Trafo Distribusi sebelumnya, sehingga diharapkan dapat memberikan kontribusi yang signifikan dalam pengembangan model prediktif yang lebih akurat dalam proses bisnis ketenagalistrikan dalam hal ini di PLN.

Metode Penelitian

Penelitian ini bertujuan mengimplementasikan dan mengevaluasi penerapan *machine learning* dalam *predictive maintenance* trafo distribusi. Proses dimulai dengan pengumpulan data melalui aplikasi Master Jardis dan wawancara dengan teknisi PLN, mencakup data operasional, pemeliharaan, dan kondisi lingkungan trafo. Data yang terkumpul kemudian diproses dengan langkah-langkah *pre-processing* seperti pembersihan, transformasi, dan normalisasi, sebelum digunakan dalam analisis berbasis *machine learning*. Tahap *clustering* menggunakan *K-Means* untuk mengelompokkan data trafo berdasarkan karakteristik operasional, diikuti dengan klasifikasi menggunakan *XGBoost* untuk memprediksi risiko kegagalan trafo. Hasil klasifikasi digunakan untuk merancang strategi pemeliharaan preventif dan penggantian komponen, dengan tujuan mengoptimalkan kinerja operasional dan memperpanjang masa pakai trafo.

Evaluasi dilakukan melalui metode *Elbow* dan *Silhouette* untuk *clustering*, serta *confusion matrix*, akurasi, precision, recall, dan AUC untuk klasifikasi, guna menilai efektivitas model dalam memprediksi kegagalan trafo. Analisis *Benefit-Cost* (BCA) diterapkan untuk mengevaluasi efisiensi biaya dari metode pemeliharaan berbasis *machine learning* dibandingkan dengan jadwal tetap, dengan fokus pada optimasi penggantian trafo, pemerataan beban, dan pengurangan biaya inspeksi. Hasil penelitian menunjukkan peningkatan keandalan sistem distribusi dan efisiensi operasional. Rekomendasi untuk implementasi praktis mencakup integrasi model dalam prosedur pemeliharaan, penggunaan data real-time untuk pembaruan model, serta pelatihan untuk teknisi untuk memaksimalkan penerapan model *predictive maintenance*.


Hasil Dan Pembahasan

Analisis Deskriptif

1. Sebaran Data dan Distribusi Data

Variabel yang akan dianalisis distribusi data nya adalah suhu, persen beban trafo dan persen ketidakseimbangan beban trafo.

a. Suhu



Gambar 1. Distribusi Suhu Trafo

Gambar 1 ini merupakan histogram yang menggambarkan distribusi frekuensi suhu trafo. Selain histogram, terdapat kurva *density* (dalam warna biru yang halus) yang menggambarkan perkiraan distribusi data suhu dalam bentuk kontinu.


Intepretasi Visualisasi:

- 1) Dari bentuk histogram ini, distribusi suhu trafo terlihat mendekati distribusi normal (kurva berbentuk lonceng).
- 2) Rentang suhu yang diamati berkisar dari sekitar 10°C hingga 90°C, dengan puncak distribusi terjadi di sekitar 40°C hingga 50°C.
- 3) Frekuensi tertinggi (sekitar 700-800 kali) terjadi pada suhu sekitar 40°C. Ini berarti suhu trafo paling sering berada pada kisaran tersebut.
- 4) Sifat distribusi ini cukup simetris di sekitar pusatnya, namun sedikit lebih lebar di sisi kanan, menunjukkan ada beberapa pengamatan suhu yang lebih tinggi di atas 50°C.

- 5) Suhu trafo yang paling umum berada di sekitar 40°C hingga 50°C. Sebagian besar trafo beroperasi pada suhu yang relatif stabil di sekitar kisaran ini, dengan beberapa suhu ekstrem yang lebih rendah atau lebih tinggi. Grafik ini dapat digunakan untuk menganalisis apakah suhu trafo berada dalam batas operasi yang aman atau jika ada suhu yang terlalu ekstrem yang mungkin memerlukan perhatian lebih lanjut dalam konteks pemeliharaan atau operasi trafo.

b. Persentase Ketidakseimbangan

Gambar 2 menjelaskan grafik distribusi persentase ketidakseimbangan karakteristik *positively skewed* (miring ke kanan), yang artinya sebagian besar data berada di nilai yang lebih rendah dengan ekor yang memanjang ke arah nilai yang lebih besar. Secara umum menunjukkan bahwa mayoritas sistem memiliki tingkat ketidakseimbangan yang sangat rendah, namun ada beberapa kasus dengan ketidakseimbangan lebih tinggi yang bisa memerlukan penanganan. Ini membantu dalam mengidentifikasi kapan dan di mana sistem mungkin perlu diperbaiki atau dioptimalkan untuk mengurangi risiko operasional.



