



Sistem Inventaris untuk Manajemen Program Robotik dengan Prediksi Kondisi Komponen Menggunakan Naïve Bayes pada PT. Diginusa

Nadia Fasha^a, Agung Siswopranoto^b

^{ab}Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pamulang

¹nadiafasha450@gmail.com, ²agung.siswopranoto@unpam.ac.id*

Article Info	ABSTRACT
Keywords: Sistem Inventaris Manajemen Aset Robotik Naïve Bayes Prediksi Kondisi Klasifikasi	Penelitian ini bertujuan untuk merancang dan mengembangkan sistem inventaris berbasis web pada program edukasi robotik di PT. Diginusa (PT. Bangun Satya Wacana) menggunakan algoritma Naïve Bayes. Sistem ini diharapkan dapat memudahkan pemantauan kondisi serta kelayakan komponen robot secara efisien dan mengatasi tantangan manajemen inventaris manual yang tersebar di berbagai lokasi sekolah mitra. Metode penelitian yang digunakan meliputi pengumpulan data historis komponen, perancangan sistem informasi, pengembangan model klasifikasi Naïve Bayes untuk prediksi kondisi, serta implementasi aplikasi menggunakan HTML, CSS, dan JavaScript yang dijalankan pada peramban dengan penyimpanan data berbasis MySQL. Dataset sebanyak 34 record komponen dengan empat variabel masukan (lama penggunaan, total jam operasional, nilai vibrasi, dan frekuensi kerusakan) dikategorikan melalui binning dan dibagi secara seimbang menjadi 17 data latih dan 17 data uji. Kondisi komponen diklasifikasikan ke dalam tiga kelas, yaitu Layak Pakai, Perlu Perawatan, dan Rusak. Performa model dievaluasi menggunakan confusion matrix dengan hasil akurasi 100% pada data latih dan 82,35% pada data uji, dengan rata-rata presisi 0,833 dan recall 0,822. Hasil penelitian menunjukkan bahwa sistem mampu mengoptimalkan proses inventarisasi dan memberikan prediksi proaktif mengenai kondisi komponen sehingga mendukung pengambilan keputusan terkait perawatan, penggantian, serta pengadaan perangkat demi menunjang kelancaran program edukasi robotik. <i>This is an open access article under the CC BY-SA license.</i> 

Corresponding Author:

Agung Siswopranoto
Program Studi Teknik Informatik
Fakultas Ilmu Komputer,
Universitas Pamulang
Tangerang Selatan, Banten,
Indonesia
Email: nadiafasha450@gmail.com

1. PENDAHULUAN

Program edukasi robotik telah menjadi salah satu aspek penting dalam pengembangan keterampilan teknologi di era modern. Di PT. Bangun Satya Wacana (Diginusa), sebagai perusahaan penyedia tenaga pengajar dan perangkat robotik, kelancaran operasional sangat bergantung pada manajemen aset yang efektif. Seiring bertambahnya jumlah sekolah mitra, muncul tantangan signifikan dalam mengelola inventaris perangkat robotik yang tersebar di berbagai lokasi. Saat ini, proses pencatatan dan pemantauan kondisi

komponen apakah masih layak pakai, memerlukan perawatan, atau sudah rusak masih dilakukan secara manual menggunakan spreadsheet (Excel). Akibatnya, proses ini kerap tidak efisien, rentan terhadap kesalahan, dan menyulitkan pemantauan kelayakan komponen secara akurat dan tepat waktu.

Sistem pencatatan manual tersebut hanya menyediakan data inventaris dasar, sementara pengolahan dan analisis datanya masih bersifat statis dan reaktif. Tindakan perbaikan atau penggantian komponen sering kali baru dilakukan setelah kerusakan terdeteksi atau dilaporkan, yang berisiko mengganggu kegiatan belajar mengajar di sekolah mitra. Pendekatan ini tidak mampu memberikan wawasan prediktif untuk mengantisipasi potensi kegagalan. Sebagai contoh, penurunan akurasi sensor jarak secara bertahap dapat menyebabkan robot berjalan tidak menentu, sementara riwayat kerusakan yang tidak tercatat menyulitkan identifikasi akar masalah dan berujung pada inefisiensi biaya perawatan serta potensi keluhan klien.

Oleh karena itu, diperlukan sebuah sistem yang tidak hanya informatif, tetapi juga prediktif, sehingga mampu mendukung pengambilan keputusan terkait perawatan dan pengadaan komponen secara lebih cepat dan tepat sasaran. Inti dari penelitian ini adalah penerapan algoritma Naïve Bayes untuk mengklasifikasikan kondisi komponen ke dalam tiga kategori: “Layak Pakai”, “Perlu Perawatan”, atau “Rusak”, dengan memanfaatkan data historis inventaris seperti lama penggunaan, total jam operasional, nilai vibrasi, dan frekuensi kerusakan.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk merancang dan membangun sistem inventaris komponen robotik berbasis web pada PT. Diginusa, menerapkan algoritma Naïve Bayes untuk memprediksi kondisi komponen ke dalam tiga kategori, serta mengevaluasi kinerja model klasifikasi menggunakan confusion matrix. Dengan demikian, sistem diharapkan mampu mengubah data historis inventaris menjadi informasi prediktif yang mendukung pengambilan keputusan perawatan dan pengadaan komponen secara lebih tepat, sekaligus mengurangi risiko gangguan pada program edukasi robotik di sekolah mitra.

