

Predictive Sparepart Maintenance Menggunakan Algoritma Machine Learning Extreme Gradient Boosting Regressor

¹Syahrul Usman, ²Rahmat Fuadi Syam
Syahrul.usman@unpacti.ac.id, rahmat@unpacti.ac.id
^{1,2}Ilmu Komputer, Universitas Pancasakti, Makassar

Abstrak

Sparepart merupakan komponen penyusun dari suatu kesatuan benda yang memiliki fungsi tertentu, pada kendaraan mobil, sparepart berfungsi dalam menjaga kinerja dan fungsi kendaraan, Predictive Sparepart Maintenance merupakan upaya untuk meningkatkan efisiensi operasional, pelayanan pelanggan, dan mengurangi waktu henti kendaraan melalui penerapan analisis dan algoritma machine learning untuk memprediksi waktu penggantian suku cadang, dengan fokus pada suku cadang baterai. Penerapan machine learning dapat dilakukan untuk melakukan prediksi terhadap waktu maintenance suku cadang mobil, dimana salah satu algoritma yang bisa dipakai adalah XGBoost Regressor. Melalui pendekatan ini, penelitian ini bertujuan untuk memperbaiki perencanaan layanan dengan melakukan prediksi waktu penggantian suku cadang berdasarkan indikator tertentu, Dengan implementasi penelitian ini, diharapkan dapat meningkatkan efisiensi operasional pada layanan purna jual otomotif, meningkatkan kepuasan pelanggan, mengurangi downtime kendaraan, dan memperbaiki perencanaan layanan secara keseluruhan serta yang terpenting bisa memberikan informasi yang bersifat pemeliharaan preventif kepada pelanggan, penelitian ini memberikan hasil prediksi dengan nilai R2-Score sebagai berikut data train: 90%, Test: 87%

Kata Kunci: *Predictive, Machine_Learning, XGBoost Regressor, Sparepart, Purna Jual*

Abstract

Spare parts are components that make up a single object that has a specific function. In car vehicles, spare parts have the function of maintaining the performance and function of the vehicle. Predictive Spare Part Maintenance is an effort to improve operational efficiency, customer service, and reduce vehicle downtime through the application of analysis and machine learning algorithms to predict spare part replacement times. A machine learning approach can be used to predict maintenance times for car spare parts, where one of the algorithms that can be used is XGBoost Regressor. Through this approach, this research aims to improve service planning by predicting spare part replacement times based on certain indicators, With the implementation of this research, it is hoped that it can increase operational efficiency in automotive after-sales services, increase customer satisfaction, reduce vehicle downtime, and improve overall service planning and most importantly can provide preventive maintenance information to customers. This research provides prediction results with R2-Score values as follows: train data: 90%, Test: 87%

Kata Kunci: *Predictive, Machin Learning, XGBoost Regressor, Sparepart, After Sales*

1. Pendahuluan

Sparepart merupakan komponen penyusun dari suatu kesatuan benda yang memiliki fungsi tertentu (Ovilianda & Ginting, 2021). Fungsi setiap sparepart berbeda - beda dan dapat saling terikat satu sama lain. Berdasarkan fungsi tersebut, suatu sparepart memiliki peran yang penting dalam berjalannya alur kerja suatu alat atau barang, termasuk pada kendaraan bermotor, yaitu mobil (Sampul et al., 2021).

Pada kendaraan mobil, sparepart berfungsi dalam menjaga kinerja dan kegunaan kendaraan. Beberapa contoh sparepart pada mobil diantaranya baterai, kampas rem, packing drain, busi, suspensi, filter oli, dan lainnya (Cadang et al., 2019; Usman et al., 2022). Agar kendaraan dapat terus optimal, penggunaan sparepart yang berkualitas dan perawatan yang teratur perlu dilakukan.

Perkembangan ilmu teknologi yang begitu pesat merambah ke berbagai bidang, termasuk pada maintenance sparepart kendaraan mobil. Salah satu pendekatan yang dapat dilakukan agar mengurangi waktu pengecekan adalah dengan predictive maintenance, dimana jika kendaraan belum layak secara prediksi untuk dilakukan maintenance, maka pengecekan tidak perlu dilakukan. Dengan kata lain, sparepart diprediksi kapan akan mengalami kerusakan sebelum terjadi kerusakan total (Purnomo et al., n.d.).

