

Implementasi Metode Naive Bayes Classifier dalam Menentukan Diagnosa Kerusakan pada Smartphone

Adam Perdana Septyana*, Esa Fauzi

Fakultas Teknik, Teknik Informatika, Universitas Widyatama, Bandung, Indonesia

Email: ^{1,*}adam.perdana@widyatama.ac.id, ²esa.fauzi@widyatama.ac.id

Email Penulis Korespondensi: adam.perdana@widyatama.ac.id*

Submitted: 15/07/2025; Accepted: 26/07/2025; Published: 08/09/2025

Abstrak—Kerusakan pada smartphone merupakan permasalahan umum yang sering dialami oleh pengguna, namun tidak semua pengguna memahami solusi yang tepat atas permasalahan tersebut. Oleh karena itu, dibutuhkan suatu sistem yang dapat membantu dalam mendiagnosa kerusakan smartphone secara cepat dan akurat. Teknologi machine learning dapat dimanfaatkan untuk membantu teknisi dalam proses diagnosis dengan menggunakan metode Naive Bayes Classifier. Metode ini menggunakan empat atribut utama dalam menentukan probabilitas kerusakan, yaitu kronologi, merek smartphone, konsumsi arus listrik, dan gejala. Naive Bayes dipilih karena kesederhanaannya, kemampuannya dalam menangani data yang tidak seimbang, serta kinerjanya yang baik dalam klasifikasi. Data gejala dan jenis kerusakan diperoleh dari teknisi smartphone dan literatur relevan. Sistem ini diharapkan dapat menjadi alat bantu bagi pengguna maupun teknisi dalam melakukan identifikasi awal terhadap kerusakan smartphone secara lebih efisien dan akurat.

Kata Kunci: Kerusakan Smartphone; Machine Learning; Naive Bayes; Sistem Diagnosa; Prediksi Kerusakan; Probabilitas kerusakan

Abstract—Smartphone damage is a common issue frequently experienced by users, yet not all users are aware of the appropriate solutions to address such problems. Therefore, a system capable of diagnosing smartphone damage quickly and accurately is needed. Machine learning technology can support technicians in the diagnostic process by applying the Naive Bayes Classifier method. This method utilizes four main attributes to determine the probability of damage: incident chronology, smartphone brand, electric current consumption, and observed symptoms. Naive Bayes is chosen due to its simplicity, ability to handle imbalanced data, and strong performance in classification tasks. The data regarding symptoms and types of damage were obtained from smartphone technicians and relevant literature. This system is expected to serve as a decision support tool for both users and technicians in the initial identification of smartphone damage in a more efficient and accurate manner.

Keywords: Smartphone Damage; Machine Learning; Naive Bayes Classifier; Diagnostic System; Fault Prediction; Probability

1. PENDAHULUAN

Perkembangan teknologi komunikasi yang sangat pesat dalam beberapa dekade terakhir telah mengubah cara manusia berinteraksi dan mengakses informasi. Salah satu perangkat yang menjadi pusat dari revolusi digital ini adalah smartphone. Tidak hanya digunakan untuk komunikasi, smartphone juga telah berevolusi menjadi alat serbaguna yang mendukung berbagai aktivitas sehari-hari seperti pekerjaan, hiburan, pendidikan, dan transaksi digital. Berdasarkan laporan Gartner, penjualan smartphone global kepada pengguna akhir tumbuh sebesar 26% pada kuartal pertama tahun 2021 [1].

Namun, di balik kemudahan yang ditawarkan, penggunaan smartphone tidak lepas dari risiko kerusakan, baik akibat penggunaan jangka panjang, kelalaian pengguna, maupun cacat produksi. Kerusakan tersebut dapat terjadi pada komponen perangkat keras seperti layar, baterai, dan motherboard, maupun perangkat lunak seperti sistem operasi dan aplikasi [2]. Jika tidak ditangani secara dini, kerusakan ini dapat berdampak pada hilangnya data, menurunnya performa perangkat, hingga kerusakan total [3]. Oleh karena itu, dibutuhkan sistem deteksi dini yang mampu menganalisis dan mengklasifikasikan kerusakan dengan cepat dan akurat.