Beberapa penelitian terdahulu telah menerapkan algoritma Naïve Bayes untuk prediksi kondisi dan kelayakan aset. Aulia et al. [1] menggabungkan Naïve Bayes dan Decision Tree untuk memprediksi kerusakan mesin pada industri manufaktur, Erni et al. [2] menerapkannya untuk klasifikasi stok barang guna optimalisasi persediaan, Monowati dan Setyadi [3] menggunakannya untuk memprediksi pengusulan penghapusan peralatan dan mesin kantor, sedangkan Putra et al. [4] menerapkannya pada sistem informasi berbasis web untuk klasifikasi kondisi aset. Ringkasan penelitian terkait disajikan pada Tabel 1. Penelitian-penelitian tersebut menunjukkan bahwa Naïve Bayes andal untuk klasifikasi berbasis data historis, namun penerapannya pada manajemen inventaris komponen robotik yang terintegrasi dalam sistem berbasis web masih jarang dibahas. Celah inilah yang menjadi fokus penelitian ini.

Tabel 1. Ringkasan Penelitian Terkait

No	Penulis (Tahun)	Judul	Metode	Hasil
1	Erni, Kamarudin, & Windarsyah (2025)	Klasifikasi Stok Barang Menggunakan Naïve Bayes untuk Optimalisasi Persediaan Toko Ahmad Adam	Naïve Bayes	Mengklasifikasikan stok ke kategori “laku cepat” dan “kurang laku”; pengujian confusion matrix menghasilkan akurasi 72,48% sebagai dasar keputusan pengadaan barang.
2	Putra, Lapatta, & Ngemba (2026)	Implementation of Naïve Bayes for Optimizing Asset Condition Classification in a Web-Based Information System	Naïve Bayes (KDD)	Mengklasifikasikan kondisi aset (Layak/Tidak Layak) berbasis web mengikuti alur KDD; terbukti meningkatkan efisiensi pengolahan data dan objektivitas keputusan.
3	Monowati & Setyadi (2023)	Penerapan Algoritma Naïve Bayes dalam Memprediksi Pengusulan Penghapusan Peralatan dan Mesin Kantor	Naïve Bayes	Memprediksi kelayakan peralatan (diusulkan/tidak) berdasarkan tahun pengadaan, bahan, dan kondisi; akurasi, presisi, dan recall masing-masing 100%.
4	Guntur & Kamarudin (2024)	Penerapan Metode Naïve Bayes dengan Sistem Pakar dalam Mendiagnosa Kerusakan pada Mesin Mobil	Naïve Bayes + Sistem Pakar	Mendiagnosa kerusakan mesin mobil berbasis gejala; sistem berbasis web yang dibangun mencapai akurasi 93%.
5	Aulia, Hermawan, & Avianto (2025)	Pendekatan Hybrid: Naïve Bayes dan Decision Tree untuk Prediksi Kerusakan Mesin pada Industri Manufaktur PT X	Naïve Bayes & Decision Tree	Untuk label tindakan preventif (2 kelas) Naïve Bayes unggul dengan akurasi 97,90%; untuk tingkat risiko (3 kelas) Decision Tree lebih baik (100%).

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan pengembangan sistem yang dipadukan dengan penerapan algoritma klasifikasi Naïve Bayes. Pengumpulan data dilakukan melalui studi pustaka terhadap literatur manajemen inventaris dan metode klasifikasi, observasi langsung terhadap pengelolaan inventaris komponen robotik di PT. Diginusa, serta wawancara dengan pihak Manajer, Akademik (Spv Product), Marketing, Guru,

dan SPV Operasional. Hasil observasi dan wawancara digunakan untuk memastikan struktur data dan variabel yang dicatat sesuai dengan kebutuhan analisis Naïve Bayes.

2.1. Data Mining dan KDD

Data mining merupakan proses menemukan pola, hubungan, dan pengetahuan bernilai dari sekumpulan data dengan memanfaatkan teknik statistik, pembelajaran mesin, dan analisis data [6]. Salah satu tugas data mining adalah klasifikasi, yaitu membangun model dari data berlabel untuk menentukan kelas data baru. Dalam penelitian ini, data mining digunakan untuk mengolah data historis komponen robotik, dengan atribut komponen sebagai variabel prediktor dan kondisi komponen sebagai kelas.

Proses pengolahan data mengacu pada kerangka Knowledge Discovery in Database (KDD) yang meliputi tahapan data cleaning, data integration, data selection, data transformation, data mining, pattern evaluation, dan knowledge presentation [7]. Data historis yang diperoleh diseleksi dan dipersiapkan, ditransformasikan pada atribut yang diperlukan, kemudian diklasifikasikan menggunakan Naïve Bayes menjadi tiga kategori kondisi, dan hasilnya dievaluasi menggunakan confusion matrix beserta metrik evaluasi klasifikasi.

2.2. Algoritma Naïve Bayes

Naïve Bayes merupakan algoritma klasifikasi probabilistik berdasarkan Teorema Bayes dengan asumsi antar fitur saling bebas secara kondisional terhadap kelas [8]. Probabilitas suatu kelas C terhadap data X dihitung dengan persamaan (1).

$$P(C|X) = [P(X|C) \times P(C)] / P(X) \quad (1)$$

dengan $P(C|X)$ adalah probabilitas posterior kelas C jika diketahui fitur X, $P(X|C)$ adalah likelihood, $P(C)$ adalah probabilitas prior kelas C, dan $P(X)$ adalah probabilitas fitur X. Untuk mengatasi masalah probabilitas nol digunakan Laplace Smoothing pada persamaan (2).


$$P(\text{fitur}|\text{kelas}) = (n(\text{fitur} \cap \text{kelas}) + 1) / (n(\text{kelas}) + k) \quad (2)$$

dengan $n(\text{fitur} \cap \text{kelas})$ adalah jumlah kemunculan suatu fitur pada kelas tertentu, $n(\text{kelas})$ adalah jumlah data pada kelas tersebut, dan k adalah jumlah kelas ($k = 3$). Prediksi akhir ditentukan berdasarkan prinsip Maximum A Posteriori, yaitu dengan memilih kelas yang memiliki nilai probabilitas posterior tertinggi.