Penerapan machine learning dapat dilakukan untuk melakukan prediksi terhadap waktu maintenance suku cadang mobil. Machine learning dilakukan dengan perancangan model yang dilatih berdasarkan data yang ada (Wiki Lofandri, 2022). Metode yang dapat digunakan dalam prediksi adalah regresi, dimana salah satu algoritma yang bisa dipakai adalah Extreme Gradient Boosting Regressor (XGBoost Regressor).

Dalam konteks tersebut, rumusan permasalahan yang akan diteliti pada kegiatan ini adalah Bagaimana melakukan prediksi waktu penggantian suku cadang secara akurat berdasarkan indikator tertentu, khususnya untuk suku cadang baterai, dalam layanan purna jual otomotif.

Dengan memiliki prediksi yang akurat tentang waktu penggantian suku cadang, pelaku usaha purna jual otomotif dapat mengoptimalkan persediaan suku cadang, menghindari kekurangan atau kelebihan stok yang tidak perlu. Dengan memastikan penggantian suku cadang dilakukan tepat waktu, pelaku usaha purna jual otomotif dapat meningkatkan kepuasan pelanggan dengan meminimalkan waktu henti kendaraan dan memastikan ketersediaan kendaraan yang handal serta dapat menghemat biaya operasional dan meningkatkan profitabilitas pelaku usaha purna jual otomotif.

Beberapa penelitian terkait yang telah dilakukan diantaranya, Fajar Martha Subqi dan tim melakukan Penelitian dengan judul “Data Mining untuk Pemeliharaan Prediktif Mesin Produksi Berdasarkan Database Kerusakan Mesin Menggunakan Naïve Bayes Classifier” yang membahas mesin mana saja yang perlu dilakukan kegiatan preventive maintenance dengan menggunakan metode naïve bayes classier, menggunakan data history kerusakan mesin pada perusahaan spare part otomotif. Data yang digunakan sebanyak 754 data kerusakan dari hasil pengujian nilai akurasi 93,65 % untuk menentukan mesin yang perlu dilakukan kegiatan preventive maintenance.

Novan Hendrawan melakukan penelitian dengan judul “Optimalisasi produksi kertas dengan peninjauan pemeliharaan dan perbaikan prediktif dan preventif pada PT. SSetia Kawan Makmur Sejahtera” pada perusahaan yang bergerak dibidang manufaktur khususnya pulp and pap, Penelitian ini membandingkan metode pemeliharaan preventif yang dilakukan perusahaan dengan metode perbaikan dan metode pemeliharaan prediktif, Hasil yang didapat perbaikan dan

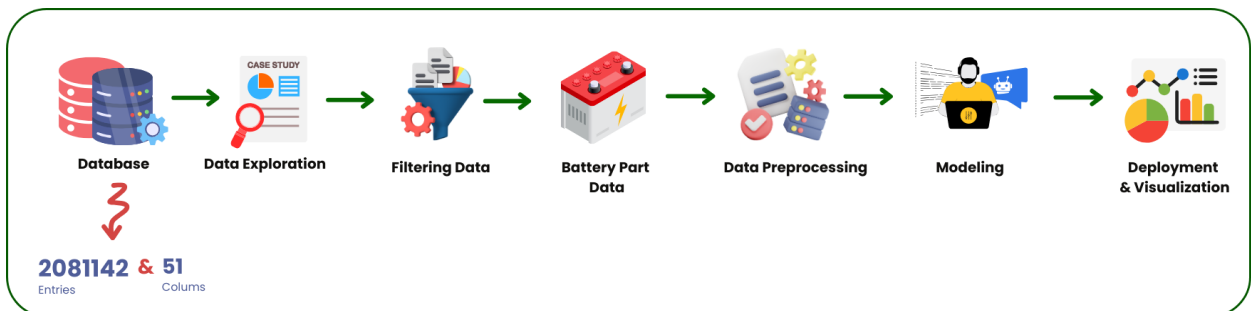
pemeliharaan prediktif maintenance lebih optimal dibandingkan dengan perbaikan dan pemeliharaan preventif dengan meningkatnya produksi Availability mesin meningkat 2%,