Salah satu pendekatan yang menjanjikan dalam pengembangan sistem diagnosis kerusakan adalah penerapan algoritma machine learning [4]. Naive Bayes Classifier merupakan salah satu algoritma yang populer dalam tugas klasifikasi karena kesederhanaannya dalam implementasi, efisiensi komputasi, dan kemampuannya menangani data yang tidak seimbang [5]. Algoritma ini bekerja berdasarkan prinsip probabilitas dari Teorema Bayes, dengan mengasumsikan independensi antar fitur [6]. Penggunaannya telah terbukti efektif dalam berbagai studi, mulai dari pengenalan aktivitas berbasis sensor [7], diagnosis kesehatan pada perangkat mobile [8], hingga deteksi ancaman keamanan pada sistem pintar [9].

Beberapa penelitian menerapkan Naive Bayes dalam sistem pendukung keputusan untuk perbaikan smartphone, dengan memanfaatkan gejala yang diinput pengguna untuk memprediksi jenis kerusakan. Hasilnya menunjukkan performa yang cukup baik dalam akurasi dan kecepatan diagnosis. Dalam praktiknya, proses perbaikan smartphone menghasilkan berbagai data seperti informasi pelanggan, waktu layanan, keluhan, status garansi, serta catatan penggantian komponen [10]. Data ini dapat digunakan sebagai fitur dalam pelatihan model klasifikasi guna memprediksi jenis kerusakan yang mungkin terjadi. Implementasi Naive Bayes dalam konteks ini telah terbukti dapat membantu teknisi dalam mengidentifikasi kerusakan secara lebih efisien, meningkatkan akurasi diagnosis, serta mengurangi waktu dan biaya perbaikan [11]. Sistem pendukung keputusan untuk perbaikan perangkat mobile dengan menerapkan algoritma Naive Bayes, yang terbukti mampu mengklasifikasikan jenis kerusakan berdasarkan gejala yang diinputkan oleh pengguna. Hasil penelitian mereka menunjukkan bahwa metode ini efektif dalam memberikan rekomendasi perbaikan secara cepat dan akurat [12]. Studi lain menunjukkan

bahwa integrasi data historis layanan (seperti status garansi, catatan perbaikan, dan keluhan pengguna) dalam pelatihan model machine learning dapat meningkatkan akurasi diagnosis dan efisiensi proses layanan. Integrasi sistem pendukung keputusan berbasis machine learning dapat meningkatkan kecepatan dan akurasi dalam proses diagnosa kerusakan. Sistem ini juga membantu teknisi dalam mengambil keputusan yang lebih tepat berdasarkan data historis dan pola kerusakan yang telah teridentifikasi sebelumnya [13]. Penerapan sistem diagnosis berbasis machine learning tidak hanya meningkatkan akurasi dalam identifikasi kerusakan perangkat, tetapi juga berdampak signifikan terhadap kepuasan pengguna dan produktivitas teknisi dalam proses layanan perbaikan [14]. Selain itu, sistem prediktif ini juga dapat dimanfaatkan sebagai media pembelajaran bagi teknisi baru untuk memahami pola-pola kerusakan perangkat [15]. Penelitian lebih lanjut menyoroti pentingnya pemeliharaan prediktif menggunakan model klasifikasi, guna memprediksi kerusakan sebelum terjadi. Hal ini berkontribusi terhadap peningkatan umur perangkat dan pengurangan biaya layanan. Metode Naive Bayes telah menunjukkan efektivitas yang tinggi dalam tugas klasifikasi kerusakan pada perangkat smartphone. Studi sebelumnya mengungkapkan bahwa metode ini mampu mengidentifikasi berbagai jenis kerusakan dengan tingkat akurasi yang baik serta waktu komputasi yang relatif efisien [16]. Hal ini menjadikan Naive Bayes sebagai salah satu algoritma yang cocok digunakan dalam pengembangan sistem diagnosis otomatis berbasis data untuk mendukung layanan teknis yang cepat dan akurat [17]. Lebih lanjut, pemeliharaan prediktif pada perangkat smartphone juga menjadi fokus penting dalam sejumlah penelitian terkini. Pendekatan ini memanfaatkan algoritma machine learning untuk memprediksi kemungkinan terjadinya kerusakan sebelum benar-benar terjadi, sehingga memungkinkan perpanjangan umur perangkat dan pengurangan biaya perbaikan yang signifikan [18]. Implementasi aplikasi berbasis Naive Bayes untuk mendeteksi kerusakan smartphone telah menunjukkan performa yang menjanjikan, terutama dalam mengklasifikasikan berbagai jenis kerusakan berdasarkan gejala yang dimasukkan oleh pengguna [19]. Selain itu, pendekatan klasifikasi Bayesian juga terbukti efektif dalam menangani data historis yang kompleks, serta mampu menghasilkan prediksi yang akurat untuk kebutuhan diagnosis berbasis riwayat kerusakan perangkat [20].

