



Analisis Komparatif *K-Nearest Neighbor*, *XGBoost*, dan *Support Vector Machine* Menggunakan *Orange Data Mining* dalam Prediksi Kerusakan Aset BMN (Barang Milik Negara) Studi Kasus : Kejaksaan Negeri Kabupaten Tangerang

Cahyo Anggoro Seto¹

¹Teknik Informatika S-2, Program Pascasarjana, Universitas Pamulang, Kota Tangerang Selatan, Banten

Email: cahyoanggoroseto@gmail.com¹

ABSTRACT

Optimal management of State-Owned Assets (BMN) is a crucial factor in ensuring the operational effectiveness of government institutions, particularly at the District Attorney's Office of Tangerang Regency. However, unexpected asset damage often disrupts workflows and leads to inefficiencies in maintenance budgets. This study addresses this issue using a data mining approach, with the primary objective of evaluating and comparing the performance of three machine learning algorithms: K-Nearest Neighbor (K-NN), Support Vector Machine (SVM), and eXtreme Gradient Boosting (XGBoost) in predicting asset damage. The methodology employs a classification experimental study on historical asset maintenance data from the 2021–2025 period, analyzed using the Orange Data Mining platform. The research process includes data preprocessing stages (imputation and normalization), data partitioning into 70% training and 30% testing sets, and performance evaluation based on Area Under Curve (AUC), Accuracy, F1-Score, Precision, and Recall metrics. Comparative analysis results indicate that the XGBoost algorithm delivers superior performance, achieving the highest AUC of 0.987 and an F1-Score of 0.905, along with dominant prediction accuracy compared to other models. The K-NN algorithm demonstrates good and stable performance in the second position, whereas SVM exhibits lower accuracy levels than the other two models. Based on these findings, XGBoost is recommended as the optimal model for implementation within the District Attorney's Office asset management system. The adoption of this model is expected to support strategic decision-making, enable a transition to predictive maintenance, and enhance the efficiency of state asset management.

Keywords: *State-Owned Assets, K-Nearest Neighbor, XGBoost, Support Vector Machine, Orange Data Mining.*

ABSTRAK

Pengelolaan Barang Milik Negara (BMN) yang optimal merupakan faktor krusial dalam menjamin kelancaran operasional instansi pemerintah, khususnya di Kejaksaan Negeri Kabupaten Tangerang. Namun, kerusakan aset yang terjadi secara tak terduga seringkali mengganggu alur kerja dan menyebabkan inefisiensi anggaran pemeliharaan. Penelitian ini dilakukan untuk mengatasi permasalahan tersebut melalui pendekatan *data mining*, dengan tujuan utama mengevaluasi dan membandingkan kinerja tiga algoritma *machine learning*: *K-Nearest Neighbor* (K-NN), *Support Vector Machine* (SVM), dan *eXtreme Gradient Boosting* (XGBoost) dalam memprediksi kerusakan aset. Metode penelitian menerapkan studi eksperimental klasifikasi pada data historis pemeliharaan aset periode 2021–2025 yang dianalisis menggunakan platform *Orange Data Mining*. Proses penelitian mencakup tahapan *preprocessing* data (imputasi dan normalisasi), pembagian data menjadi 70% data latih dan 30% data uji, serta evaluasi performa berbasis metrik *Area Under Curve* (AUC), Akurasi, F1-Score, Presisi, dan *Recall*. Hasil analisis komparatif menunjukkan bahwa algoritma XGBoost memberikan performa paling superior, mencatatkan nilai AUC tertinggi sebesar 0.987, F1-Score 0.905, serta akurasi prediksi yang dominan dibandingkan model lainnya. Algoritma K-NN menunjukkan kinerja yang cukup baik dan stabil di posisi

kedua, sedangkan SVM memiliki tingkat akurasi yang lebih rendah dibanding kedua model tersebut. Berdasarkan temuan ini, *XGBoost* direkomendasikan sebagai model terbaik untuk diimplementasikan dalam sistem manajemen aset Kejaksaan. Penerapan model ini diharapkan dapat mendukung pengambilan keputusan strategis, memungkinkan transisi ke pemeliharaan prediktif, serta meningkatkan efisiensi pengelolaan aset negara.

Kata kunci: *Barang Milik Negara*, *K-Nearest Neighbor*, *XGBoost*, *Support Vector Machine*, *Orange Data Mining*.