2.3. Perancangan Sistem

Sistem yang diusulkan dirancang berbasis web menggunakan HTML, CSS (Tailwind), dan JavaScript yang dijalankan pada peramban dengan penyimpanan data berbasis MySQL. Sistem melibatkan lima entitas pengguna, yaitu Akademik (admin), Marketing, Guru, Manajer, dan SPV Operasional, dengan hak akses yang berbeda.

Akademik berperan sebagai admin dengan hak akses penuh untuk mengelola pengguna, data komponen, dan laporan kerusakan, mengisi formulir perbaikan, melihat statistik serta prediksi kondisi komponen, dan mencetak laporan. Marketing bertanggung jawab atas pengadaan dan penggantian komponen sehingga dapat mengelola data komponen, memantau statistik dan tren, serta melihat prediksi kondisi. Guru sebagai pengguna di sekolah mitra berinteraksi langsung dengan perangkat, melaporkan kerusakan, serta melihat data kerusakan dan daftar komponen. Manajer berperan sebagai pengawas yang memantau tindak lanjut perbaikan dan memanfaatkan statistik serta prediksi sebagai dasar pengambilan keputusan. SPV Operasional mengawasi proses perbaikan, memantau data kerusakan, melihat prediksi kondisi, dan mencetak laporan. Interaksi antara kelima aktor dan fungsi sistem dimodelkan menggunakan use case diagram sebagaimana ditunjukkan pada Gambar 1.




Gambar 1. Use Case Diagram Sistem Inventaris Robotik

Struktur data sistem dirancang melalui Entity Relationship Diagram (ERD) yang terdiri atas empat entitas utama, yaitu Pengguna, Laporan_Kerusakan, Komponen, dan Perbaikan. Seorang pengguna dapat membuat laporan kerusakan yang mengacu pada satu komponen tertentu, sedangkan satu komponen dapat memiliki beberapa laporan kerusakan, yang kemudian ditindaklanjuti melalui entitas Perbaikan. Rancangan ERD ditunjukkan pada Gambar 2.



Gambar 2. Entity Relationship Diagram (ERD)

Alur kerja sistem usulan, mulai dari proses login, pengelolaan data komponen, pelaporan kerusakan, hingga prediksi kondisi komponen dan pencetakan laporan, ditunjukkan pada Gambar 3.



Gambar 3. Activity Diagram Sistem Usulan

2.4. Teknologi Pengembangan Web

Sistem dibangun sebagai aplikasi berbasis web yang dapat diakses melalui web browser. HTML (HyperText Markup Language) digunakan untuk membangun struktur halaman, seperti halaman login, dashboard, tabel data komponen, serta formulir laporan kerusakan dan perbaikan [9]. CSS (Cascading Style Sheets) melalui framework Tailwind CSS digunakan untuk mengatur tampilan dan tata letak antarmuka agar konsisten dan mudah dipahami [10]. JavaScript memberikan kemampuan interaktif dan dinamis, seperti validasi input, pengelolaan event, dan komunikasi data [11].

Data sistem, meliputi data pengguna, komponen robotik, laporan kerusakan, perbaikan, serta hasil klasifikasi, dikelola menggunakan MySQL sebagai sistem manajemen basis data relasional [12]. Alur komunikasi sistem secara sederhana berlangsung dari pengguna melalui antarmuka HTML/CSS/JavaScript menuju server/API, kemudian ke basis data MySQL, dan kembali lagi untuk ditampilkan pada halaman web. Dengan arsitektur ini, data inventaris tersimpan secara terpusat dan terstruktur sehingga mendukung proses komputasi algoritma prediksi.

2.5. Pengumpulan dan Pra-pemrosesan Data

Dataset yang digunakan terdiri atas 34 record komponen robotik dengan empat variabel masukan utama, yaitu Lama Penggunaan (bulan), Total Jam Operasional (jam), Nilai Vibrasi (mm/s), dan Frekuensi Kerusakan (kali/tahun), serta satu variabel target berupa Status Kondisi yang terbagi ke dalam tiga kelas: Layak Pakai, Perlu Perawatan, dan Rusak. Keseluruhan dataset disajikan pada Tabel 2. Karena Naïve Bayes pada penelitian ini bekerja pada data kategorikal, setiap variabel numerik ditransformasikan menjadi kategori melalui proses binning sebagaimana ditunjukkan pada Tabel 3.