Essa A Wahid melakukan penelitian dengan judul “Pengembangan Algoritma Predictive Maintenance Pada Coal Pfister Feeder Dengan Pendekatan Machine Learning” aktivitas perawatan dilakukan pada mesin Coal Pfister Feeder dengan mengevaluasi dan menganalisa kondisi aktual dari alat, sehingga dapat diprediksi waktu yang optimal untuk dilakukan aktivitas perawatan sebelum kegagalan alat terjadi. Data yang digunakan merupakan parameter operasi pada coal pfister feeder terdiri dari 17 kolom dan 5093 baris, hasil dari penelitian ini membandingkan kinerja dari beberapa algoritma machine learning Dimana Gradient Boosting memberikan hasil akurasi yang paling baik diantara model Random Forest, AdaBoost, SVM dan Neural Network

Dari penelitian diatas didapati bahwa dengan menggunakan cukup banyak data serta menggunakan metode machine learning XGBoosting (Extreme Gradient Boosting) merupakan versi lanjutan dari Gradient Boosting bisa menghasilkan akurasi prediksi yang baik

2. Metodologi Penelitian

Tahapan Metode penelitian pada artikel ini terdiri dari Persiapan penelitian, Pengumpulan Data, data Explorasi, Data Preprocessing, Modelling, Visualisasi



Gambar 1. Tahapan Penelitian

2.1 Waktu dan Tempat Penelitian

Penelitian ini dilaksanakan pada Authorized Main Dealer Toyota yang meliputi penjualan, servis dan penyediaan suku cadang untuk wilayah servis dan pemasaran di Sulawesi Selatan, Sulawesi Barat, Sulawesi Tengah dan Sulawesi Tenggara. Penelitian ini membutuhkan waktu selama 5 bulan

2.2 Pengumpulan Data

Data yang digunakan dalam penelitian ini bersumber dari data service kendaraan dengan menggunakan data transaksi service yang terjadi pada bengkel sejak tahun 2016 sampai 2023 dengan jumlah baris data sebanyak 2081142 baris dan 51 kolom. Data dibatasi sesuai dengan jenis sparepart yang dijadikan objek penelitian, yaitu baterai. Pemrosesan data dilakukan dengan seleksi data, pembersihan data dan transformasi data. Pertama, data diseleksi untuk memilih fitur yang

akan dipakai pada model, seperti tanggal penggantian, jenis kendaraan, jenis baterai, jarak tempuh saat ini, dan usia kendaraan. Kemudian dilakukan data cleaning dengan penanganan missing value dan menghilangkan outlier data (Sihombing et al., 2023). Selanjutnya dilakukan data transformation agar format data sesuai dengan yang diharapkan untuk proses selanjutnya (Asohi, 2020) seperti mengubah data tanggal servis untuk mendapatkan selisih waktu penggantian.

2.3 Preprocessing Data

Setelah pengumpulan data selesai, dilakukan preprocessing data dengan melakukan beberapa hal diantaranya, melakukan Filtering data part berdasarkan part baterai, Filtering data workorder (wo) berdasarkan wo baterai pada data part, Menghitung umur kendaraan berdasarkan data faktur pembelian, Menghitung selisih waktu penggantian dari penggantian sebelumnya, Penangan *missing value* dan *anomaly* data *Current Mileage Record* berdasarkan umur kendaraan, Menghitung selisih *mileage* dari penggantian sebelumnya dan menghapus data *mileage* yang tidak konsisten, melakukan pemetaan data model kendaraan dan membuat kategori data umur.