Gambar 2. Distribusi Persentase Ketidakseimbangan


Intepretasi visual:

- 1) Grafik ini menunjukkan bahwa sebagian besar persentase ketidakseimbangan berada pada angka yang rendah (di bawah 2%).
- 2) Frekuensi Tertinggi: Nilai persentase ketidakseimbangan yang paling umum berada di sekitar 0% hingga 1%, dengan frekuensi tertinggi mendekati 1200.
- 3) Hal ini menunjukkan bahwa pada mayoritas kasus, sistem atau parameter yang diukur memiliki tingkat ketidakseimbangan yang sangat rendah.
- 4) Ekstrem Ketidakseimbangan: Sebagian kecil data menunjukkan ketidakseimbangan yang lebih tinggi, dengan nilai di atas 2%. Namun, frekuensinya menurun drastis setelah 2%, dan hampir tidak ada kasus ketidakseimbangan di atas 4%.
- 5) Ini mungkin menunjukkan bahwa situasi di mana ketidakseimbangan tinggi (di atas 4% atau 5%) adalah kasus-kasus jarang yang memerlukan perhatian khusus atau perbaikan.

- 6) Pemaknaan Ketidakseimbangan: Dalam konteks persentase ketidakseimbangan, bisa jadi ini merujuk pada ketidakseimbangan beban listrik, ketidakseimbangan input-output, atau ketidakseimbangan parameter operasional lain yang dimonitor.
- 7) Nilai yang rendah berarti sistem berjalan dengan baik atau dalam batas toleransi yang diizinkan, sementara nilai yang lebih tinggi dapat menjadi indikator masalah yang perlu diperbaiki.
- 8) Analisis Risiko: Dari grafik ini, terlihat bahwa sebagian besar pengamatan berada pada ketidakseimbangan yang sangat kecil. Ini menunjukkan bahwa sistem secara umum stabil.
- 9) Namun, ekor panjang ke kanan memperingatkan bahwa ada beberapa kasus dengan tingkat ketidakseimbangan lebih tinggi yang bisa menjadi outlier dan memerlukan analisis lebih lanjut atau pemeliharaan preventif.
- 10) Rekomendasi Pemantauan: Jika persentase ketidakseimbangan terus dipantau dari waktu ke waktu, histogram ini bisa membantu dalam menganalisis pola dan tren ketidakseimbangan. Jika jumlah kasus ketidakseimbangan yang tinggi meningkat, mungkin diperlukan tindakan korektif seperti menyeimbangkan kembali beban atau memperbaiki sistem distribusi.
- 11) Persentase ketidakseimbangan ini bisa diterapkan pada berbagai skenario, seperti ketidakseimbangan tegangan listrik di trafo, distribusi beban dalam sistem mekanis, atau bahkan ketidakseimbangan dalam proses produksi. Mengidentifikasi dan meminimalkan ketidakseimbangan membantu meningkatkan efisiensi operasional dan mencegah kerusakan.

c. Persen Beban

Gambar 3 berisi histogram distribusi persen beban, dengan frekuensi pada sumbu vertikal (y) dan persen beban pada sumbu horizontal (x). Berikut adalah penjelasan mendetail mengenai grafik ini:



Gambar 3. Distribusi Persen Beban

Distribusi yang diamati dalam data ini cenderung mendekati distribusi normal berbentuk lonceng, dengan puncak distribusi berada di sekitar 0% pada sumbu horizontal. Nilai persentase beban yang tercatat berkisar antara -2% hingga 5%, dengan frekuensi tertinggi berada di sekitar 0%. Hal ini menunjukkan bahwa sebagian besar data berada dalam rentang nilai yang mendekati 0% beban. Titik dengan frekuensi tertinggi, yaitu

sekitar 300 pengamatan pada 0% beban, mengindikasikan bahwa beban sistem atau objek yang dianalisis sering kali berada dalam keadaan seimbang atau netral.

Dari sisi penyebaran data, di sisi kiri terdapat sedikit pengamatan yang menunjukkan beban negatif, yakni antara -2% hingga 0%, yang berarti ada sebagian kecil kondisi sistem yang mengalami pengurangan beban. Sementara itu, di sisi kanan terdapat data dengan beban positif hingga 5%, namun frekuensinya semakin menurun setelah 1%, yang menandakan bahwa beban yang lebih besar jarang terjadi. Nilai negatif (antara -2% dan 0%) mungkin menandakan adanya defisit beban atau pengurangan beban dalam sistem, yang kemungkinan disebabkan oleh *underutilization* atau penggunaan yang kurang maksimal. Sebaliknya, nilai positif (antara 0% hingga 5%) menandakan adanya peningkatan beban atau penggunaan berlebih dalam sistem, dengan beban di atas 1% yang jarang terjadi, serta nilai ekstrem di atas 3% yang hampir tidak terlihat.