Tabel 2. Dataset Komponen Robotik

No	Nama Komponen	Lama (bln)	Jam Operasional	Vibrasi (mm/s)	Frekuensi/thn	Status Kondisi
1	Servo Motor MG996R	6	1200	0.8	0	Layak Pakai
2	Sensor Ultrasonik HC-SR04	8	1500	0.5	0	Layak Pakai
3	Main Controller Arduino Mega	10	1800	0.6	2	Layak Pakai
4	Motor DC Gearbox	5	900	0.9	0	Layak Pakai
5	Baterai Lithium 3S	14	2500	0.7	1	Layak Pakai
6	Sensor IR Proximity	9	1600	0.6	0	Layak Pakai
7	Gripper Servo	11	1900	1.7	1	Layak Pakai
8	Kamera Modul OV7670	4	800	0.3	0	Layak Pakai
9	Roda Omni Wheel	6	1300	1.1	0	Layak Pakai
10	Sensor Gyro MPU6050	13	2600	0.5	1	Layak Pakai
11	Servo Motor MG996R	18	3500	2.1	2	Perlu Perawatan
12	Motor DC Gearbox	20	4200	2.4	3	Perlu Perawatan
13	Baterai Lithium 3S	16	3000	1.0	2	Perlu Perawatan
14	Main Controller Arduino Mega	22	4800	1.8	2	Perlu Perawatan
15	Aktuator Linear	19	3800	2.5	4	Perlu Perawatan
16	Gripper Servo	17	3200	2.0	2	Perlu Perawatan
17	Sensor Ultrasonik HC-SR04	24	5500	1.9	3	Perlu Perawatan
18	Roda Omni Wheel	21	4900	2.3	2	Perlu Perawatan
19	Motor DC Gearbox	15	2800	1.2	3	Perlu Perawatan
20	Servo Motor MG996R	23	4700	3.2	3	Perlu Perawatan
21	Servo Motor MG996R	36	7500	4.2	5	Rusak
22	Motor DC Gearbox	40	8200	4.5	6	Rusak
23	Baterai Lithium 3S	30	6200	3.4	3	Rusak
24	Main Controller Arduino Mega	38	7800	3.8	5	Rusak
25	Aktuator Linear	42	8500	4.8	6	Rusak
26	Sensor Ultrasonik HC-SR04	35	7200	2.7	4	Rusak
27	Gripper Servo	37	7600	4.0	5	Rusak
28	Roda Omni Wheel	31	6400	3.6	3	Rusak
29	Sensor Gyro MPU6050	26	4900	3.4	4	Rusak
30	Kamera Modul OV7670	39	8000	3.9	5	Rusak
31	Konektor Kabel Jumper	7	1400	0.7	0	Layak Pakai
32	Motor Servo SG90	14	2800	1.8	1	Layak Pakai
33	Sensor Cahaya LDR	15	2600	1.2	1	Perlu Perawatan
34	Baterai Li-Po 2200mAh	30	5600	2.7	3	Rusak

Tabel 3. Kriteria Kategorisasi (Binning) Variabel

Variabel	Rendah / Baru	Sedang	Tinggi / Lama
Lama Penggunaan (bln)	< 12	12 – 24	> 24
Total Jam Operasional	< 2000	2000 – 5000	> 5000
Nilai Vibrasi (mm/s)	< 1.5	1.5 – 3.0	> 3.0
Frekuensi Kerusakan/thn	0 – 1	2 – 3	> 3

Dataset sebanyak 34 data kemudian dibagi menjadi dua kelompok secara seimbang pada setiap kelas, yaitu 17 data latih (training) dan 17 data uji (testing) dengan proporsi 50% : 50%. Data latih digunakan untuk membentuk model dengan menghitung nilai Prior dan Likelihood, sedangkan data uji digunakan untuk menguji model dengan membandingkan hasil prediksi terhadap status aktualnya. Keandalan model dievaluasi

menggunakan confusion matrix, yaitu metode yang membandingkan kelas aktual dengan kelas hasil prediksi [13], sebagai dasar perhitungan accuracy, precision, dan recall.

3. HASIL DAN PEMBAHASAN

3.1. Spesifikasi Sistem

Implementasi sistem membutuhkan spesifikasi perangkat keras dan perangkat lunak minimum agar seluruh proses, mulai dari interaksi antarmuka hingga komputasi algoritma Naïve Bayes, dapat berjalan stabil. Spesifikasi perangkat keras disajikan pada Tabel 4 dan perangkat lunak pada Tabel 5.

Tabel 4. Spesifikasi Perangkat Keras

Perangkat Keras	Spesifikasi
Processor	Intel Core i3 / setara atau lebih tinggi
RAM	Minimal 4 GB
Penyimpanan	Minimal 256 GB SSD
Monitor	Resolusi minimal 1366 x 768

Tabel 5. Spesifikasi Perangkat Lunak

Perangkat Lunak	Keterangan
Sistem Operasi	Windows 10 / 11
Bahasa Pemrograman	HTML, CSS, JavaScript
Framework CSS	Tailwind CSS
Library Pendukung	Chart.js (grafik), Lucide (ikon)
Penyimpanan Data	MySQL
Web Browser	Google Chrome / Mozilla Firefox
Code Editor	Visual Studio Code

3.2. Contoh Perhitungan Naïve Bayes

Sebagai contoh perhitungan, diambil salah satu data uji dengan ciri: Jam Operasional = Tinggi, Vibrasi = Tinggi, dan Frekuensi Kerusakan = Sedang. Langkah pertama adalah menghitung probabilitas prior tiap kelas berdasarkan 17 data latih, sebagaimana ditunjukkan pada Tabel 6.

Tabel 6. Perhitungan Probabilitas Prior

Kelas	Jumlah Data	Prior P(C)
Layak Pakai	6	$6/17 = 0,353$
Perlu Perawatan	6	$6/17 = 0,353$
Rusak	5	$5/17 = 0,294$

Selanjutnya dihitung nilai likelihood tiap fitur menggunakan Laplace Smoothing ($k = 3$), sehingga penyebutnya merupakan jumlah data latih tiap kelas ditambah 3, yaitu 9 untuk kelas Layak Pakai dan Perlu Perawatan serta 8 untuk kelas Rusak. Hasilnya disajikan pada Tabel 7.

Tabel 7. Perhitungan Likelihood tiap Fitur (Laplace, $k = 3$)

Fitur	Layak Pakai	Perlu Perawatan	Rusak
$P(\text{Jam=Tinggi} \text{C})$	$1/9 = 0,111$	$1/9 = 0,111$	$6/8 = 0,750$
$P(\text{Vibrasi=Tinggi} \text{C})$	$1/9 = 0,111$	$1/9 = 0,111$	$6/8 = 0,750$
$P(\text{Frekuensi=Sedang} \text{C})$	$2/9 = 0,222$	$6/9 = 0,667$	$2/8 = 0,250$

Nilai posterior tiap kelas diperoleh dengan mengalikan prior dan seluruh likelihood, sebagaimana pada Tabel 8.