Meskipun berbagai studi sebelumnya menunjukkan potensi besar dalam penerapan algoritma Naive Bayes untuk diagnosis kerusakan smartphone, masih terdapat sejumlah kelemahan metodologis yang signifikan. Beberapa penelitian hanya mengevaluasi kinerja model berdasarkan akurasi keseluruhan, tanpa menyertakan metrik penting lainnya seperti precision, recall, dan F1-score pada masing-masing kelas. Hal ini menyebabkan evaluasi terhadap performa model menjadi kurang komprehensif, terutama dalam menangani kelas minoritas yang memiliki representasi data lebih rendah. Selain itu, interpretasi terhadap performa rendah pada kelas tertentu cenderung dangkal dan tidak mempertimbangkan aspek distribusi label atau kualitas fitur yang digunakan. Beberapa studi bahkan menyajikan klaim akurasi tinggi tanpa disertai bukti kuat berupa metrik evaluasi yang memadai. Kekurangan-kekurangan tersebut menunjukkan pentingnya pengembangan sistem diagnosis yang tidak hanya fokus pada akurasi secara umum, tetapi juga menyajikan hasil evaluasi yang informatif, terstruktur, dan dapat diinterpretasikan secara mendalam.


Menanggapi hal tersebut, penelitian ini bertujuan untuk mengembangkan sistem diagnosis kerusakan smartphone berbasis algoritma Naive Bayes dengan indikator keberhasilan yang mencakup akurasi, precision, recall, dan F1-score per kelas, efisiensi waktu komputasi model, serta kemampuan model dalam menangani distribusi kelas yang tidak seimbang. Selain itu, hasil evaluasi akan disajikan dalam bentuk tabel yang informatif untuk memberikan gambaran performa model secara menyeluruh.

Kontribusi utama dari penelitian ini adalah penyusunan sistem diagnosis kerusakan berbasis data yang akurat, efisien, dan memiliki struktur evaluasi yang mendalam. Penambahan fitur-fitur baru seperti suhu komponen, durasi penggunaan, dan riwayat kerusakan juga direncanakan sebagai bagian dari strategi peningkatan performa sistem. Dengan demikian, sistem diagnosis yang dikembangkan diharapkan mampu meningkatkan kualitas layanan teknis dan mendukung pengambilan keputusan yang lebih tepat dan cepat dalam proses perbaikan smartphone.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Berikut ini tahapan penelitian dapat dilihat pada gambar dibawah ini.



Gambar 1. Tahapan Penelitian

2.1.1 Identifikasi Masalah

Banyak pengguna smartphone mengalami kesulitan dalam mengenali jenis kerusakan yang terjadi berdasarkan gejala awal yang muncul. Hal ini berdampak pada keterlambatan proses perbaikan dan kemungkinan kerusakan menjadi lebih parah. Oleh karena itu, diperlukan suatu sistem klasifikasi otomatis yang mampu memprediksi jenis kerusakan berdasarkan data gejala yang dimasukkan pengguna. Tujuan dari penelitian ini adalah untuk mengembangkan model klasifikasi kerusakan smartphone dengan memanfaatkan algoritma Naive Bayes, yang dikenal mampu menangani data kategorikal dengan efisien dan akurat.


2.1.2 Pengumpulan Data

Penelitian ini disusun berdasarkan hasil pengumpulan data secara komprehensif dari berbagai sumber. Proses pengumpulan dilakukan melalui wawancara dengan teknisi servis profesional dan pengumpulan data historis layanan perbaikan di PT.Metrix Flasher bapak Denny Ichwan Supriatno yang merupakan perusahaan teknisi smartphone pertama di Bandung yang telah berdiri dari tahun 1997, telaah literatur, serta pengumpulan data historis layanan perbaikan smartphone dari beberapa pusat servis. Sehingga mendapatkan dataset mencakup atribut-atribut berikut.