Meskipun distribusinya menyerupai bentuk normal, terdapat sedikit *skewness* positif atau kemiringan ke kanan, yang menunjukkan adanya beberapa pengamatan dengan beban lebih tinggi dibandingkan pengamatan dengan beban rendah. Hal ini juga mengindikasikan bahwa dalam beberapa kasus, sistem mungkin mengalami peningkatan beban mendadak yang melampaui nilai 0%. Distribusi ini secara umum menunjukkan bahwa sebagian besar sistem berada pada kondisi beban seimbang atau mendekati netral di sekitar 0%. Kasus-kasus beban yang lebih tinggi dari 1% jarang terjadi dan dapat dianggap sebagai outlier yang memerlukan perhatian khusus, terutama jika terjadi secara berulang atau dalam frekuensi tinggi. Beban yang terlalu rendah atau negatif bisa menjadi indikasi adanya *underutilization*, sedangkan beban yang terlalu tinggi bisa menjadi tanda adanya *overload* yang memerlukan penanganan. Grafik ini secara keseluruhan menggambarkan bahwa dalam banyak kasus, sistem berada dalam kondisi beban yang mendekati netral, dengan hanya sedikit pengamatan pada kondisi beban yang sangat rendah atau sangat tinggi. Hal ini dapat menjadi indikator bahwa sistem secara umum berfungsi dengan baik dan stabil.

d. Pengukuran Tendensi Sentral

Pengukuran tendensi sentral memiliki peran penting dalam *predictive maintenance* trafo, karena membantu dalam memahami kondisi rata-rata dari berbagai parameter operasional trafo, seperti suhu, beban, dan efisiensi (Susilawati & Dharmawansyah, 2019; Tjalla, n.d.). Mean dapat memberikan gambaran umum tentang kondisi rata-rata trafo dan mendeteksi perubahan signifikan dari performa normal, yang dapat mengindikasikan potensi masalah. Median sangat berguna untuk menghindari pengaruh nilai ekstrem yang mungkin terjadi, seperti lonjakan suhu atau beban yang tidak normal, sehingga dapat memberikan nilai yang lebih representatif untuk kondisi normal trafo. Mode dapat menunjukkan pola atau masalah yang sering terjadi, misalnya ketidakseimbangan beban yang sering terjadi pada sejumlah trafo.

Dengan menggunakan pengukuran tendensi sentral, tim pemeliharaan dapat lebih mudah memantau performa trafo, mendeteksi anomali lebih cepat, dan merencanakan tindakan perawatan yang lebih efektif. Misalnya, jika mean suhu trafo lebih tinggi dari biasanya, ini bisa menjadi indikasi adanya potensi masalah. Jika median beban trafo lebih tinggi atau lebih rendah dari nilai normal, tindakan koreksi bisa segera dilakukan. Secara keseluruhan, pengukuran ini memberikan wawasan yang lebih jelas untuk mengoptimalkan strategi perawatan preventif dan mengurangi risiko kerusakan yang tidak terdeteksi.

	No	kapasitas	thn_pembuatan	Ir	Is	It	In	persen_beban	Persentase_ketidakseimbangan	Suhu_Trafo	Tanggal_Inspeksi
count	2708.000000	2708.000000	2708.000000	2708.000000	2708.000000	2708.000000	2708.000000	2708.000000	2708.000000	2708.000000	2708
mean	1354.630724	472.745569	2010.36743	231.902142	225.793575	240.285820	111.199040	0.332114	0.170052	47.296411	2023-12-25 07:59:38.729689600
min	1.000000	50.000000	1972.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	2023-09-01 00:00:00
25%	677.750000	400.000000	2006.000000	109.000000	107.000000	117.000000	58.000000	0.184488	0.070000	41.000000	2023-11-20 00:00:00
50%	1354.500000	400.000000	2012.000000	206.500000	201.500000	217.000000	101.000000	0.313383	0.121212	46.000000	2023-12-27 00:00:00
75%	2031.250000	630.000000	2017.000000	329.000000	316.250000	334.250000	152.000000	0.466222	0.208185	52.000000	2024-02-02 00:00:00
max	2709.000000	1000.000000	2023.000000	991.000000	1022.000000	1127.000000	569.000000	1.273843	2.000000	106.400000	2024-03-21 00:00:00
std	782.073495	150.992483	9.58622	160.679676	158.346678	164.503126	74.439235	0.197026	0.178044	8.741086	NaN