1. PENDAHULUAN

Pengelolaan Barang Milik Negara (BMN)[1] merupakan aspek penting dalam tata kelola aset pemerintah[2], karena berkaitan langsung dengan efisiensi penggunaan anggaran negara serta akuntabilitas publik. Dalam praktiknya, aset BMN seperti kendaraan dinas, peralatan elektronik, dan bangunan mengalami penurunan fungsi atau kerusakan seiring waktu. Kejadian kerusakan tersebut tidak hanya menimbulkan kerugian material, tetapi juga dapat menghambat kinerja instansi pemerintah. Oleh karena itu, diperlukan upaya prediksi kerusakan aset secara lebih dini dan akurat agar perawatan atau penggantian dapat dilakukan tepat waktu.

Seiring berkembangnya teknologi data mining[3] dan kecerdasan buatan[4], penerapan algoritma prediktif[5] dalam pengelolaan aset menjadi semakin relevan. Beberapa algoritma yang populer digunakan untuk klasifikasi dan prediksi adalah *K-Nearest Neighbor* (K-NN)[6], *eXtreme Gradient Boosting* (*XGBoost*)[7], dan *Support Vector Machine* (SVM)[8]. Ketiga algoritma ini memiliki kelebihan masing-masing dalam hal akurasi, kecepatan, dan kemampuan menangani berbagai jenis data. Dalam konteks penelitian ini, ketiga algoritma tersebut dibandingkan untuk mengetahui performa terbaik dalam memprediksi kerusakan aset BMN menggunakan aplikasi *Orange Data Mining*[9], sebuah platform visualisasi analisis data yang mudah digunakan.

Penelitian ini difokuskan pada studi kasus di Kejaksaan Negeri Kabupaten Tangerang, yang merupakan salah satu instansi pemerintah dengan jumlah aset cukup besar dan beragam. Melalui pendekatan komparatif[10], penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja algoritma K-NN, *XGBoost*, dan SVM dalam hal akurasi, presisi, recall, dan metrik evaluasi lainnya. Hasil dari penelitian ini diharapkan dapat memberikan rekomendasi metode prediksi yang optimal untuk diterapkan dalam manajemen aset BMN, khususnya dalam mendukung pengambilan keputusan[11] berbasis data di lingkungan instansi pemerintah.

2. METODE

2.1. Tempat Dan Waktu Penelitian

Penelitian ini dilaksanakan di Kejaksaan Negeri Kabupaten Tangerang, yang berlokasi di Jl. M. Atiek Soeari Pusat Pemerintahan Kabupaten Tangerang, Provinsi Banten. Kejaksaan Negeri Kabupaten Tangerang dipilih sebagai lokasi studi kasus karena instansi ini memiliki beragam aset Barang Milik Negara (BMN) yang digunakan dalam mendukung operasional penegakan hukum dan pelayanan publik. Selain itu, terdapat kebutuhan nyata dalam melakukan prediksi dan pemeliharaan aset secara efisien untuk menjaga keandalan fasilitas dan peralatan kerja.

Pengumpulan data dilakukan dengan bekerja sama langsung dengan bagian Subbagian Pembinaan dan Pengelola BMN di Kejaksaan Negeri Kabupaten Tangerang. Data yang digunakan meliputi informasi historis kondisi aset, frekuensi perawatan, riwayat kerusakan, dan parameter-parameter lain yang relevan dalam proses prediksi kerusakan. Data ini kemudian diolah dan dianalisis menggunakan algoritma machine learning[12], yaitu *K-Nearest Neighbor*, *XGBoost*, dan *Support Vector Machine*. Data penelitian yang digunakan dibatasi hanya rentan tahun 2021-2025.

2.2. Jenis Dan Pendekatan Penelitian

Penelitian ini bersifat komparatif, karena fokus utama adalah membandingkan performa tiga algoritma (KNN, *XGBoost*, dan SVM) berdasarkan data historis pemeliharaan (dataset aset BMN) dan menerapkan algoritma machine learning untuk melakukan analisis hasil prediksi kerusakan BMN.

2.3. Metode Pengumpulan Data

Dalam penelitian ini, data yang digunakan merupakan data primer yang diperoleh dari instansi terkait, yaitu Kejaksaan Negeri Kabupaten Tangerang. Data ini mencakup informasi historis mengenai aset Barang Milik Negara (BMN), seperti Jenis BMN, Kode Barang, NUP, Nama Barang, Merk, Tipe, Kondisi, Tanggal Perolehan, Usia Asset, Jumlah Servis.

A. Jenis Data Yang Dikumpulkan

Tabel 1. Index Data

No.	Nama Field	Keterangan
1	Jenis BMN	Kategori Aset
2	Kode Barang	Kode Aset

3	NUP	Nomor
4	Nama Barang	Nama Aset
5	Merk	
6	Tipe	
7	Kondisi	Kondisi Aset Saat Ini
8	Tanggal Perolehan	Tanggal Perolehan Aset
9	Usia Asset	Usia Pakai Aset
10	Jumlah Servis	Berapa kali aset dilakukan pemeliharaan


B. Sumber Data

Dokumen Internal Kejaksaan Negeri Kabupaten Tangerang bersumber dari SIMAN (Sistem Informasi Manajemen Aset Negara) dan data historis pemeliharaan.

C. Teknik Pengumpulan Data

Studi Dokumentasi: Peneliti memperoleh data dari dokumen atau sistem pengelolaan BMN yang telah tersedia dalam bentuk file (Excel).

2.4. Tahapan Penelitian



Gambar 1. Workflow Penelitian

Setelah melakukan identifikasi masalah dan melakukan pengumpulan data, maka Langkah selanjutnya adalah :

a) Pre-processing Data

1. Membersihkan dan mempersiapkan data agar algoritma klasifikasi bekerja secara akurat.
2. Menstandarkan input agar perbandingan performa ketiga algoritma (K-NN, XGBoost, SVM) valid dan adil.

3. Mengoptimalkan hasil prediksi kerusakan aset pada BMN Kejaksaan Negeri Kabupaten Tangerang.

Jenis BMN	Kode Barang	NUP	Nama Barang	Merk	Tipe	Kondisi	tanggal Peroleha	Usia Asset	Jumlah Servis
ALAT ANGKUTA	3020101003	18	Station Wagor	TOYOTA AVANZ	TOYOTA AVANZ	Baik	2013-05-24	12	10
ALAT ANGKUTA	3020101003	19	Station Wagor	Innova 2.4 G M	INNOVA REBOR	Baik	2022-11-29	3	3
ALAT ANGKUTA	3020102003	1	Mini Bus (Pen	KIJANG INOVA	TIPE E	Baik	2011-11-08	14	7
ALAT ANGKUTA	3020102003	2	Mini Bus (Pen	KIJANG INOVA	G MT	Baik	2018-12-31	7	5
ALAT ANGKUTA	3020104001	1	Sepeda Motor	YAMAHA	VIXION LIMITEI	Baik	2011-09-10	14	10
ALAT ANGKUTA	3020104001	2	Sepeda Motor	YAMAHA	VIXION LIMITEI	Baik	2011-09-10	14	10
ALAT ANGKUTA	3020104001	3	Sepeda Motor	YAMAHA	VIXION LIMITEI	Baik	2011-09-10	14	8
ALAT ANGKUTA	3020104001	4	Sepeda Motor	HONDA VARIO	HONDA VARIO	Baik	2020-11-04	5	2
ALAT ANGKUTA	3020104001	5	Sepeda Motor	HONDA VARIO	HONDA VARIO	Baik	2020-11-04	5	2
ALAT ANGKUTA	3020104001	6	Sepeda Motor	Honda PCX	PCX 160	Baik	2023-12-12	2	1
ALAT ANGKUTA	3020105020	1	Mobil Unit Tah	TOYOTA DYNA	NEW DYNA 110	Baik	2009-09-15	16	6
ALAT ANGKUTA	3020105020	2	Mobil Unit Tah	TOYOTA	BU303R-TKMLS	Baik	2006-09-14	19	7
ALAT ANGKUTA	3020105020	3	Mobil Unit Tah	TOYOTA	MOBIL TAHANA	Baik	2008-10-15	17	10
ALAT ANGKUTA	3020105020	4	Mobil Unit Tah	TOYOTA	DYNA	Baik	2015-05-20	10	6
ALAT ANGKUTA	3020105020	5	Mobil Unit Tah	HINO DUTRO 1	RODA 6	Baik	2017-11-01	8	6
ALAT ANGKUTA	3020105020	6	Mobil Unit Tah	MOBIL TAHANAN		Baik	2023-12-01	2	1
ALAT ANGKUTA	3020105092	1	Mobil Unit TKP	SUZUKI APV	SUZUKI APV BO	Baik	2015-05-20	10	7
ALAT ANGKUTA	3020105132	1	Sepeda Motor	Honda CRF 150	CRF 150	Baik	2023-12-12	2	1
ALAT ANGKUTA	3020105132	2	Sepeda Motor	Honda CRF 150	CRF 150	Baik	2023-12-12	2	1
ALAT ANGKUTA	3020105132	3	Sepeda Motor	Honda CRF 150	CRF 150	Baik	2023-12-12	2	2
ALAT ANGKUTA	3020105999	1	Kendaraan Ber	MOBIL PENYULU	HINO	Baik	2022-12-30	3	2

Gambar 2. Contoh Dataset

Data Test - Orange

Info
184 instances (no missing data)
8 features
No target variable.
No meta attributes.

Variables
☒ Show variable labels (if present)
☐ Visualize numeric values
☒ Color by instance classes


Selection
☒ Select full rows

Jenis BMN	Kode Barang	NUP	Nama Barang	Kondisi	tanggal Perolehar	Usia Asset	Jumlah Servis
1 ALAT ANGKUT...	-2.04961	0.106	Station Wagon	Baik	2013-05-24	0.771	1.912
2 ALAT ANGKUT...	-2.04961	0.178	Station Wagon	Baik	2022-11-29	-1.074	-0.759
3 ALAT ANGKUT...	-2.04957	-1.112	Mini Bus (Penu...	Baik	2011-11-08	1.181	0.767
4 ALAT ANGKUT...	-2.04957	-1.040	Mini Bus (Penu...	Baik	2018-12-31	-0.254	0.004
5 ALAT ANGKUT...	-2.0495	-1.112	Sepeda Motor	Baik	2011-09-10	1.181	1.912
6 ALAT ANGKUT...	-2.0495	-1.040	Sepeda Motor	Baik	2011-09-10	1.181	1.912
7 ALAT ANGKUT...	-2.0495	-0.968	Sepeda Motor	Baik	2011-09-10	1.181	1.149
8 ALAT ANGKUT...	-2.0495	-0.897	Sepeda Motor	Baik	2020-11-04	-0.664	-1.140
9 ALAT ANGKUT...	-2.0495	-0.825	Sepeda Motor	Baik	2020-11-04	-0.664	-1.140
10 ALAT ANGKUT...	-2.0495	-0.754	Sepeda Motor	Baik	2023-12-12	-1.279	-1.522
11 ALAT ANGKUT...	-2.04947	-1.112	Mobil Unit Taha...	Baik	2009-09-15	1.591	0.386

Gambar 3. Clean Missing Data


b) Membangun Data Training

Berikut ini proses membangun data training di Orange Data Mining.




Gambar 4. Proses membangun data training

1. File : Sumber data (Data pemeliharaan Aset)
2. Pre-process : membersihkan dan memastikan tidak ada missing value pada data.



Tambahkan *item preprocess Input Missing Value* dan *Normalize Feature* pada *preprocess*. Hal ini dimaksudkan mengisi nilai-nilai yang kosong (*missing*) dengan nilai yang wajar/terstandar, agar data bisa diproses oleh algoritma *machine learning* seperti **KNN**, **SVM**, **XGBoost**.

3. Data *training* : pembatasan data untuk data *training* sebanyak 70%



Gambar 6. Pembatasan data untuk training sebanyak 70%

4. *Save Data Training* : menyimpan data training yang akan diujicoba

c) Membuat Model

- 3 Model Klasifikasi Algoritma yang akan dilakukan analisa komparatif:

- a. Model K-Nearest Neighbor (KNN)[13]

KNN adalah algoritma klasifikasi berbasis kedekatan data. Model ini tidak melakukan pelatihan eksplisit, tapi menyimpan data training dan membuat prediksi berdasarkan data tetangga terdekat.

- b. Model *Support Vector Machine* (SVM)


SVM adalah algoritma klasifikasi supervised learning yang bekerja dengan mencari garis pemisah (*hyperplane*) terbaik yang memisahkan kelas-kelas dalam data.

- c. Model *XGBoost*[7]

XGBoost adalah algoritma klasifikasi berbasis pohon keputusan (*decision tree*) yang menggunakan teknik boosting, yaitu membangun model secara bertahap dan memperbaiki kesalahan model sebelumnya.

4 Evaluasi Model

Berdasarkan alur proses pengujian data training terhadap 3 model yang ditentukan, akan di dapatkan data hasil akhir dalam bentuk *prediction* dan *test score* sebagai dasar evaluasi.



Gambar 7. Alur Proses pengujian data training terhadap model

3. HASIL DAN PEMBAHASAN

3.1. Analisis Hasil *Test and Score*

Penelitian ini membandingkan tiga model klasifikasi *K-Nearest Neighbor* (KNN), *Support Vector Machine* (SVM)[14], dan *XGBoost* dalam memprediksi kondisi kerusakan aset BMN berdasarkan data historis yang telah diproses melalui Orange Data Mining. Dataset dibagi menjadi data latih (70%) dan data uji (30%) menggunakan Data Sampler, dan telah dilakukan proses preprocessing berupa imputasi data hilang dan normalisasi fitur. Hasil perbandingan test and score dari 3 klasifikasi model tersebut dapat dilihat sebagai berikut ini :

Evaluation results for target (None, show average over classes)						
Model	AUC	CA	F1	Prec	Recall	MCC
SVM	0.923	0.864	0.858	0.865	0.864	0.708
kNN	0.965	0.880	0.869	0.866	0.880	0.744
XGBoost	0.987	0.913	0.905	0.901	0.913	0.817

Gambar 8. Hasil Nilai Test And Score

Berdasarkan hasil diatas maka diperoleh ringkasan sebagai berikut :

Tabel 2. Perbandingan Model

Model	Kelebihan	Kekurangan	Kesimpulan
SVM	- AUC cukup tinggi (0.923) - Presisi & recall seimbang (F1: 0.858)	- Akurasi (86.4%) masih lebih rendah dibanding model lain - MCC rendah	Kinerja cukup baik, tapi tidak sebaik kNN dan <i>eXtreme Gradient Boosting</i>
kNN	- AUC lebih tinggi dari SVM (0.965) - Recall baik (0.880)	- Bisa sensitif terhadap skala data - Kurang efisien di data besar	Performa baik dan stabil, cocok jika data tidak terlalu besar
<i>eXtreme Gradient Boosting</i> (XGBoost)	- Akurasi, AUC, dan F1 paling tinggi - MCC tertinggi (0.817)	- Komputasi lebih berat - Overfitting jika tidak dikontrol	Model terbaik dari ketiganya, sangat cocok untuk kebutuhan prediksi kompleks

3.2. Analisis Hasil *Prediction SVM*

Hasil evaluasi performa model *Support Vector Machine* dalam *table confusion matrix* dengan membandingkan hasil prediksi model terhadap data aktual (*ground truth*) adalah sebagai berikut :

		Predicted			Σ
		Baik	Rusak Berat	Rusak Ringan	
Actual	Baik	118	0	4	122
	Rusak Berat	10	39	0	49
	Rusak Ringan	3	0	10	13
Σ		131	39	14	184

Gambar 9. Hasil *Confusion Matrix* model SVM

Berdasarkan *confusion matrix* di atas, perhitungan akurasi dilakukan dengan menjumlahkan seluruh prediksi yang benar (*True Positive* dari setiap kelas) kemudian dibagi dengan total data keseluruhan. Mengacu pada persamaan akurasi $\frac{TP+TN}{Total\ data}$, maka diperoleh perhitungan sebagai berikut:

$$Akurasi = \frac{TP\ kelas\ baik + TP\ rusak\ berat + TP\ rusak\ ringan}{Total\ data}$$

$$Akurasi = \frac{118 + 39 + 10}{184}$$

$$Akurasi = \frac{167}{184} \times 100\% = 90,76\%$$

Dengan demikian, model SVM menghasilkan akurasi sebesar **90,76%**.

3.3. Analisis Hasil *Prediction K-Nearest Neighbour*

Hasil evaluasi performa model *K-Nearest Neighbour* dalam *table confusion matrix* dengan membandingkan hasil prediksi model terhadap data aktual (*ground truth*) adalah sebagai berikut :

		Predicted			Σ
		Baik	Rusak Berat	Rusak Ringan	
Actual	Baik	116	4	2	122
	Rusak Berat	2	47	0	49
	Rusak Ringan	7	0	6	13
Σ		125	51	8	184

Gambar 10. Hasil *Confusion Matrix* model *K-Nearest*

Berdasarkan *confusion matrix* di atas, perhitungan akurasi dilakukan dengan menjumlahkan seluruh prediksi yang benar (*True Positive* dari setiap kelas) kemudian dibagi dengan total data keseluruhan. Mengacu pada persamaan akurasi $\frac{TP+TN}{Total\ data}$, maka diperoleh perhitungan sebagai berikut:

$$Akurasi = \frac{TP\ kelas\ baik + TP\ rusak\ berat + TP\ rusak\ ringan}{Total\ data}$$


$$Akurasi = \frac{116 + 47 + 6}{184}$$

$$Akurasi = \frac{169}{184} \times 100\% = 91,84\%$$

Dengan demikian, model *K-Nearest Neighbor* menghasilkan akurasi sebesar **91,84%**, yang menunjukkan peningkatan kinerja dibandingkan model SVM.

3.4. Analisis Hasil Prediction XGBoost

Hasil evaluasi performa model XGBoost dalam *table confusion matrix* dengan membandingkan hasil prediksi model terhadap data aktual (*ground truth*) adalah sebagai berikut :



		Predicted			Σ
		Baik	Rusak Berat	Rusak Ringan	
Actual	Baik	122	0	0	122
	Rusak Berat	0	49	0	49
	Rusak Ringan	0	0	13	13
Σ		122	49	13	184

Gambar 11. Hasil Confusion Matrix model XGBoost

Berdasarkan *confusion matrix* di atas, perhitungan akurasi dilakukan dengan menjumlahkan seluruh prediksi yang benar (*True Positive* dari setiap kelas) kemudian dibagi dengan total data keseluruhan. Mengacu pada persamaan akurasi $\frac{TP+TN}{Total\ data}$, maka diperoleh perhitungan sebagai berikut:

$$Akurasi = \frac{TP\ kelas\ baik + TP\ rusak\ berat + TP\ rusak\ ringan}{Total\ data}$$

$$Akurasi = \frac{122 + 49 + 13}{184}$$

$$Akurasi = \frac{184}{184} \times 100\% = 100\%$$

Dengan demikian, model XGBoost menghasilkan akurasi sebesar **100%**, yang menunjukkan Akurasi paling tertinggi dari SVM dan KNN.

4. KESIMPULAN

Penelitian ini berhasil menunjukkan bahwa penerapan algoritma machine learning dapat dimanfaatkan secara efektif untuk memprediksi kerusakan aset Barang

Milik Negara (BMN) di Kejaksaan Negeri Kabupaten Tangerang. Dari ketiga model yang diuji, yaitu *K-Nearest Neighbor* (KNN), *Support Vector Machine* (SVM), dan *XGBoost*, algoritma *XGBoost* menunjukkan kinerja terbaik pada hasil evaluasi *test and score* dengan akurasi dalam pengujian data, serta skor tertinggi F1 90.5% dan AUC 98.7%. Hal ini menunjukkan bahwa *XGBoost* memiliki kemampuan paling andal dalam menangani kompleksitas data dan menghasilkan prediksi yang konsisten. Model KNN juga menunjukkan performa yang baik, sedikit di atas SVM, dan masih layak dipertimbangkan terutama jika keterbatasan sumber daya komputasi menjadi faktor penting. Temuan ini membuka peluang untuk diterapkannya sistem prediktif berbasis machine learning dalam mendukung perencanaan pemeliharaan aset, sehingga dapat meminimalisir risiko kerusakan yang tidak terduga dan mendukung efisiensi anggaran.

Sebagai implikasi praktis, instansi pemerintah dapat mengadopsi model prediktif berbasis *XGBoost* untuk merancang sistem pemeliharaan aset berbasis data historis, guna meningkatkan keandalan operasional. Untuk penelitian selanjutnya, disarankan melakukan pengujian dengan dataset yang lebih besar dan beragam, serta mempertimbangkan variabel lingkungan dan perilaku penggunaan aset agar prediksi menjadi lebih kontekstual dan akurat. Selain itu, pengembangan sistem prediksi secara real-time dan integrasi dengan sistem manajemen aset yang telah berjalan akan menjadi langkah strategis dalam transformasi digital pengelolaan BMN.

5. DAFTAR PUSTAKA

- [1] E. A. Lubis, "Efektivitas Tata Kelola Barang Milik Negara (BMN) di Lingkungan Kementerian Agama," *J. Ilm. GEMA PERENCANA*, vol. 2, no. 1, pp. 1–24, 2023.
- [2] D. O. Setiabudhi, "Pengelolaan Aset Pemerintah Daerah Dalam Perspektif Good Governance," *Stud. Soc. Sci.*, vol. 1, no. 1, p. 7, 2019, doi: 10.35801/tsss.2019.1.1.25014.
- [3] Dodi Nofri Yoliad, "Data mining Dalam Analisis Tingkat Penjualan Barang Elektronik Menggunakan Algoritma K-means," *Insearch (Information Syst. Res. J.)*, vol. 3, no. 1, 2023.
- [4] Z. R. H. Pohan, M. N. Idris, Ramli, Anwar, and J. Paisal, "Kesadaran Manusia

- Pada Posisi Ontologis Kecerdasan Buatan (Artificial Intelligence) Dalam Perspektif Alquran (Kajian Tafsir Ayat-Ayat Filosofis),” *J. Stud. Alquran dan Tafsir*, vol. 3, no. 1, pp. 29–38, 2023.
- [5] F. Martha and D. Anggraini, “Data Mining Untuk Pemeliharaan Prediktif Mesin Produksi berdasarkan Database Kerusakan Mesin menggunakan Naïve Bayes Classifier,” *J. Ilm. Komputasi*, vol. 20, no. 2, pp. 143–154, 2021, doi: 10.32409/jikstik.20.2.368.
- [6] P. Pangestu and R. Setyadi, “Penerapan Metode K-Nearest Neighbor Untuk Pemilihan Rekomendasi Game FPS Pada Aplikasi Google Play Store,” *J. Inf. Syst. Res.*, vol. 4, no. 2, pp. 742–747, 2023, doi: 10.47065/josh.v4i2.3006.
- [7] S. E. Herni Yulianti, Oni Soesanto, and Yuana Sukmawaty, “Penerapan Metode Extreme Gradient Boosting (XGBOOST) pada Klasifikasi Nasabah Kartu Kredit,” *J. Math. Theory Appl.*, vol. 4, no. 1, pp. 21–26, 2022, doi: 10.31605/jomta.v4i1.1792.
- [8] F. Abdusyukur, “Penerapan Algoritma Support Vector Machine (Svm) Untuk Klasifikasi Pencemaran Nama Baik Di Media Sosial Twitter,” *Komputa J. Ilm. Komput. dan Inform.*, vol. 12, no. 1, pp. 73–82, 2023, doi: 10.34010/komputa.v12i1.9418.
- [9] Ismail, H. N. Rahmah, and R. Sulistiyowati, “Penggunaan Software Orange Data Mining Pada Implementasi Text Mining Dalam Analisis Sentimen Netizen Di Twitter Terhadap Kelangkaan Minyak Goreng,” *Sigma-Mu*, vol. 14, no. 2, pp. 1–11, 2022, doi: 10.35313/sigmamu.v14i2.4667.
- [10] A. Umar, A. Abubakar, and M. Mahfudz, “Aplikasi Metode Komparatif (Analisis Buku Tafsir Nusantara : Analisis Isu-Isu Gender Dalam Al-Misbah Karya M . Quraish Shihab Dan Turjuman,” *Al-Tadabbur J. Ilmu Al-Qur’an dan Tafsir*, vol. 6, no. 2, pp. 161–174, 2021, doi: 10.30868/at.v6i02.1825.
- [11] N. N. F. Nindy, Vip Paramarta, Indah Haerunnisa, Lia Liana, and Jan Wahyudi Ria, “Implementasi Sistem Pengambilan Keputusan Mahasiswa Berprestasi Politeknik Lp3I Kampus Tasikmalaya,” *J. Ekon. Bisnis dan Manaj.*, vol. 1, no. 2, pp. 46–54, 2023, doi: 10.38204/ekobima.v1i2.1643.
- [12] R. G. Wardhana, G. Wang, and F. Sibuea, “Penerapan Machine Learning Dalam Prediksi Tingkat Kasus Penyakit Di Indonesia,” *J. Inf. Syst. Manag.*, vol. 5, no. 1,

- pp. 40–45, 2023, doi: 10.24076/joism.2023v5i1.1136.
- [13] M. Kafil and F. T. Industri, “Penerapan Metode K-Nearest Neighbors,” vol. 3, no. 2, pp. 59–66, 2019.
- [14] T. Menggunakan, M. K.- Nearest, N. B. Dan, and S. V. Machines, “Jurnal ilmu komputer,” vol. 2, pp. 323–342, 2024.