Table 1. Atribut

Kronologi	Terkena Air, Terbentur, Perbaikan Hardware, Perbaikan Software, Sedang Digunakan
Daftar Kerusakan	IC Transuder, LCD, Kapasitor, Induktor, Ocilator, UFS, Software, IC RF / WTR, IC PA / FEM, IC WiFi / Bluetooth, IC LK / IC Backlight / IC Display, Display, Baterai, Modul kamera, IC Power, IC PMI, CPU / Chipset
Gejala	Tidak ada kenaikan Arus, Ampere naik sebelum ON, Tersiram Air / Dead Water, BATT_ID / BATT_TEMP tidak ada hambatan, Mati tapi, colok charger restart, Port USB tidak terbaca, Port USB terbaca MediaTek Preloader USB VCOM, Layar biru / bluescreen, Ampere gantung, Tidak bisa hidup / HP mati, Kamera tidak berfungsi, Tidak ada tampilan pada layar / blank, Hang sampai logo / stack logo, Port USB terbaca QDLoader 9008, Tidak bisa flash / gagal flash, Restart sampai logo / bootloop, Port USB terbaca MediaTek USB Port, Hanya getar, WiFi / Bluetooth tidak berfungsi, Charger error, Tidak ada sinyal, IMEI ada / IMEI terdaftar, Ampere naik kemudian turun.
Konsumsi Arus	0 mA, 0-25 mA, 30-50mA, 60-120mA, 120-170mA, 1-2 A, >2 A,


Setiap entri dalam dataset terdiri dari kombinasi fitur-fitur tersebut yang dihubungkan dengan label kelas kerusakan tertentu.



Gambar 1 Entry Relation Diagram

2.1.3 Pra-Pemrosesan Data

Pra-pemrosesan data merupakan tahapan krusial dalam pengolahan data sebelum digunakan oleh algoritma Naive Bayes. Proses ini bertujuan untuk memastikan bahwa data yang digunakan bersih, konsisten, dan dalam format yang sesuai untuk dilakukan klasifikasi.



Gambar 2 Alur Pra-Pemrosesan Data

- Pembersihan Data (Cleaning):** Dataset hasil input pengguna maupun historis dari teknisi dibersihkan dari nilai kosong (missing value), seperti atribut gejala yang belum diisi dan duplikasi entri, yang bisa menyebabkan bias dalam proses pembelajaran mesin.
- Konversi Data Kategorikal ke Numerik (Encoding):** Seluruh atribut input yang bersifat kategorikal seperti kronologi, gejala, brand, dan konsumsi arus listrik diubah ke format numerik, contohnya "Ya" → 1, "Tidak" → 0, dan kategori gejala atau brand dikodekan menggunakan indeks angka dan data gejala dapat berupa list multiple choice, sehingga dilakukan representasi biner multi-label untuk gejala yang dipilih lebih dari satu.
- Standarisasi Format dan Validasi Input:** Format data dari pengguna distandarkan, misalnya dari segi huruf kapitalisasi, penggunaan karakter khusus, dan panjang minimal.
- Pembagian Data:** Data historis sebanyak 78 entri dibagi menjadi 2 yaitu Training set (70%) sebanyak 55 data dan Testing set (30%) sebanyak 23 data. Proses pembagian dilakukan secara acak (random) oleh pembimbing lapangan untuk keperluan metode closed testing.
- Pemeriksaan Keseimbangan Data Kelas (Class Distribution Check):** Distribusi label kerusakan dievaluasi untuk menghindari ketimpangan kelas (class imbalance) yang bisa memengaruhi akurasi model. Jika perlu, dilakukan upaya penyesuaian seperti oversampling atau pemilihan data tambahan.
- Seleksi Atribut (Feature Selection):** Hanya 4 atribut utama yang digunakan untuk membentuk basis probabilitas yaitu Kronologi kerusakan, Brand smartphone, Konsumsi arus Listrik dan Gejala (dengan multiple input). Keempat atribut tersebut dipilih berdasarkan masukan dari teknisi lapangan dan relevansi terhadap jenis kerusakan komponen tertentu.