Gambar 4. Tendensi Sentral

Gambar yang ditampilkan merupakan ringkasan statistik deskriptif dari sebuah dataset, yang biasanya dihasilkan menggunakan fungsi seperti *describe()* dalam Python, khususnya dengan pustaka *pandas*. Setiap kolom pada tabel memiliki nama yang merepresentasikan jenis data tertentu, seperti No, kapasitas, thn_pembuatan, Ir, Is, It, In, persen_beban, Persentase_ketidakseimbangan, Suhu_Trafo, dan Tanggal_Inspeksi. Baris-baris statistik meliputi count (jumlah data valid), mean (rata-rata), std (standar deviasi), min (nilai minimum), 25% (kuartil pertama), 50% (median), 75% (kuartil ketiga), dan max (nilai maksimum). Misalnya, kolom kapasitas menunjukkan rata-rata sebesar 472 dengan standar deviasi 150, dan nilai berkisar antara 50 hingga 1000. Kolom thn_pembuatan tampak berisi data tahun, mulai dari 1972 hingga 2023. Pada kolom persen_beban, beban rata-rata adalah 33,2% dengan maksimum 56,9%. Kolom Tanggal_Inspeksi merupakan data bertipe waktu sehingga statistik deskriptif numerik kurang relevan untuk dianalisis langsung. Suhu trafo berkisar antara 41°C hingga 52°C, dengan rata-rata 47,3°C, namun terdapat nilai ekstrem sebesar 106°C yang kemungkinan merupakan outlier dan perlu diselidiki lebih lanjut. Sementara itu, Persentase Ketidakseimbangan menunjukkan bahwa sebagian besar nilai berada di bawah 28,2%, dengan rata-rata 17% dan median 12,1%. Nilai maksimum mencapai 200%, yang sangat tinggi dan berpotensi merupakan outlier akibat kondisi ekstrem atau kesalahan input data. Distribusi data ini juga mengindikasikan kemungkinan skewness ke kanan (positif), di mana sebagian kecil data memiliki nilai sangat tinggi.

Exploratory Data Analysis (EDA)

1. Analisis Korelasi Pearson

Analisis korelasi Pearson digunakan untuk mengukur hubungan antara variabel-variabel seperti persentase beban, ketidakseimbangan, suhu transformator, dan usia transformator. Nilai korelasi yang berkisar antara -1 hingga 1 menunjukkan kekuatan hubungan antar variabel. Nilai mendekati 1 menunjukkan hubungan positif yang kuat, nilai mendekati -1 menunjukkan hubungan negatif yang kuat, dan nilai mendekati 0 menunjukkan tidak ada hubungan linear yang signifikan. Hasil analisis korelasi menunjukkan bahwa: 1) Persentase Beban vs. Persentase Ketidakseimbangan memiliki korelasi negatif moderat (-0,37), yang menunjukkan bahwa semakin tinggi beban, ketidakseimbangan distribusi cenderung menurun. 2) Persentase Beban vs. Suhu Transformator memiliki korelasi positif moderat (0,5), yang menunjukkan bahwa beban yang lebih tinggi cenderung meningkatkan suhu transformator. 3) Persentase Beban vs. Usia Transformator menunjukkan korelasi positif yang sangat lemah (0,079), yang mengindikasikan bahwa usia transformator hampir tidak mempengaruhi variasi beban yang diterima oleh transformator. 4) Persentase Ketidakseimbangan vs. Suhu Transformator memiliki korelasi negatif lemah (-0,2), menunjukkan bahwa ketidakseimbangan yang lebih tinggi sedikit menurunkan suhu transformator. 5) Persentase Ketidakseimbangan vs. Usia Transformator menunjukkan korelasi negatif yang sangat lemah (-0,057), yang berarti tidak ada hubungan yang signifikan. 6) Suhu Transformator vs. Usia Transformator menunjukkan

korelasi positif lemah (0,32), yang mengindikasikan bahwa suhu transformator cenderung meningkat seiring bertambahnya usia transformator, kemungkinan karena penurunan efisiensi dan degradasi material.