2.4 Modelling dan Model Evaluasi

Pada tahap pemodelan, dilakukan penggunaan metode regresi dengan memanfaatkan algoritma Extreme Gradient Boosting (XGBoost). XGBoost merupakan implementasi open-source yang efisien dari algoritma decision tree yang ditingkatkan gradiennya (Muslim Karo Karo, 2020). Metode ini operasional dengan membangun serangkaian pohon keputusan secara berurutan, menggabungkan hasil prediksi mereka untuk meningkatkan kinerja secara keseluruhan. XGBoost mengoptimalkan parameter training secara berulang dengan tujuan menurunkan fungsi kerugian (loss function). Pendekatan ini melibatkan pembentukan pohon regresi yang memiliki struktur yang lebih teratur, bertujuan untuk mengurangi kompleksitas model dan mencegah terjadinya overfitting (Andriansyah & Eka Wulansari Fridayanthie, 2023). Fungsi kerugian dan regularisasi yang ingin diminimalkan dirumuskan dalam persamaan (1).

$$L_t = \sum_{i=1}^n \ln |y_i| + \sum_{i=1}^n \hat{y}_{i,t-1} + f_t(X_i) + \Omega(f_t) \quad (1)$$

Prediksi akhir dari XGBoost diperoleh dengan menjumlahkan hasil prediksi dari setiap pohon regresi. Khususnya, algoritma ini menunjukkan performa optimal pada dataset yang mengandung fitur kategorikal, dan memiliki kecenderungan untuk kurang terpengaruh oleh ketidakseimbangan kelas pada data.

Evaluasi model dilakukan dengan metrik evaluasi R-Squared (koefisien determinasi). Koefisien determinasi (R^2) pada dasarnya mengukur seberapa baik model dapat menjelaskan varians dari variabel dependen (Supriana et al., n.d.). Rentang nilai koefisien determinasi adalah antara nol dan satu. Apabila nilai R^2 rendah, hal itu menunjukkan bahwa kemampuan variabel independen dalam menjelaskan varians dari variabel dependen sangat terbatas. Sebaliknya, nilai yang mendekati satu menandakan bahwa variabel independen memberikan sebagian besar informasi yang diperlukan untuk memprediksi varians dari variabel dependen. Nilai R^2 dihitung menggunakan persamaan (2) berikut.

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

Keterangan :

- R^2 : Koefisien determinasi
- y_i : Nilai aktual untuk sampel ke-i
- \hat{y}_i : Nilai prediksi untuk sampel ke-i
- \bar{y}_i : Nilai rata – rata

3. Hasil dan Pembahasan

Dataset dibagi menjadi data train data test dengan perbandingan 80%:20%, dengan atribut data yaitu kilometer, umur, tipe baterai, merk kendaraan, area dan banyak penggantian. Adapun target prediksi adalah waktu penggantian.

Sebelum dibangun model untuk prediksi, dilakukan Exploratory Data Analysis (EDA) sebagai investigasi awal untuk lebih memahami data yang digunakan seperti menemukan anomali data. EDA dilakukan secara univariate untuk tipe data object dan int64/float64 dengan melakukan describe dataframe. Tabel 1 menggambarkan hasil EDA secara univariate untuk data dengan tipe data object

Tabel 1. EDA tipe data object

	<i>count</i>	<i>unique</i>	<i>top</i>	<i>freq</i>
tipe_baterai	13752	2	0	7631
merk	13752	63	Avanza	3711
area	13752	2	<i>incity</i>	10036

Adapun Tabel 2 menunjukkan hasil EDA secara univariate untuk data dengan tipe data int64/float64.

Tabel 2. EDA tipe data object

	<i>count</i>	<i>mean</i>	<i>min</i>	25%	50%	75%	<i>max</i>
kilometer	13752	239593.35	0	38162.75	64110.79	108939.63	2147484000
umur	13752	2095.34	3	1173	1736	2825	16790