Tabel 8. Perhitungan Probabilitas Posterior

Kelas	Perhitungan	Hasil
Layak Pakai	$0,353 \times 0,111 \times 0,111 \times 0,222$	0,0010
Perlu Perawatan	$0,353 \times 0,111 \times 0,111 \times 0,667$	0,0029
Rusak	$0,294 \times 0,750 \times 0,750 \times 0,250$	0,0414

Hasil komputasi menunjukkan kelas Rusak memperoleh nilai probabilitas tertinggi (0,0414) dibandingkan kelas Perlu Perawatan (0,0029) dan Layak Pakai (0,0010). Mengacu pada prinsip Maximum A Posteriori, sistem secara otomatis mengklasifikasikan komponen tersebut ke dalam kategori Rusak, sehingga PT. Diginusa perlu segera menindaklanjuti perbaikan alat robotik terkait.

3.3. Evaluasi Model

Evaluasi dilakukan untuk mengukur keandalan model Naïve Bayes dalam mengklasifikasikan kondisi komponen. Model dibentuk dari 17 data latih yang telah dikategorikan melalui binning (Tabel 9) dan diuji terhadap 17 data uji dengan membandingkan hasil prediksi terhadap status aktualnya (Tabel 10). Kinerja model diukur menggunakan tiga metrik utama, yaitu accuracy, precision, dan recall, yang dihitung dengan persamaan (3), (4), dan (5).

$$Accuracy = (TP + TN) / (TP + TN + FP + FN) \times 100\% \quad (3)$$

$$Precision = TP / (TP + FP) \quad (4)$$

$$Recall = TP / (TP + FN) \quad (5)$$

dengan TP (True Positive) dan TN (True Negative) adalah jumlah prediksi benar, sedangkan FP (False Positive) dan FN (False Negative) adalah jumlah prediksi salah. Rincian data latih hasil binning dan data uji beserta hasil prediksinya disajikan pada Tabel 9 dan Tabel 10.

Tabel 9. Data Latih Hasil Binning (17 Data)

No	Nama Komponen	Jam	Vibrasi	Frekuensi	Status Kondisi
1	Servo Motor MG996R	Rendah	Rendah	Rendah	Layak Pakai
2	Sensor Ultrasonik HC-SR04	Rendah	Rendah	Rendah	Layak Pakai
3	Main Controller Arduino Mega	Rendah	Rendah	Sedang	Layak Pakai
4	Motor DC Gearbox	Rendah	Rendah	Rendah	Layak Pakai
5	Baterai Lithium 3S	Sedang	Rendah	Rendah	Layak Pakai
6	Sensor IR Proximity	Rendah	Rendah	Rendah	Layak Pakai
7	Servo Motor MG996R	Sedang	Sedang	Sedang	Perlu Perawatan
8	Motor DC Gearbox	Sedang	Sedang	Sedang	Perlu Perawatan
9	Baterai Lithium 3S	Sedang	Rendah	Sedang	Perlu Perawatan
10	Main Controller Arduino Mega	Sedang	Sedang	Sedang	Perlu Perawatan
11	Aktuator Linear	Sedang	Sedang	Tinggi	Perlu Perawatan
12	Gripper Servo	Sedang	Sedang	Sedang	Perlu Perawatan
13	Servo Motor MG996R	Tinggi	Tinggi	Tinggi	Rusak
14	Motor DC Gearbox	Tinggi	Tinggi	Tinggi	Rusak
15	Baterai Lithium 3S	Tinggi	Tinggi	Sedang	Rusak
16	Main Controller Arduino Mega	Tinggi	Tinggi	Tinggi	Rusak
17	Aktuator Linear	Tinggi	Tinggi	Tinggi	Rusak

Tabel 10. Data Uji beserta Hasil Prediksi (17 Data)

No	Nama Komponen	Jam	Vibrasi	Frekuensi	Status Aktual	Status Prediksi	Ket
1	Gripper Servo	Rendah	Sedang	Rendah	Layak Pakai	Layak Pakai	Benar
2	Kamera Modul OV7670	Rendah	Rendah	Rendah	Layak Pakai	Layak Pakai	Benar
3	Roda Omni Wheel	Rendah	Rendah	Rendah	Layak Pakai	Layak Pakai	Benar
4	Sensor Gyro MPU6050	Sedang	Rendah	Rendah	Layak Pakai	Layak Pakai	Benar
5	Konektor Kabel Jumper	Rendah	Rendah	Rendah	Layak Pakai	Layak Pakai	Benar
6	Motor Servo SG90	Sedang	Sedang	Rendah	Layak Pakai	Perlu Perawatan	Salah
7	Sensor Ultrasonik HC-SR04	Tinggi	Sedang	Sedang	Perlu Perawatan	Perlu Perawatan	Benar
8	Roda Omni Wheel	Sedang	Sedang	Sedang	Perlu Perawatan	Perlu Perawatan	Benar
9	Motor DC Gearbox	Sedang	Rendah	Sedang	Perlu Perawatan	Perlu Perawatan	Benar
10	Servo Motor MG996R	Sedang	Tinggi	Sedang	Perlu Perawatan	Perlu Perawatan	Benar
11	Sensor Cahaya LDR	Sedang	Rendah	Rendah	Perlu Perawatan	Layak Pakai	Salah
12	Sensor Ultrasonik HC-SR04	Tinggi	Sedang	Tinggi	Rusak	Rusak	Benar
13	Gripper Servo	Tinggi	Tinggi	Tinggi	Rusak	Rusak	Benar
14	Roda Omni Wheel	Tinggi	Tinggi	Sedang	Rusak	Rusak	Benar
15	Sensor Gyro MPU6050	Sedang	Tinggi	Tinggi	Rusak	Rusak	Benar
16	Kamera Modul OV7670	Tinggi	Tinggi	Tinggi	Rusak	Rusak	Benar
17	Baterai Li-Po 2200mAh	Tinggi	Sedang	Sedang	Rusak	Perlu Perawatan	Salah

Hasil prediksi pada data uji kemudian disusun ke dalam confusion matrix. Pada data latih, seluruh 17 data terklasifikasi benar sehingga diperoleh akurasi 100%, yang menunjukkan model berhasil mempelajari pola data latih dengan baik. Hasil pengujian pada data uji ditunjukkan pada Tabel 11.