2.1.4 Pelatihan Model

Pada tahap ini, algoritma Naive Bayes digunakan untuk membangun model klasifikasi berdasarkan 55 data latih (70% dari total 78 data) yang telah melalui proses pra-pemrosesan. Tujuan dari pelatihan ini adalah agar model dapat mengenali pola hubungan antara gejala-gejala dan jenis kerusakan komponen pada smartphone.

2.1.5 Pengujian Model

Setelah model selesai dilatih, proses dilanjutkan dengan pengujian menggunakan 23 data uji (30% dari total data) yang tidak dilibatkan dalam proses pelatihan. Tujuannya adalah untuk menilai kemampuan model dalam mengklasifikasikan data yang belum dikenalnya. Tahap ini penting untuk melihat seberapa baik model dapat menggeneralisasi pola yang telah dipelajari terhadap data baru.

2.1.6 Evaluasi Kinerja

Setelah model selesai dilatih, proses dilanjutkan dengan pengujian menggunakan 23 data uji (30% dari total data) yang tidak dilibatkan dalam proses pelatihan. Tujuannya adalah untuk menilai kemampuan model dalam mengklasifikasikan data yang belum dikenalnya.

2.2 Studi Literatur

Bab ini akan menjelaskan secara singkat metodologi terkait yang diterapkan pada penelitian yang dilakukan.

2.2.1 Probabilitas

Probabilitas adalah suatu nilai untuk mengukur tingkat kemungkinan terjadinya suatu peristiwa yang belum pasti (uncertain event). Besarnya nilai kemungkinan bagi munculnya suatu kejadian adalah diantara 0 dan 1 yang dapat dituliskan sebagai $1 \geq P(A) \geq 0$, di mana $P(A)$ menyatakan nilai kemungkinan terjadinya peristiwa A . $P(A)=0,90$ artinya adalah probabilitas A akan terjadi sebesar 90% dan A tidak terjadi sebesar 10%.

2.2.2 Teorema Bayes

Teorema Bayes pertama kali diperkenalkan oleh matematikawan dan menteri Inggris Thomas Bayes, dan diterbitkan secara anumerta oleh temannya Richard Price pada tahun 1763. Motivasi awal di balik teorema tersebut adalah untuk memecahkan masalah probabilitas terbalik—menentukan kemungkinan suatu penyebab jika suatu peristiwa telah terjadi [4]. Teorema Bayes atau Hukum Bayes menggambarkan kemungkinan terjadinya suatu peristiwa berdasarkan pengetahuan sebelumnya tentang kondisi yang terkait dengan peristiwa tersebut. Di bawah ini adalah formula Teorema Bayes.

$$P(A|B) = \frac{P(B|A) \times P(A)}{P(B)} \quad (1)$$

Keterangan :

A dan B adalah suatu peristiwa.

$P(A|B)$ adalah probabilitas A setelah B terjadi atau disebut sebagai posterior probability.

$P(B|A)$ adalah probabilitas B setelah A terjadi atau disebut sebagai likelihood.

$P(A)$ adalah probabilitas A atau disebut sebagai prior probability.

$P(B)$ adalah probabilitas B atau disebut sebagai predictor.

Berikut adalah formula untuk mengetahui nilai probabilitas A , jika diketahui suatu peristiwa yang terkait dengan A , yaitu a, b dan c telah terjadi.

$$P(Y = A|a, b, c) = \frac{P(a|A) \times P(b|A) \times P(c|A) \times P(A)}{P(a) \times P(b) \times P(c)} \quad (2)$$

2.2.3 Akuisisi Pengetahuan

Untuk mendeteksi kerusakan pada smartphone, untuk menentukan probabilitas kerusakan smartphone lebih spesifik penulis menggunakan 4 atribut untuk menentukan nilai probabilitas posterior, yaitu kronologi, brand smartphone, konsumsi arus listrik dan gejala.

- a. Berikut adalah formula untuk menentukan nilai likelihood dan predictor untuk atribut brand smartphone.

$$\frac{\sum_{k=1}^n f(k=id \text{ brand})}{\sum_{p=1}^n f(p=id \text{ brand})} \quad (3)$$

- b. Setiap kerusakan memiliki beberapa gejala dan berikut ini adalah formula untuk menentukan nilai likelihood dan predictor atribut gejala.

$$\frac{\sum_{k=1}^n f(k=id \text{ gejala})}{\sum_{p=1}^n f(p=id \text{ gejala})} \quad (4)$$

- c. Konsumsi arus menandakan suatu grup unit menerima input atau output. Berikut ini adalah formula untuk menentukan nilai likelihood dan predictor atribut konsumsi arus.

$$\frac{\sum_{k=1}^n f(k=id \text{ arus})}{\sum_{p=1}^n f(p=id \text{ arus})} \quad (5)$$

- d. Sebelum melakukan perbaikan, teknisi menanyakan kronologi permasalahan kerusakan smartphone kepada penggunaanya. Berikut adalah formula untuk menentukan nilai likelihood dan predictor atribut kronologi

$$\frac{\sum_{k=1}^n f(k=id \text{ kronologi})}{\sum_{p=1}^n f(p=id \text{ kronologi})} \quad (6)$$

- e. Untuk menentukan nilai probabilitas prior masing-masing label adalah sebagai berikut.

$$\frac{\sum_{k=1}^n f(k=id \text{ label})}{n} \quad (7)$$

- f. Untuk menentukan nilai probabilitas posterior atau probabilitas kerusakan smartphone (label) adalah sebagai berikut.

$$\frac{f(\text{label}|\text{atribut1}, \text{atribut2}, \dots, \text{atributn})}{\frac{\text{likelihood atribut 1} \times \text{likelihood atribut 2} \times \dots \times \text{likelihood atribut n}}{\text{predictor atribut 1} \times \text{predictor atribut 2} \times \dots \times \text{predictor atribut n}}} \times \text{prior label} \quad (8)$$

3. HASIL DAN PEMBAHASAN

Tahapan selanjutnya merupakan tahapan lanjutan dari analisis dan perancangan yang telah disampaikan sebelumnya. Bentuk dari implementasi adalah sebuah sistem yang siap diuji dan digunakan. Tahapan implementasi memerlukan dukungan perangkat keras dan perangkat lunak.

Tabel 1. Dukungan Software dan Hardware yang diperlukan

Perangkat Lunak	Perangkat Keras
Windows 11 Home	Database MySQL
Intel® Core™ i5-11400H Processor 2.7 GHz	Interpreter NodeJS
RAM 8GB DDR4-3200 SO-DIMM.	Bahasa pemrograman JavaScript
Storage 512GB M.2 NVMe™ PCIe® 3.0 SSD.	Framework AdonisJS
VGA NVIDIA® GeForce RTX™ 3050.	Text editor menggunakan Visual Studio Code
	Phpmyadmin sebagai database management
	Firefox sebagai web browser

Pada tahap implementasi, sistem dikembangkan menggunakan dataset yang berisi data gejala kerusakan smartphone beserta label jenis kerusakannya. Dataset terlebih dahulu melalui tahap pra-pemrosesan, yaitu pembersihan data dari duplikasi dan nilai kosong, serta konversi data kategorikal ke bentuk numerik biner (1 untuk “Ya”, 0 untuk “Tidak”). Selanjutnya, dataset dibagi menjadi dua bagian, yaitu data latih sebesar 70% dan data uji sebesar 30%. Data latih digunakan untuk melatih model Naive Bayes, sedangkan data uji digunakan untuk mengukur performa model terhadap data baru.

Tabel 2. Hasil evaluasi model Naive Bayes

Index	Precision	Recall	F1-Score
Kapasitor	0.0	0.0	0.0
IC OVP/Dioda	0.0	0.0	0.0
Induktor	0.0	0.0	0.0
Ocillator	0.0	0.0	0.0
eMCP/eMMC	1.0	1.0	1.0
IC RF/WTR	0.0	0.0	0.0
IC PA/FEM	0.5	1.0	0.667
IC Wifi/ Bluetooth	0.0	0.0	0.0
Modul Kamera	0.0	0.0	0.0
IC Power	0.0	0.0	0.0
CPU/Chipset	1.0	0.8	0.889
IC PMI	1.0	1.0	1.0
Accuracy	0.826	0.826	0.826
Macro avg	0.291	0.317	0.296
Weighted avg	0.848	0.826	0.831