2. Analisis Outlier

Outlier adalah data yang menyimpang jauh dari pola umum dalam dataset dan dapat menunjukkan **anomali** atau kesalahan pengukuran. Dalam penelitian ini, analisis outlier dilakukan pada variabel seperti persentase beban, ketidakseimbangan, suhu, dan usia transformator untuk memantau kinerja dan kesehatan trafo distribusi. 1) Persentase Beban vs. Suhu Transformator: Ketika beban pada transformator meningkat, arus yang mengalir juga meningkat, yang menyebabkan kenaikan suhu. Outlier pada suhu berdasarkan beban membantu mengidentifikasi apakah suhu tetap dalam batas aman. 2) Ketidakseimbangan Beban vs. Suhu Transformator: Ketidakseimbangan beban dapat menyebabkan distribusi arus yang tidak merata, yang berpotensi meningkatkan suhu transformator. Menganalisis outlier pada suhu berdasarkan ketidakseimbangan dapat membantu mendeteksi kondisi yang berisiko. 3) Usia Transformator vs. Suhu Transformator: Semakin tua transformator, efisiensinya dapat menurun, yang menyebabkan peningkatan suhu pada beban tertentu. Outlier suhu berdasarkan usia membantu mengidentifikasi kondisi abnormal yang memerlukan perhatian. Analisis ini penting untuk memantau kondisi operasional trafo, mengidentifikasi anomali, dan mencegah kerusakan prematur pada transformator.

3. Feature Engineering

Feature engineering adalah proses yang dilakukan dalam analisis data dan pembangunan model prediktif di mana Anda membuat atau mengekstraksi fitur-fitur baru dari data mentah untuk meningkatkan kinerja model. Fitur-fitur ini adalah variabel yang digunakan oleh model untuk membuat prediksi atau memahami hubungan antara variabel input dan output. Proses *feature engineering* sangat penting karena kualitas dan relevansi fitur-fitur yang digunakan dapat memiliki dampak yang signifikan terhadap kualitas model prediktif.

4. Clustering

Metode *Elbow* dan evaluasi kinerja menggunakan *Silhouette Score*. *Elbow Method* digunakan untuk menentukan jumlah cluster optimal dalam algoritma *K-Means Clustering* dengan menghitung *Within-Cluster Sum of Squares* (WCSS). Dari hasil analisis, titik siku (*elbow point*) kemungkinan berada di jumlah cluster 3 atau 4, yang menunjukkan bahwa jumlah cluster optimal berada di rentang tersebut. Setelah itu, evaluasi lebih lanjut dilakukan dengan metode *Silhouette Score* untuk mengukur kualitas pengelompokan. Hasil analisis menunjukkan bahwa *clustering* dengan 3 cluster memiliki *Silhouette Score* sebesar 0.288, sementara *clustering* dengan 4 cluster menghasilkan nilai yang sedikit lebih baik, yaitu 0.317. Meskipun terjadi peningkatan kualitas, nilai tersebut masih menunjukkan bahwa pengelompokan dapat lebih dioptimalkan. Oleh karena itu, dilakukan optimasi model clustering dengan mencoba berbagai kombinasi parameter inisialisasi centroid dan jumlah iterasi maksimum. Hasil optimasi menunjukkan bahwa dengan jumlah cluster optimal sebanyak 4, nilai *Silhouette Score* meningkat menjadi 0.7638, yang mengindikasikan bahwa pemisahan antar cluster menjadi lebih jelas dan model clustering bekerja dengan baik.

Setelah model clustering dioptimasi, langkah berikutnya adalah menerapkan model matematis *K-Means* dengan nilai K terbaik, yaitu 4. Proses ini mencakup perhitungan jarak *Euclidean* untuk menentukan kedekatan setiap titik data dengan centroid cluster, pengelompokan titik-titik data berdasarkan jarak terdekat, pembaruan centroid hingga konvergen, dan evaluasi hasil pengelompokan. Hasil akhir menunjukkan bahwa setiap cluster memiliki karakteristik yang berbeda, yang dapat dimanfaatkan untuk analisis lebih lanjut.

Interpretasi cluster ini membantu dalam segmentasi transformator berdasarkan usia, beban, dan tingkat ketidakseimbangan, yang dapat digunakan dalam strategi predictive maintenance. Dengan demikian, pengelompokan ini berkontribusi dalam optimasi pemeliharaan transformator, mengurangi biaya operasional, dan meningkatkan efisiensi sistem kelistrikan secara keseluruhan.