Tabel 11. Confusion Matrix Data Uji (17 Data)

Aktual \ Prediksi	Layak Pakai	Perlu Perawatan	Rusak	Total
Layak Pakai	5	1	0	6
Perlu Perawatan	1	4	0	5
Rusak	0	1	5	6

Dari 17 data uji, sebanyak 14 data terklasifikasi benar dan 3 data salah, sehingga akurasi data uji = $(14/17) \times 100\% = 82,35\%$. Nilai precision dan recall tiap kelas disajikan pada Tabel 12.

Tabel 12. Precision dan Recall Data Uji


Kelas	Precision	Recall
Layak Pakai	0,833	0,833
Perlu Perawatan	0,667	0,800
Rusak	1,000	0,833
Rata-rata	0,833	0,822

Berdasarkan hasil tersebut, model Naïve Bayes dinilai mampu mengklasifikasikan kondisi komponen dengan cukup baik pada data yang belum pernah dilatih sebelumnya. Kesalahan klasifikasi umumnya terjadi pada batas antara kelas Layak Pakai dan Perlu Perawatan, yang disebabkan oleh kemiripan pola fitur pada kategori tersebut serta keterbatasan jumlah data latih.

Jika dibandingkan dengan penelitian terkait pada Tabel 1, akurasi 82,35% berada pada rentang yang wajar untuk klasifikasi multiclass. Nilai ini lebih tinggi dibandingkan penelitian Erni et al. [2] yang memperoleh akurasi 72,48% pada klasifikasi dua kelas stok barang, meskipun masih di bawah penelitian Guntur dan Kamarudin [5] sebesar 93%, Aulia et al. [1] sebesar 97,90%, dan Monowati serta Setyadi [3] yang mencapai 100%. Perbedaan tersebut wajar mengingat penelitian ini menangani klasifikasi tiga kelas dengan dataset yang relatif kecil (34 record) dan pembagian data yang seimbang (50% : 50%), sehingga model diuji pada proporsi data uji yang cukup besar. Hal ini menunjukkan bahwa penambahan jumlah data latih berpotensi meningkatkan akurasi model pada penerapan selanjutnya.

3.4. Implementasi Antarmuka Sistem

Hasil perancangan diimplementasikan menjadi halaman aplikasi berbasis web. Halaman login menjadi pintu masuk utama sistem yang membatasi akses hanya kepada pengguna terdaftar; setelah autentikasi berhasil, pengguna diarahkan ke dashboard sesuai perannya. Tampilan halaman login ditunjukkan pada Gambar 4.




Gambar 4. Implementasi Halaman Login

Halaman dashboard berfungsi sebagai pusat kendali yang menampilkan ringkasan metrik inventaris, seperti total komponen, jumlah item rusak, status perawatan, dan perbaikan tertunda, serta visualisasi distribusi inventaris. Tampilan halaman dashboard ditunjukkan pada Gambar 5.



Gambar 5. Implementasi Halaman Dashboard

Halaman Daftar Komponen menampilkan seluruh komponen robotik beserta model, nomor serial, jumlah stok, lokasi penyimpanan, dan status kondisinya yang ditandai dengan warna berbeda untuk kategori Layak Pakai, Perlu Perawatan, dan Rusak. Melalui halaman ini pengguna dapat menambah, mengubah, dan menghapus data komponen. Tampilan halaman ini ditunjukkan pada Gambar 6.



No	Nama Komponen	Status	Jumlah	Lokasi	Aksi
1	Robotik Dasar	Normal	10	Lab. Robotika	[Edit] [Hapus]
2	Motor DC	Normal	20	Lab. Robotika	[Edit] [Hapus]
3	Baterai 18650	Normal	50	Lab. Robotika	[Edit] [Hapus]
4	Arduino Uno	Normal	10	Lab. Robotika	[Edit] [Hapus]
5	Motor Stepper	Normal	10	Lab. Robotika	[Edit] [Hapus]
6	Sensor Ultrasonik	Normal	10	Lab. Robotika	[Edit] [Hapus]
7	Modul Relay	Normal	10	Lab. Robotika	[Edit] [Hapus]
8	Modul Motor Driver	Normal	10	Lab. Robotika	[Edit] [Hapus]
9	Modul Kamera	Normal	10	Lab. Robotika	[Edit] [Hapus]
10	Modul GPS	Normal	10	Lab. Robotika	[Edit] [Hapus]

Gambar 6. Implementasi Halaman Daftar Komponen

Halaman Laporan Kerusakan digunakan untuk memantau dan menindaklanjuti laporan kerusakan alat yang dikirimkan oleh Guru. Setiap laporan menampilkan komponen terkait, pelapor, tanggal, tingkat prioritas, dan status penanganannya, sehingga proses perbaikan dapat dikelola secara terstruktur. Tampilan halaman ini ditunjukkan pada Gambar 7.



No	Tgl Laporan	Komponen	Pelapor	Status	Prioritas	Aksi
1	2023-09-01	Robotik Dasar	Guru	Proses	Normal	[Edit] [Hapus]
2	2023-09-02	Motor DC	Guru	Proses	Normal	[Edit] [Hapus]
3	2023-09-03	Baterai 18650	Guru	Proses	Normal	[Edit] [Hapus]
4	2023-09-04	Arduino Uno	Guru	Proses	Normal	[Edit] [Hapus]
5	2023-09-05	Motor Stepper	Guru	Proses	Normal	[Edit] [Hapus]
6	2023-09-06	Sensor Ultrasonik	Guru	Proses	Normal	[Edit] [Hapus]
7	2023-09-07	Modul Relay	Guru	Proses	Normal	[Edit] [Hapus]
8	2023-09-08	Modul Motor Driver	Guru	Proses	Normal	[Edit] [Hapus]
9	2023-09-09	Modul Kamera	Guru	Proses	Normal	[Edit] [Hapus]
10	2023-09-10	Modul GPS	Guru	Proses	Normal	[Edit] [Hapus]

Gambar 7. Implementasi Halaman Laporan Kerusakan

Halaman Formulir Perbaikan digunakan untuk mencatat tindakan perbaikan teknis berdasarkan laporan kerusakan yang dipilih, meliputi pembaruan status, teknisi, serta kondisi komponen sebelum dan sesudah perbaikan. Data hasil perbaikan inilah yang selanjutnya memperkaya riwayat komponen sebagai bahan prediksi kondisi. Tampilan halaman ini ditunjukkan pada Gambar 8.



Gambar 8. Implementasi Halaman Formulir Perbaikan

Halaman Manajemen Pengguna hanya dapat diakses oleh Akademik selaku admin dan digunakan untuk menambah, mengubah, serta menghapus akun pengguna beserta perannya. Halaman ini memastikan pembatasan hak akses tiap aktor berjalan sesuai rancangan. Tampilan halaman ini ditunjukkan pada Gambar 9.



No	Nama Pengguna	Role	Status	Lokasi	Aksi
1	Admin	Admin	Active	Lab. Robotika	[Edit] [Hapus]
2	Guru	Guru	Active	Lab. Robotika	[Edit] [Hapus]
3	Mahasiswa	Mahasiswa	Active	Lab. Robotika	[Edit] [Hapus]
4	Guest	Guest	Active	Lab. Robotika	[Edit] [Hapus]

Gambar 9. Implementasi Halaman Manajemen Pengguna

Halaman Statistik & Tren menyajikan rekapitulasi pemeliharaan inventaris dalam bentuk kartu ringkasan analitik dan grafik batang frekuensi kerusakan antar komponen, sehingga manajemen dapat memantau tren kerusakan dan menindaklanjuti hasil prediksi kondisi komponen secara proaktif. Tampilan halaman ini ditunjukkan pada Gambar 10.



Gambar 10. Implementasi Halaman Statistik & Tren

3.5. Pengujian Sistem

Pengujian sistem dilakukan menggunakan dua pendekatan, yaitu Black Box dan White Box. Pengujian Black Box berfokus pada fungsionalitas aplikasi dari sudut pandang pengguna tanpa memeriksa struktur kode internal, meliputi autentikasi login, pembatasan hak akses tiap aktor, penanganan input tidak valid, serta penyimpanan dan penyajian data. Ringkasan hasil pengujian Black Box untuk setiap aktor disajikan pada Tabel 13.

Tabel 13. Ringkasan Hasil Pengujian Black Box

Aktor	Fungsi yang Diuji	Hasil
Akademik	Login, manajemen pengguna, kelola komponen & laporan, formulir perbaikan, statistik, cetak laporan	Valid
Manajer	Login, lihat data kerusakan, pantau perbaikan, statistik & prediksi, cetak laporan	Valid
Guru	Login, lapor kerusakan, lihat data kerusakan & daftar komponen	Valid
Marketing	Login, kelola komponen, lihat kerusakan, statistik & prediksi, cetak laporan	Valid
SPV Operasional	Login, lihat data kerusakan, pantau perbaikan, prediksi, cetak laporan	Valid

Seluruh skenario Black Box memberikan hasil yang sesuai dengan harapan (Valid), termasuk penolakan login dengan kredensial salah dan pembatasan akun Marketing serta Guru terhadap menu administrator. Sementara itu, pengujian White Box dilakukan dengan menganalisis alur logika program menggunakan flowgraph dan perhitungan cyclomatic complexity pada modul otentikasi dan otorisasi tiap aktor.

Perhitungan cyclomatic complexity menggunakan rumus $V(G) = E - N + 2$, dengan E adalah jumlah edge dan N adalah jumlah node pada flowgraph. Nilai $V(G)$ menunjukkan jumlah jalur independen yang harus diuji pada setiap modul. Hasil pengujian White Box menunjukkan bahwa seluruh jalur independen pada alur otentikasi dan otorisasi setiap aktor dapat dieksekusi dengan benar sesuai dengan hak akses yang dirancang, tanpa ditemukan jalur logika yang menyimpang, sehingga logika sistem dinyatakan telah berjalan sebagaimana mestinya.

Dengan demikian, sistem tidak hanya menggantikan pencatatan manual yang tersebar menjadi pencatatan terpusat dan terstruktur, tetapi juga memberikan dukungan keputusan berbasis data. Komponen yang terprediksi “Rusak” dapat segera diganti dan yang “Perlu Perawatan” dijadwalkan perbaikan preventif, sehingga potensi gangguan pada program edukasi robotik dapat diminimalkan.

4. KESIMPULAN

Sistem inventaris berbasis web yang dibangun berhasil mengatasi permasalahan pencatatan manual yang tidak efisien dengan mengubahnya menjadi pencatatan terstruktur dan terpusat, sehingga pemantauan kondisi aset berjalan lebih konsisten, transparan, dan tidak lagi bergantung pada perkiraan subjektif pengguna. Penerapan algoritma Naïve Bayes berhasil menjawab kebutuhan sistem prediktif dengan mengklasifikasikan kondisi komponen ke dalam tiga status, yaitu Layak Pakai, Perlu Perawatan, dan Rusak, berdasarkan data historis pemeliharaan. Hasil pengujian melalui confusion matrix menunjukkan akurasi 100% pada data latih dan 82,35% pada data uji, dengan rata-rata precision 0,833 dan recall 0,822, yang membuktikan metode ini andal untuk diterapkan. Hasil prediksi yang disajikan melalui dashboard membantu manajemen mengambil keputusan pemeliharaan secara lebih proaktif dan berbasis data. Komponen yang aus dapat dijadwalkan pemeliharaan preventif dan yang rusak dapat segera diganti, sehingga sistem ini berkontribusi menekan gangguan program edukasi, mengurangi biaya perbaikan tak terduga, serta menjaga kelancaran operasional dan kepercayaan klien di PT. Diginusa. Untuk penelitian selanjutnya, sistem dapat

dikembangkan dengan menambah parameter lain, menguji metode klasifikasi lain sebagai pembanding, serta melengkapi fitur peringatan dini berupa notifikasi otomatis saat komponen terdeteksi rusak.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pamulang, serta dosen pembimbing atas bimbingan dan arahannya. Ucapan terima kasih juga disampaikan kepada PT. Bangun Satya Wacana (Diginusa) yang telah memberikan kesempatan, data, dan dukungan selama pelaksanaan penelitian ini.

REFERENSI

- [1] I. R. Aulia, A. Hermawan, and D. Avianto, "Pendekatan Hybrid: Naïve Bayes dan Decision Tree untuk Prediksi Kerusakan Mesin pada Industri Manufaktur PT X," *IJAI (Indonesian Journal of Applied Informatics)*, vol. 9, no. 2, pp. 554–563, 2025, doi: 10.20961/ijai.v9i2.97905.
- [2] E. Erni, K. Kamarudin, and W. Windarsyah, "Klasifikasi Stok Barang Menggunakan Naïve Bayes untuk Optimalisasi Persediaan Toko Ahmad Adam," *Jurnal Ilmiah Teknik Mesin, Elektro dan Komputer (JURITEK)*, vol. 5, no. 2, pp. 292–303, 2025, doi: 10.51903/juritek.v5i2.3907.
- [3] I. T. Monowati and R. Setyadi, "Penerapan Algoritma Naïve Bayes dalam Memprediksi Pengusulan Penghapusan Peralatan dan Mesin Kantor," *Journal of Information System Research (JOSH)*, vol. 4, no. 2, pp. 483–491, 2023, doi: 10.47065/josh.v4i2.2674.
- [4] A. P. Putra, N. T. Lapatta, and H. R. Ngemba, "Implementation of Naïve Bayes for Optimizing Asset Condition Classification in a Web-Based Information System," *Technomedia Journal (TMJ)*, vol. 10, no. 3, pp. 134–145, 2026, doi: 10.33050/tmj.v10i3.2273.
- [5] G. Guntur and K. Kamarudin, "Penerapan Metode Naïve Bayes dengan Sistem Pakar dalam Mendiagnosa Kerusakan pada Mesin Mobil," *Jurnal Ilmiah Sistem Informasi dan Teknik Informatika (JISTI)*, vol. 7, no. 1, pp. 177–186, 2024.
- [6] J. Han, J. Pei, and H. Tong, *Data Mining: Concepts and Techniques*, 4th ed. Cambridge, MA, USA: Morgan Kaufmann/Elsevier, 2023.
- [7] P. W. Rahayu, I. G. I. Sudipa, S. Suryani, A. Surachman, A. Ridwan, and I. G. M. Darmawiguna, *Buku Ajar Data Mining*. Sonpedia, 2024.
- [8] F. Chinesta et al., *A Gentle Introduction to Data, Learning, and Model Order Reduction*, Studies in Big Data, vol. 174. Springer, 2025.
- [9] C.-S. Yang, *Building User Interfaces for Modern Web Applications: React Programming*. PA-ADOPT, 2024.
- [10] A. R. K. Maranto, *Desain dan Pengembangan Web (HTML, CSS, dan JavaScript)*. Tangerang, Indonesia: Universitas Buddhi Dharma, 2023.
- [11] U. Gandhi, "JavaScript and the Earth Engine API," in *Cloud-Based Remote Sensing with Google Earth Engine*. Springer, 2024, pp. 3–17.
- [12] Huawei Technologies Co., Ltd., *Database Principles and Technologies – Based on Huawei GaussDB*. Springer, 2023.
- [13] A. P. Nicolau, K. Dyson, and D. Saah, "Accuracy Assessment: Quantifying Classification Quality," in *Cloud-Based Remote Sensing with Google Earth Engine*. Springer, 2024, pp. 135–145.
- [14] M. Biehl, *The Shallow and the Deep: A Biased Introduction to Neural Networks and Old School Machine Learning*. Groningen, The Netherlands: University of Groningen, 2023.
- [15] J.-C. Franchitti, *Introduction to Computer Science*. Houston, TX, USA: OpenStax, Rice University, 2026.
- [16] M. Saqr, K. Misiejuk, S. Tikka, and S. López-Pernas, "Artificial Intelligence: Using Machine Learning to Classify Students and Predict Low Achievers," in *Advanced Learning Analytics Methods*. Springer, 2026, pp. 79–98.