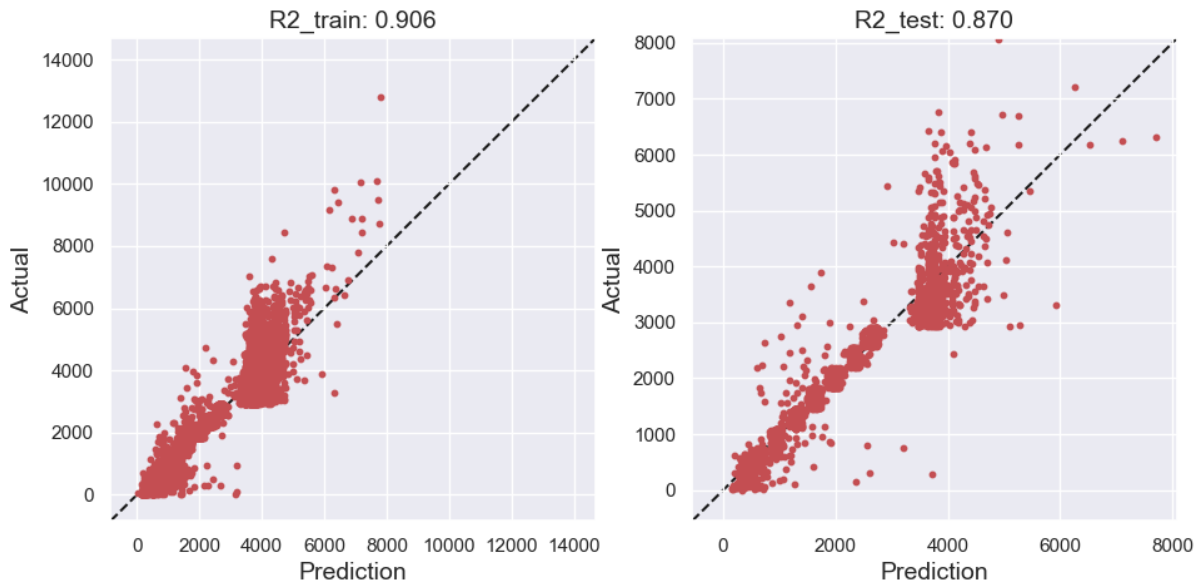
Berdasarkan hasil EDA, dilakukan normalisasi data seperti handling outlier untuk kemudian masuk ke pemodelan. Pemodelan dilakukan dengan menggunakan Extreme Gradient Boosting Regressor. Dilakukan hyper parameter tuning agar model dapat berfungsi optimal, dimana parameter terbaik yang diperoleh digambarkan pada Gambar 2.

```
===== Best Model Info =====
algo                | XGBRegressor
algo__colsample_bytree | 0.557932669154884
algo__gamma         | 6
algo__learning_rate  | 0.03391600849438614
algo__max_depth     | 6
algo__n_estimators   | 150
algo__reg_alpha      | 3.6998679204890976
algo__reg_lambda     | 0.3346220103048382
algo__subsample      | 0.6974056517708243
=====

===== Best Preprocessor Info =====
categorical_imputer | SimpleImputer(add_indicator=False, strategy='most_frequent')
categorical_encoder  | OneHotEncoder
numerical_imputer    | SimpleImputer(add_indicator=False, strategy='mean')
numerical_poly       | PolynomialFeatures
numerical_transformer | PowerTransformer(method='yeo-johnson')
=====
```

Gambar 2. Best parameter

Dari parameter diatas, diperoleh model prediksi dengan hasil evaluasi R^2 untuk train sebesar 90% dan untuk test sebesar 87%. Adapun perbandingan actual dan prediction dapat dilihat pada Gambar 3.



Gambar 3. Actual vs Prediction

Hasil ini menggambarkan bahwa model dapat menjelaskan sekitar 90% variansi dari data train dan 87% variansi dari data test. Hal ini mengindikasikan bahwa model cenderung baik dalam memprediksi waktu penggantian berdasarkan atribut-atribut yang dilatih.

Setelah dilakukan pemodelan, data hasil prediksi dikeluarkan dan dilakukan transformasi data untuk mendapatkan tanggal prediksi maintenance. Tabel 3 menunjukkan hasil prediksi waktu

maintenance baterai mobil. Tabel ini juga terdiri dari beberapa informasi kendaraan serta prediksi kapan waktu ideal melakukan penggantian atau *maintenance* part Baterai mobil

Tabel 3. Hasil Prediksi.

No	Kilometer	Umur Kendaraan (Tahun)	Tipe Baterai	Merk Kendaraan	Area	Penggantian Terakhir	Prediksi Penggantian
1	16504	3.9	0	AVANZA	incity	10/25/2021	2/13/2025
2	65542	3	0	RUSH	incity	8/24/2022	2/19/2026
3	5328	13.6	0	YARIS	incity	3/17/2022	10/23/2024
4	200000	8.4	1	INNOVA	incity	7/6/2023	12/12/2033
5	43998	2.6	0	YARIS	incity	4/26/2021	11/21/2023
6	100212	17.5	0	ALPHARD	incity	5/6/2021	3/19/2031
7	236455	14.9	1	AVANZA	incity	12/5/2022	7/11/2033
8	63877	12.7	0	HARRIER	outcity	1/13/2021	8/29/2030
9	57865	13.1	0	HARRIER	incity	1/18/2021	7/31/2030
10	82790	13.8	1	HARRIER	incity	10/1/2022	7/15/2032
11	45211	0.5	0	ALPHARD	incity	5/24/2021	2/27/2023
12	98214	8	1	ALPHARD	incity	3/17/2023	2/2/2033
13	106849.32	5.3	0	VELLFIRE	incity	6/4/2022	11/19/2027
14	27850	6.2	1	LEXUS	incity	2/24/2021	10/18/2026
15	74984	17.4	1	ALPHARD	incity	7/7/2022	11/7/2031
16	169014	16.5	1	ALPHARD	outcity	11/24/2022	8/29/2032
17	213260.27	10.7	0	ALPHARD	incity	9/15/2017	5/22/2028
18	188843	13.5	0	ALPHARD	incity	5/8/2021	6/20/2031
19	71417	3.5	0	ALPHARD	incity	3/11/2022	9/30/2025
20	20574	11.6	0	ALPHARD	incity	9/13/2021	9/24/2027
21	126646	9.5	0	ALPHARD	incity	12/9/2021	11/19/2031
22	103435	9.1	0	ALPHARD	incity	10/27/2021	9/20/2031
23	73334	10.4	0	VELLFIRE	incity	4/3/2023	8/4/2032
24	37821	6.7	0	ALPHARD	incity	2/3/2021	2/5/2027

25	36104	3.7	1	CALYA	incity	9/27/2021	3/25/2025
26	68956	10	0	YARIS	incity	7/28/2021	12/11/2030
27	124403	10.2	0	AVANZA	incity	7/12/2021	5/25/2031
28	65321	30.1	0	DYNA	incity	4/22/2021	7/9/2030
29	193216	9	0	INNOVA	incity	5/25/2021	8/21/2031
30	179232.88	9	0	YARIS	incity	4/30/2021	1/10/2031
31	285121	9.7	0	ALPHARD	incity	9/14/2020	8/1/2031
32	114136.99	5.7	0	RUSH	incity	1/16/2021	7/5/2026
33	188438.36	9.4	0	RUSH	incity	8/21/2021	11/7/2031
34	189704	9.2	0	AVANZA	incity	6/12/2021	6/9/2031
35	210253	9.2	0	RUSH	incity	8/21/2021	5/11/2032
36	34413	8	0	ETIOS	incity	5/31/2021	7/29/2029
37	197698.63	9.9	0	ETIOS	outcity	6/19/2023	8/18/2033
38	78954	8.8	0	ETIOS	incity	11/1/2022	3/24/2032
39	15818	7.8	1	HARRIER	incity	2/20/2023	4/28/2027
40	99721	9.6	0	AVANZA	incity	9/9/2021	6/15/2031
41	167287.67	8.4	0	AVANZA	incity	9/14/2021	3/14/2031
42	66000	12.1	1	RUSH	incity	2/21/2023	7/21/2032
43	71331	8.1	0	HILUX	incity	5/4/2022	10/4/2031
44	34756	8.2	0	YARIS	incity	8/4/2022	7/6/2030
45	125828	35	0	COROLLA	incity	1/20/2021	3/26/2031
46	127068	9.1	0	AVANZA	incity	3/27/2021	1/20/2031
47	55278	6.7	0	YARIS	incity	9/28/2021	12/21/2027
48	101237	6.2	1	AGYA	incity	2/5/2022	6/25/2028
49	138677	7	0	AGYA	incity	8/3/2022	2/15/2029

4. Penutup

4.1 Kesimpulan

Dalam penelitian ini, predictive maintenance dilakukan menggunakan algoritma machine learning XGBoost Regressor untuk memprediksi waktu maintenance suku cadang mobil, fokus pada baterai. Hasil evaluasi model menunjukkan bahwa XGBoost Regressor mampu menjelaskan sekitar 90% variansi dari data train dan 87% variansi dari data test, mengindikasikan kinerja yang baik dalam memprediksi waktu penggantian baterai berdasarkan atribut-atribut yang telah dilatih. Dengan demikian, pendekatan ini dapat meningkatkan efisiensi dan efektivitas proses maintenance suku cadang mobil, terutama baterai, sehingga dapat mengurangi biaya yang terkait dengan kegiatan tersebut.

4.2 Saran

Untuk pengembangan lebih lanjut, disarankan agar penelitian ini dapat diperluas pada jenis suku cadang mobil lainnya untuk mendapatkan gambaran yang lebih komprehensif terkait prediksi maintenance. Selain itu, penggunaan data yang lebih besar dan representatif dapat meningkatkan akurasi model. Penulis juga menyarankan untuk menjelajahi penggunaan metode lain agar dapat memberikan pemahaman lebih mendalam terhadap perbandingan kinerja model.

5. Daftar Pustaka

- Andriansyah, D.-, & Eka Wulansari Fridayanthie. (2023). Optimization of Support Vector Machine and XGBoost Methods Using Feature Selection to Improve Classification Performance. *JOURNAL OF INFORMATICS AND TELECOMMUNICATION ENGINEERING*, 6(2), 484–493. <https://doi.org/10.31289/jite.v6i2.8373>
- Asohi, Y. (2020). IMPELEMENTASI ALGORITMA REGRESI LINIER BERGANDA UNTUK PREDIKSI PENJUALAN. In *Jurnal Nasional Ilmu Komputer* (Vol. 1, Issue 3).
- Cadang, P. S., Berbasis, B., Pada Bengkel, W., Motor, D., & Nurhachita, P. (2019). *Sistem Informasi*.
- Ovilianda, A., & Ginting, B. (2021). Penerapan Data Mining Korelasi Penjualan Spare Part Mobil Menggunakan Metode Algoritma Apriori (Studi Kasus: CV. Citra Kencana Mobil). In *JOURNAL OF INFORMATION AND TECHNOLOGY UNIMOR*.
- Purnomo, J., Affandi, N., Rahmatullah, A., Manajemen, J., & Bina Bangsa, U. (n.d.). ANALISIS PENERAPAN PERAWATAN MOTOR KONVEYOR MESIN XRAY DENGAN MENGGUNAKAN METODE RELIABILITY CENTERED MAINTENANCE (RCM) PADA PT. TRISTAN ENGINEERING. *Jurnal Ilmiah Teknik Dan Manajemen Industri Jurnal Taguchi*, 1(2), 134–270. <https://doi.org/10.46306/tgc.v1i2>
- Sampul, H., Oleh, S., Sihombing, J., Teknik, F., & Komputer, D. (2021). *IMPLEMENTASI AUGMENTED REALITY SEBAGAI MEDIA PENGENALAN SPAREPART MOBIL BERBASIS ANDROID PROGRAM STUDI TEKNIK INFORMATIKA*.
- Sihombing, P. R., Suryadiningrat, S., Sunarjo, D. A., & Yuda, Y. P. A. C. (2023). Identifikasi Data Outlier (Pencilan) dan Kenormalan Data Pada Data Univariat serta Alternatif Penyelesaiannya. *Jurnal Ekonomi Dan Statistik Indonesia*, 2(3), 307–316. <https://doi.org/10.11594/jesi.02.03.07>

- Supriana, W., Raharja, M. A., Made, I., & Bimantara, S. (n.d.). *SINTECH Journal / 1 Pengembangan Sistem Prediksi Bantuan Program Keluarga Harapan (PKH) Berbasis Machine Learning*. <https://doi.org/10.31598>
- Usman, S., Aziz, F., Mipa, F., & Studi Ilmu Komputer, P. (2022). FORECASTING PENGENDALIAN PERSEDIAAN SUKU CADANG MENGGUNAKAN METODE NAIVE. In *Jeffry* (Vol. 8, Issue 1). Firman Aziz.
- Wiki Lofandri. (2022). Analisis Predictive Maintenance Peralatan Lab Berbasis Machine Learning. *Jurnal Sistim Informasi Dan Teknologi*. <https://doi.org/10.37034/jsisfotek.v5i1.164>