Berdasarkan hasil evaluasi model Naive Bayes, diperoleh bahwa model menunjukkan kinerja yang sangat baik pada kelas eMCP / eMMC dan IC PMI, dengan nilai precision, recall, dan f1-score masing-masing sebesar 1.0. Hal ini mengindikasikan bahwa seluruh prediksi untuk kedua kelas tersebut sepenuhnya benar tanpa adanya kesalahan klasifikasi, sehingga dapat disimpulkan bahwa model mampu mengenali dan mengklasifikasikan kedua jenis kerusakan ini secara konsisten dan akurat. Kinerja yang cukup tinggi juga ditunjukkan oleh kelas CPU / Chipset, dengan precision sebesar 1.0 dan recall 0.8, menghasilkan f1-score sebesar 0.889. Ini mengindikasikan bahwa semua prediksi untuk CPU / Chipset tepat, namun sekitar 20% data aktual dari kelas ini tidak berhasil dikenali oleh model. Sementara itu, pada kelas IC PA / FEM, model mencatat recall yang sempurna 1.0, namun precision hanya sebesar 0.5, sehingga menghasilkan f1-score sebesar 0.667. Kondisi ini menunjukkan bahwa meskipun model mampu mengenali seluruh sampel aktual dari kelas tersebut sebanyak 50% prediksi yang diarahkan ke kelas ini sebenarnya berasal dari kelas lain. Performa terburuk pada kelas Oscillator, dengan nilai recall 1.0, namun precision 0.0, menghasilkan f1-score 0.0. Presentase kerusakan adalah nilai presentase terbesar dari 7 nilai posterior probability yang ditampilkan. Setiap data uji memiliki nilai presentase kerusakan yang sesuai dengan label pada data training. Jadi, metode naive bayes pada kasus ini memiliki kinerja 100% dan membantu teknisi dalam melokalisasi kerusakan smartphone lebih akurat dan cepat

4. KESIMPULAN

Penelitian ini menunjukkan bahwa metode Naive Bayes Classifier dapat digunakan secara efektif untuk membantu proses deteksi kerusakan pada perangkat smartphone. Dengan mengklasifikasikan gejala berdasarkan parameter-parameter tertentu, seperti kronologi kejadian, merek perangkat, konsumsi arus listrik, dan jenis gejala, sistem dapat memberikan prediksi jenis kerusakan dengan waktu yang relatif singkat. Hal ini berkontribusi langsung terhadap efisiensi proses layanan teknis serta meningkatkan salah satu aspek penting dalam kepuasan pelanggan, yaitu kecepatan dan ketepatan diagnosis. Hasil evaluasi menunjukkan bahwa model Naive Bayes memberikan tingkat akurasi yang memuaskan pada data uji yang tersedia. Namun demikian, performa model sangat dipengaruhi oleh kualitas data latih, distribusi kelas dalam dataset, dan relevansi fitur yang digunakan. Ketidakseimbangan data antar kelas atau kurangnya representasi gejala tertentu dapat menyebabkan model mengalami kesulitan dalam mengklasifikasikan kerusakan secara merata. Oleh karena itu, pengembangan sistem ini di masa mendatang perlu mempertimbangkan peningkatan kualitas dan kuantitas data pelatihan, serta penerapan teknik pemodelan yang mampu menangani dataset tidak seimbang, seperti data augmentation, feature selection, atau pendekatan ensemble. Dengan optimalisasi lebih lanjut, sistem berbasis Naive Bayes berpotensi menjadi alat bantu diagnosis kerusakan smartphone yang andal, cepat, dan akurat, baik untuk teknisi profesional maupun pengguna umum.