5. Pemodelan Klasifikasi

Pemodelan klasifikasi menggunakan *XGBoost* dilakukan setelah proses *clustering* data inspeksi Trafo Distribusi menjadi empat kelompok: Cluster Muda Efisien, Cluster Beban Tidak Seimbang, Cluster Trafo Moderat, dan Cluster Trafo Tangguh. Model ini menggunakan persentase beban, ketidakseimbangan beban, suhu trafo, dan usia trafo sebagai fitur input, dengan target variabel berupa hasil clustering. Proses *XGBoost* melibatkan perhitungan residual error, pembentukan pohon keputusan, perhitungan bobot pada setiap leaf node, serta iterasi hingga konvergen, sehingga model dapat terus meningkatkan akurasi dengan memperbaiki prediksi di setiap iterasi.

Evaluasi model menunjukkan akurasi 97%, dengan performa terbaik pada *Cluster Trafo Losses* (F1-Score: 0.98). *Confusion Matrix* menunjukkan bahwa sebagian besar prediksi model benar, dengan kesalahan klasifikasi yang kecil. Selain itu, Kurva ROC menggambarkan hubungan antara *True Positive Rate* (TPR) dan *False Positive Rate* (FPR) dalam menilai kualitas klasifikasi. Untuk memastikan kestabilan model dan mencegah *overfitting*, digunakan teknik *K-Fold Cross Validation*, yang membagi data menjadi beberapa bagian untuk pengujian berulang, sehingga model memiliki generalisasi yang lebih baik terhadap data baru.

6. Optimalisasi Parameter untuk peningkatan Kinerja Model

Optimalisasi Parameter diperlukan agar kinerja model efisien atau optimal. Untuk hal tersebut dilakukan dengan menemukan kombinasi ideal dari parameter operasional seperti persen beban, usia trafo, persentase ketidakseimbangan, dan suhu trafo. Dengan memahami interaksi antara variabel-variabel ini, diharapkan dapat ditemukan kondisi optimal yang meminimalkan risiko kerusakan dan meningkatkan efisiensi operasional. Pembahasan ini juga akan mencakup metode evaluasi data historis dan penggunaan model simulasi untuk memprediksi kinerja jangka panjang trafo distribusi, guna memastikan keandalan pasokan energi dan memperpanjang masa pakai peralatan.

Optimisasi tersebut dilakukan dengan pendekatan *brute-force*. Melalui metode ini, setiap kombinasi yang mungkin dari parameter operasional seperti usia trafo, persen beban, suhu, dan persentase ketidakseimbangan diuji secara sistematis untuk menilai kinerjanya. Pendekatan ini menjamin bahwa semua kemungkinan kombinasi diperiksa, sehingga dapat mengidentifikasi kondisi terbaik untuk kinerja trafo yang optimal.

Optimalisasi Parameter Metode *Brute force* digunakan untuk mengoptimalkan kombinasi fitur. Metode ini menguji setiap kemungkinan kombinasi nilai dari fitur yang diberikan (Usia, Persen Beban, Suhu Trafo, Persentase Ketidakseimbangan) dan kemudian memilih kombinasi yang memberikan hasil terbaik berdasarkan probabilitas prediksi yang diperoleh dari model *XGB Classifier*.

7. Implikasi Manajerial

Berdasarkan hasil analisis model prediktif yang mengintegrasikan *Clustering* dan klasifikasi *XGBoost* pada data inspeksi Trafo Distribusi, diperoleh sejumlah rekomendasi strategis dalam pengambilan keputusan terkait pemeliharaan transformator. Rekomendasi ini merupakan implikasi manajerial yang dihasilkan dari penelitian ini, yang bertujuan untuk meningkatkan efektivitas strategi pemeliharaan, mengoptimalkan sumber daya, serta meminimalkan risiko kegagalan operasional pada sistem distribusi tenaga listrik.

8. Perbandingan Efisiensi Biaya Perhitungan Biaya Menggunakan Machine Learning dan Perhitungan Biaya Existing di PLN

Pada sub bab ini akan dibahas mengenai perbandingan Efisiensi Biaya Perhitungan Biaya *Predictive Maintenance* Trafo Distribusi Menggunakan *Machine Learning* dengan Perhitungan Biaya Pemeliharaan *Existing* yang digunakan PLN saat ini. Perhitungan ini menggunakan data sebagai berikut:

Tabel 1. Komponen Biaya Pemeliharaan

Pekerjaan	Biaya sarana & jasa
Inpeksi Gardu Distribusi	Rp 165.476
Pemeliharaan Trafo	Rp 550.213
Pembersihan Umum Gardu	Rp 207.704
Pengukuran Beban Puncak & Tegang Uj	Rp 144.790
Biaya Pemeliharaan Trafo	Rp 20.638.554
Biaya Pemerataan Beban Fase	Rp 20.638.554