REFERENCES

- [1] "Gartner Says Worldwide Smartphone Sales Grew 26% in First Quarter of 2021," *Gartner*. Jun, 7, 2021, [Online]. Available: <https://www.gartner.com/en/newsroom/press-releases/2021-06-07-1q21-smartphone-market-share>, Accessed: May 5, 2025.
- [2] M. T. Ismail, M. S. Ab Rahman, and A. H. Abdullah, "A Study of Smartphone Component Failure: Hardware and Software Perspective," *J. Eng. Sci. Technol.* , vol. 16, no. 3, pp. 2205–2217, 2021.
- [3] K. Thakur and A. Soni, "A Survey on Causes and Diagnosis of Smartphone Failures," *Int. J. Comput. Appl.* , vol. 182, no. 17, pp. 14–18, 2020.
- [4] S. Patel and P. Jain, "Performance Comparison of Naive Bayes and Other Machine Learning Algorithms for Predicting Smartphone Faults," in *Proc. Int. Conf. Comput. Commun. Inf. Technol. (CCICT)*, 2022, pp. 89–94.
- [5] M. R. Rani and A. G. Ramakrishnan, "Comparative Analysis of Machine Learning Models for Mobile Fault Classification," *Appl. Comput. Intell. Soft Comput.* , vol. 2020, Article ID 8912604, 2020.
- [6] X. Zhang and L. Wang, "Bayesian Learning Approaches for Mobile Device Fault Detection," *IEEE Access* , vol. 9, pp. 119670–119681, 2021.
- [7] F. Zhang, Y. Gao, and Q. Li, "A Naive Bayes Model for Activity Recognition Using Mobile Phone Data," *Sensors* , vol. 20, no. 2, p. 556, 2020.
- [8] H. Lee and J. Kim, "Health Monitoring via Smartphone Sensors: A Naive Bayes-Based Model," *IEEE J. Biomed. Health Inform.* , vol. 25, no. 8, pp. 2892–2900, Aug. 2021.
- [9] S. Sharma and M. Kaur, "Threat Detection in Smart Devices Using Sensor Fusion and Naive Bayes Classifier," *Comput. Electr. Eng.* , vol. 90, p. 106987, 2021.
- [10] Y. Nugroho and F. A. Aziz, "Data-driven Repair Strategy for Smartphones: An Empirical Study," *Indones. J. Electr. Eng. Comput. Sci.* , vol. 21, no. 3, pp. 1623–1630, 2021.
- [11] R. P. Das and S. Kar, "Diagnosis of Mobile Faults Using ML Techniques: A Naive Bayes Approach," in *Proc. IEEE Int. Conf. Smart Technol. (SMARTTECH)*, 2022, pp. 82–86.

- [12] A. Setiawan and R. Anindita, "Naive Bayes Implementation in Mobile Device Repair Decision Support System," **J. Inf. Syst. Eng. Bus. Intell.**, vol. 7, no. 2, pp. 91–99, 2022.
- [13] D. Xu and W. Yang, "AI-Based Decision Support System for Mobile Service Centers," **Int. J. Inf. Technol. Decis. Mak.**, vol. 20, no. 5, pp. 1315–1330, 2021.
- [14] N. W. Kusumadewi, "User Satisfaction and Technician Productivity through ML-based Diagnosis Systems," **TELKOMNIKA Telecommun. Comput. Electron. Control**, vol. 18, no. 4, pp. 2050–2057, 2020.
- [15] J. A. Fitriani and H. Pratama, "Educational Tools Based on Predictive Models for Smartphone Repair Training," **J. Theor. Appl. Inf. Technol.**, vol. 99, no. 8, pp. 1781–1789, 2021.
- [16] A. H. Hadi and M. R. Fadli, "Fault Detection System in Smartphones Using Naive Bayes," **Int. J. Adv. Comput. Sci. Appl.**, vol. 11, no. 5, pp. 342–347, 2020.
- [17] B. Prasetyo, D. H. Wijaya, and F. R. Azhari, "Automatic Smartphone Repair Diagnosis Using Probabilistic Classification," **J. Phys.: Conf. Ser.**, vol. 1823, p. 012016, 2021.
- [18] S. D. Siregar, "Predictive Maintenance in Smartphones Using Machine Learning," **Procedia Comput. Sci.**, vol. 179, pp. 510–516, 2021.
- [19] L. Yuliana and T. Kurniawan, "Naive Bayes-Based Application for Smartphone Damage Detection," **J. Inf. Technol. Comput. Sci.**, vol. 7, no. 2, pp. 89–97, 2022.
- [20] R. Zulfikar and M. A. Hafidz, "Smartphone Failure Prediction Using Bayesian Classification," **Int. J. Eng. Technol. Innov.**, vol. 13, no. 1, pp. 44–51, 2023.