Untuk keperluan perhitungan ini, ditetapkan beberapa asumsi dan batasan sebagai berikut. Pertama, anggaran dari PLN diasumsikan mencukupi untuk menutupi seluruh biaya yang dihitung dalam analisis ini. Kedua, perhitungan dalam kerangka *Benefit Cost Analysis* hanya dibatasi pada aspek biaya (*cost*) saja. Perhitungan manfaat (*benefit*) tidak dilakukan karena memerlukan data realisasi gangguan yang memiliki integritas tinggi sebagai dasar penghitungan *Energy Not Supplied* (ENS) akibat gangguan pada trafo distribusi. Selain itu, manfaat dari implementasi biaya berbasis *Machine Learning* juga tidak dihitung karena analisis prediktif hanya mencakup aspek *predictive maintenance*, bukan prediksi gangguan secara langsung, sehingga tidak dapat digunakan untuk menghitung ENS dari potensi gangguan. Ketiga, metode pemeliharaan trafo yang saat ini digunakan PLN adalah gabungan antara *Time-Based Maintenance* dan *Condition-Based Maintenance*, di mana inspeksi dan pengukuran beban trafo dilakukan setiap tiga bulan sekali dan pemeliharaan periodik dilaksanakan setiap satu tahun. Dalam konteks *Condition-Based Maintenance*, diasumsikan tidak ditemukan anomali. Keempat, kebijakan penggantian trafo tua berlaku untuk trafo dengan usia operasional 25 tahun ke atas. Kelima, kebijakan pengurangan beban trafo diterapkan untuk beban trafo yang melebihi 80% dari kapasitas nominal. Terakhir, kebijakan pemerataan beban fase diberlakukan jika ketidakseimbangan beban antar fase melebihi 50%.

Kesimpulan

Kesimpulan dari penelitian ini menunjukkan bahwa penggunaan Machine Learning dengan algoritma *Clustering* dan XGBoost menghasilkan klasifikasi tingkat keandalan dan kesehatan Trafo Distribusi dalam empat kelas: Trafo Sehat (46,99%), Trafo Beban Tinggi dan Rawan Gangguan (30,53%), Trafo Tua dan Rawan Gangguan (17,53%), dan Trafo *Losses* (4,95%). Model ini memiliki performa tinggi dengan akurasi 97%, precision 92-97%, dan *recall* 95-98%, tanpa indikasi *overfitting* atau *underfitting*, serta evaluasi K-Fold Cross Validation menunjukkan akurasi stabil antara 89–95%. Rekomendasi pemeliharaan berdasarkan hasil model mencakup inspeksi normal hingga intensif, pemeliharaan berbasis waktu, dan penggantian trafo tua ekstrim. Dengan biaya *Predictive Maintenance* berbasis *Machine Learning* sebesar Rp.14.133.542.153,- dan biaya pemeliharaan PLN sebesar Rp.73.920.146.452,-, didapatkan efisiensi biaya sebesar 80,88%. Saran untuk penyempurnaan model mencakup peningkatan efektivitas inspeksi dengan menggunakan uji *Partial Discharge* dan sensor kelembaban, serta pengembangan lebih lanjut menjadi *Prescriptive Analytics* dengan algoritma optimasi yang lebih kompleks. Penelitian ini menyarankan agar implementasi

machine learning dalam predictive maintenance trafo distribusi didukung oleh integrasi data real-time dari sensor digital untuk meningkatkan akurasi model. Selain itu, model sebaiknya dikembangkan lebih lanjut untuk memprediksi potensi gangguan agar perhitungan *Energy Not Supplied* (ENS) dan manfaat ekonomi bisa dilakukan secara menyeluruh. Penggunaan algoritma lain seperti *Random Forest* atau *LightGBM* juga disarankan untuk dibandingkan dengan *XGBoost* guna mendapatkan model paling optimal. Uji coba model di unit distribusi lain perlu dilakukan untuk memastikan generalisasi hasil. Terakhir, pelatihan teknisi sangat penting agar hasil prediksi dapat diterapkan secara efektif di lapangan.

DAFTAR PUSTAKA

- Ballal, M. S., Jaiswal, G. C., Tutkane, D. R., Venikar, P. A., Mishra, M. K., & Suryawanshi, H. M. (2017). Online condition monitoring system for substation and service transformers. *IET Electric Power Applications*, 11(7), 1187–1195. <https://doi.org/10.1049/iet-epa.2016.0842>
- Fitriyan, R., & Syairudin, B. (2016). Analisis risiko kerusakan peralatan dengan menggunakan metode fmea untuk meningkatkankinerja pemeliharaan prediktif pada pembangkit listrik. *Prosiding Seminar Nasional Manajemen Teknologi XXV. Program Studi MMT-ITS*.
- Honarmand, N. (2015). *Key performance indicators modeling for optimized microgrid configuration*.
- Li, J., An, X., Li, Q., Wang, C., Yu, H., Zhou, X., & Geng, Y. (2022). Application of *XGBoost* algorithm in the optimization of pollutant concentration. *Atmospheric Research*, 276, 106238. <https://doi.org/10.1016/j.atmosres.2022.106238>
- Li, M., Fu, X., & Li, D. (2020). Diabetes prediction based on *XGBoost* algorithm. *IOP Conference Series: Materials Science and Engineering*, 768(7), 72093.
- Li, W., Yin, Y., Quan, X., & Zhang, H. (2019). Gene expression value prediction based on *XGBoost* algorithm. *Frontiers in Genetics*, 10, 1077.
- Mitchell, R., & Frank, E. (2017). Accelerating the *XGBoost* algorithm using GPU computing. *PeerJ Computer Science*, 3, e127.
- Molęda, M., Małysiak-Mrozek, B., Ding, W., Sunderam, V., & Mrozek, D. (2023). From corrective to predictive maintenance—A review of maintenance approaches for the power industry. *Sensors*, 23(13), 5970.
- Nelson, A. A., Jaiswal, G. C., Ballal, M. S., & Tutakne, D. R. (2014). Remote condition monitoring system for distribution transformer. *2014 Eighteenth National Power Systems Conference (NPSC)*, 1–5.
- Pan, B., Zhang, Y., Gui, X., Wan, Y., & Wang, G. (2019). Analysis and research of three-phase unbalance in distribution transformers. *IOP Conference Series: Earth and Environmental Science*, 252(3), 32196. <https://doi.org/10.1088/1755-1315/252/3/032196>
- Setiawan, T. (2022). Kajian Pemeliharaan Trafo Distribusi Menggunakan Metode Condition Based Maintenance (CBM). *Aceh Journal of Electrical Engineering and Technology*, 2(2), 18–23.
- Sodikin, J., & Jati, U. S. (2022). Analisa Kerusakan Transmisi Otomatis dengan Metode Failures Mode and Effects Analysis (FMEA) dan Logic Tree Anaysis (LTA). *Accurate: Journal of Mechanical Engineering and Science*, 3(1), 13–21.
- Sukadana, I. W., Darmawan, K. D., & Utama, I. W. (2021). Deteksi Dini Gangguan Transformator Berbasis Manajemen Transformator Untuk Meningkatkan Kinerja Operasi dan Finansial Di PT. PLN ULP Singaraja. *Jurnal Teknik Elektro*, 10(2), 77–85. <https://doi.org/10.21063/JTE.2021.31331012>
- Susilawati, T., & Dharmawansyah, D. (2019). Metode Penerapan Keselamatan Dan Kesehatan Kerja Terhadap Kinerja Proyek Konstruksi (Studi Kasus Proyek Pembangkit Listrik

- Tenaga Mesin Gas Sumbawa). *Jurnal Tambora*, 3(3), 107–114. <https://doi.org/10.36761/jt.v3i3.403>
- Sutaryono, G. L. (2015). *Analisa Indeks Kesehatan Transformator Daya Berbasis Neural Network Untuk Mereduksi Jumlah Test Pada Trafo*. Institut Technology Sepuluh Nopember.
- Tamma, W. R., Prasajo, R. A., & Suwarno. (2021). High voltage power transformer condition assessment considering the health index value and its decreasing rate. *High Voltage*, 6(2), 314–327. <https://doi.org/10.1049/hve2.12074>
- Tjalla, A. (n.d.). *Tendensi Sentral Dan Variabilitas*.
- Tran, Q. T., Davies, K., Roose, L., Wiriyaikitikun, P., Janjampop, J., Riva Sanseverino, E., & Zizzo, G. (2020). A review of health assessment techniques for distribution transformers in smart distribution grids. *Applied Sciences*, 10(22), 8115.
- Vita, V., Fotis, G., Chobanov, V., Pavlatos, C., & Mladenov, V. (2023). Predictive maintenance for distribution system operators in increasing transformers' reliability. *Electronics*, 12(6), 1356.
- Xing, Z., He, Y., Chen, J., Wang, X., & Du, B. (2023). Health evaluation of power transformer using deep learning neural network. *Electric Power Systems Research*, 215, 109016.

Copyright holder:

Aulia Mahdi, Erma Suryani (2025)

First publication right:

Syntax Literate: Jurnal Ilmiah Indonesia

This article is licensed under:

