

PENERAPAN ALGORITMA NAIVE BAYES DALAM MEMPREDIKSI KEBUTUHAN PELAYANAN KESEHATAN PASCA BENCANA ALAM DI SUMATERA UTARA

Abel Saragih¹, Rohitta Girsang², Guddes Naibaho³, Gita Valentina Br Tarigan⁴, Jijon Raphita Sagala⁵

Abstract - Natural disasters can significantly increase the demand for health services while simultaneously disrupting the capacity of health facilities. This condition requires a simple predictive approach that can provide early information for post-disaster health response planning. This study evaluates the application of Gaussian Naive Bayes to classify post-disaster health service needs in North Sumatra using disaster-impact indicators and health-facility capacity. The dataset consists of 17 historical disaster records covering injured victims, fatalities, displaced residents, damaged health facilities, active hospitals, and active community health centers. The data were stratified into 11 training records and 6 testing records. Model performance was evaluated using accuracy, weighted precision, weighted recall, weighted F1-score, macro-averaged metrics, and a multiclass confusion matrix. The testing results yielded an accuracy of 83.33%, weighted precision of 70.83%, weighted recall of 83.33%, and weighted F1-score of 76.19%. However, class-level evaluation showed that the only High-need observation in the test set was misclassified as Medium. These findings indicate that Gaussian Naive Bayes has potential as a low-computational-cost component of a decision support system, but the evidence remains preliminary because of the limited dataset size. Future research should expand the dataset, improve the representation of each target class, and conduct validation using larger datasets before operational deployment.

Abstrak - Bencana alam dapat meningkatkan kebutuhan pelayanan kesehatan secara signifikan dan mengganggu kapasitas fasilitas kesehatan. Kondisi tersebut menuntut pendekatan prediktif yang sederhana dan dapat digunakan sebagai informasi awal dalam perencanaan respons kesehatan pascabencana. Penelitian ini bertujuan mengevaluasi penerapan Gaussian Naive Bayes untuk mengklasifikasikan tingkat kebutuhan pelayanan kesehatan pascabencana di Sumatera Utara berdasarkan indikator dampak bencana dan kapasitas fasilitas kesehatan. Dataset penelitian terdiri atas 17 catatan historis bencana yang mencakup jumlah korban luka, korban meninggal, penduduk mengungsi, fasilitas kesehatan rusak, rumah sakit aktif, dan puskesmas aktif. Data dibagi secara terstratifikasi menjadi 11 data latih dan 6 data uji. Evaluasi dilakukan menggunakan accuracy, weighted precision, weighted recall, weighted F1-score, serta metrik macro dan confusion matrix. Hasil pengujian menunjukkan accuracy sebesar 83,33%, weighted precision 70,83%, weighted recall 83,33%, dan weighted F1-score 76,19%. Namun, evaluasi per kelas menunjukkan bahwa satu-satunya observasi kelas Tinggi pada data uji salah diklasifikasikan sebagai Sedang. Temuan ini menunjukkan bahwa Gaussian Naive Bayes berpotensi digunakan sebagai komponen awal sistem pendukung keputusan dengan kebutuhan komputasi rendah, tetapi hasilnya masih bersifat awal karena ukuran dataset terbatas. Penelitian lanjutan perlu memperluas dataset, memperkuat representasi

setiap kelas, dan melakukan validasi menggunakan data yang lebih besar sebelum diterapkan pada lingkungan operasional.

Kata Kunci: *Pelayanan Kesehatan; Machine Learning; Naive Bayes; Bencana Alam; Prediksi*

I. PENDAHULUAN

Bencana alam merupakan peristiwa yang menimbulkan dampak multidimensi terhadap kehidupan manusia, termasuk korban jiwa, kerusakan infrastruktur, perpindahan penduduk, dan gangguan terhadap sistem pelayanan kesehatan masyarakat [1]. Dampak pascabencana tidak hanya berkaitan dengan korban langsung, tetapi juga dengan meningkatnya kebutuhan pelayanan kesehatan, antara lain penanganan trauma, pencegahan penyakit menular, dukungan kesehatan mental, dan rehabilitasi [2], [3]. Ketika terjadi bencana, fasilitas kesehatan dapat mengalami peningkatan beban pelayanan sementara sebagian kapasitas fisiknya terganggu. Kondisi tersebut dapat menimbulkan kesenjangan antara kebutuhan masyarakat dan sumber daya kesehatan yang tersedia [4]. Kerusakan fasilitas, gangguan logistik, keterbatasan akses geografis, dan koordinasi lintas sektor semakin meningkatkan kompleksitas respons. Dalam konteks tersebut, pendekatan perencanaan berbasis data dapat membantu menyediakan informasi pendukung keputusan yang lebih sistematis dibandingkan ketergantungan sepenuhnya pada permintaan ad hoc [5], [6].

Indonesia memiliki tingkat kerentanan bencana yang tinggi karena kondisi geografis dan karakteristik hidrometeorologinya [7]. Pada akhir 2025, Sumatera Utara mengalami rangkaian bencana hidrometeorologi yang berdampak pada penduduk dan infrastruktur di sejumlah wilayah [8]. Kondisi tersebut menunjukkan pentingnya dukungan analitik yang dapat membantu memperkirakan tingkat kebutuhan pelayanan kesehatan berdasarkan informasi dampak bencana yang tersedia. Perkembangan teknologi informasi dan analitik data membuka peluang penerapan metode machine learning untuk mendukung pengambilan keputusan pada lingkungan yang memiliki ketidakpastian tinggi. Pendekatan berbasis data dapat mengubah catatan historis menjadi informasi prediktif yang berpotensi digunakan sebagai salah satu masukan dalam perencanaan respons kesehatan [9], [10].

Naive Bayes merupakan salah satu metode klasifikasi probabilistik yang relatif sederhana dan memiliki kebutuhan

komputasi rendah [11], [12]. Karakteristik tersebut membuatnya relevan untuk dikaji pada permasalahan klasifikasi dengan jumlah data terbatas. Penelitian sebelumnya menunjukkan penggunaan Naive Bayes pada berbagai permasalahan klasifikasi, termasuk analisis sentimen dan data kesehatan [13], [19]. Dalam konteks dengue, artificial intelligence juga telah dikaji sebagai pendekatan yang berpotensi mendukung pengelolaan penyakit dan pengambilan keputusan [14]. Temuan-temuan tersebut menunjukkan bahwa metode probabilistik ringan dapat menjadi salah satu alternatif dalam pengembangan sistem pendukung keputusan berbasis data.

Sejumlah penelitian juga menunjukkan pemanfaatan machine learning untuk prediksi dan klasifikasi pada penyakit kronis, penyakit infeksi, serta risiko stroke [15]–[18]. Meskipun demikian, penerapan Gaussian Naive Bayes secara khusus untuk mengklasifikasikan tingkat kebutuhan pelayanan kesehatan pascabencana pada tingkat wilayah masih memerlukan kajian lebih lanjut. Kesenjangan tersebut menjadi dasar penelitian ini. Penelitian tidak dimaksudkan untuk menggantikan penilaian klinis atau keputusan petugas lapangan, tetapi untuk menguji apakah model klasifikasi yang ringan dapat memberikan estimasi awal berdasarkan indikator dampak bencana dan kapasitas fasilitas kesehatan.

Berdasarkan kesenjangan tersebut, penelitian ini menerapkan Gaussian Naive Bayes untuk mengklasifikasikan kebutuhan pelayanan kesehatan pascabencana di Sumatera Utara. Pendekatan ini dipilih karena struktur probabilistiknya relatif sederhana dan dapat dihitung dengan kebutuhan komputasi yang rendah [11], [12]. Model diharapkan dapat memberikan informasi awal mengenai tingkat kebutuhan pelayanan yang selanjutnya dapat dipertimbangkan bersama hasil asesmen lapangan.

Kontribusi penelitian ini adalah penerapan Gaussian Naive Bayes pada klasifikasi tingkat kebutuhan pelayanan kesehatan pascabencana dengan menggunakan indikator korban, pengungsi, kerusakan fasilitas kesehatan, serta kapasitas rumah sakit dan puskesmas. Secara praktis, hasil penelitian dapat menjadi dasar pengembangan sistem pendukung keputusan untuk membantu prioritas awal sumber daya kesehatan. Namun, karena dataset yang digunakan hanya terdiri atas 17 observasi, hasil penelitian diposisikan sebagai bukti awal dan belum dimaksudkan sebagai model operasional yang siap diterapkan tanpa validasi lanjutan.

Tujuan utama penelitian ini adalah mengevaluasi kinerja Gaussian Naive Bayes dalam mengklasifikasikan tingkat kebutuhan pelayanan kesehatan pascabencana berdasarkan data historis di Sumatera Utara. Evaluasi difokuskan pada tiga aspek, yaitu: (1) kinerja klasifikasi pada data pengujian; (2) precision, recall, dan F1-score sebagai metrik evaluasi multikelas; dan (3) waktu eksekusi model pada perangkat yang digunakan dalam eksperimen.

Penelitian dibatasi pada penerapan algoritma Gaussian Naive Bayes untuk klasifikasi kebutuhan pelayanan kesehatan

pascabencana di Provinsi Sumatera Utara. Prediktor yang digunakan adalah jumlah korban luka, korban meninggal, penduduk mengungsi, fasilitas kesehatan rusak, rumah sakit aktif, dan puskesmas aktif. Penelitian tidak membahas diagnosis klinis, pengobatan pasien, penyebab bencana, maupun evaluasi kebijakan publik. Penelitian juga tidak membandingkan Gaussian Naive Bayes dengan algoritma machine learning lain. Kebaruan penelitian terletak pada pengujian penerapan model probabilistik ringan untuk mengklasifikasikan tingkat kebutuhan pelayanan kesehatan pada konteks bencana tingkat wilayah menggunakan data empiris Sumatera Utara.

II. METODE

a. Desain Penelitian

Penelitian menggunakan pendekatan kuantitatif dengan desain eksperimen machine learning untuk membangun dan mengevaluasi model klasifikasi. Unit analisis berupa catatan kejadian bencana pada wilayah kabupaten/kota di Provinsi Sumatera Utara. Model yang digunakan adalah Gaussian Naive Bayes karena seluruh prediktor numerik dapat diproses melalui estimasi distribusi Gaussian pada masing-masing kelas. Kinerja model dievaluasi menggunakan accuracy, precision, recall, F1-score, dan confusion matrix.

b. Populasi dan Pengambilan Sampel

Populasi penelitian mencakup catatan kejadian bencana yang tersedia untuk wilayah Sumatera Utara pada periode pengamatan. Karena penelitian menggunakan data sekunder, tidak terdapat partisipasi manusia secara langsung. Dataset penelitian terdiri atas 17 catatan yang dipilih dari data bencana yang tersedia pada sumber resmi BNPB dan digunakan sesuai kriteria kelengkapan atribut penelitian. Data tidak memuat informasi pribadi yang dapat mengidentifikasi individu.

c. Variabel Penelitian

Instrumen penelitian berupa dataset terstruktur yang digunakan sebagai masukan model machine learning. Prediktor yang digunakan terdiri atas enam atribut numerik, yaitu jumlah korban luka, jumlah korban meninggal, jumlah penduduk mengungsi, jumlah fasilitas kesehatan rusak, jumlah rumah sakit aktif, dan jumlah puskesmas aktif. Jenis bencana dan wilayah digunakan sebagai informasi identitas serta konteks data. Variabel target adalah tingkat kebutuhan pelayanan kesehatan pascabencana yang terdiri atas tiga kelas, yaitu Kebutuhan Rendah, Kebutuhan Sedang, dan Kebutuhan Tinggi.

d. Prosedur Penelitian

Penelitian dilakukan melalui tahapan pengumpulan data, prapemrosesan, pemodelan, dan evaluasi. Data kejadian dan dampak bencana dikumpulkan dari sumber resmi BNPB yang digunakan dalam penelitian, kemudian disusun dalam satu

matriks berdasarkan wilayah dan kejadian yang memenuhi kriteria kelengkapan atribut.

Pada tahap prapemrosesan dilakukan pemeriksaan kelengkapan, pemeriksaan duplikasi, standardisasi nama kolom, dan konversi seluruh prediktor ke tipe data numerik. Seluruh 17 catatan dinyatakan lengkap sehingga tidak diperlukan imputasi nilai hilang atau penghapusan baris. Encoding dan normalisasi tidak diterapkan pada prediktor akhir karena seluruh prediktor model bersifat numerik.

Dataset dibagi secara terstratifikasi menjadi 11 data latih dan 6 data uji, atau sekitar 64,71% dan 35,29%. Model Gaussian Naive Bayes dilatih menggunakan data latih, kemudian digunakan untuk memprediksi kelas pada data uji. Hasil prediksi dibandingkan dengan label aktual menggunakan confusion matrix dan metrik klasifikasi.

e. Perangkat Penelitian

Eksperimen dilakukan menggunakan laptop dengan prosesor Intel Core i5 Generasi ke-8 dan RAM 16 GB. Microsoft Excel digunakan untuk kompilasi data awal. Prapemrosesan, pemodelan, dan evaluasi dilakukan menggunakan Jupyter Notebook dengan bahasa Python serta pustaka Pandas, NumPy, dan Scikit-Learn.

f. Model Gaussian Naive Bayes

Analisis menggunakan teorema Bayes dengan asumsi independensi bersyarat antarprediktor terhadap kelas. Untuk Gaussian Naive Bayes, distribusi setiap prediktor numerik pada masing-masing kelas dimodelkan menggunakan distribusi Gaussian. Probabilitas posterior dihitung menggunakan:

$$P(C|X) = P(X|C) P(C) / P(X)$$

dengan $P(C|X)$ merupakan probabilitas posterior kelas C berdasarkan vektor prediktor X ; $P(X|C)$ merupakan likelihood; $P(C)$ merupakan probabilitas prior kelas C ; dan $P(X)$ merupakan probabilitas bukti atau konstanta normalisasi.

Untuk setiap fitur numerik, likelihood dihitung berdasarkan distribusi Gaussian menggunakan parameter rata-rata (μ) dan varians (σ^2). Kelas akhir ditetapkan pada kelas dengan probabilitas posterior terbesar berdasarkan aturan Maximum A Posteriori (MAP) [11].

g. Evaluasi Model

Accuracy digunakan untuk mengukur proporsi seluruh prediksi yang benar. Precision mengukur proporsi prediksi suatu kelas yang benar dibandingkan seluruh observasi yang diprediksi sebagai kelas tersebut. Recall mengukur proporsi observasi aktual suatu kelas yang berhasil diidentifikasi. F1-score merupakan rata-rata harmonis antara precision dan recall. Karena dataset kecil dan distribusi kelas tidak sepenuhnya seimbang, hasil weighted dan macro digunakan untuk membedakan kinerja agregat dan kinerja rata-rata antarkelas.

Evaluasi holdout dilakukan pada enam observasi data uji. Karena ukuran data uji sangat kecil, satu perubahan prediksi dapat mengubah metrik secara substansial. Oleh sebab itu, hasil penelitian diperlakukan sebagai evaluasi awal dan tidak digunakan untuk menyimpulkan generalisasi model secara luas. Validasi silang K-fold yang tidak dilaporkan pada hasil penelitian tidak dimasukkan dalam analisis final.

III. HASIL DAN PEMBAHASAN

a. Deskripsi Dataset dan Kategorisasi Target

Dataset empiris terdiri atas 17 catatan historis bencana alam di Provinsi Sumatera Utara. Data merupakan data sekunder yang memuat informasi mengenai dampak bencana dan kapasitas fasilitas kesehatan pada wilayah terdampak. Variabel target terdiri atas tiga kelas, yaitu Rendah, Sedang, dan Tinggi. Kategori operasional tersebut digunakan sebagai label klasifikasi dan tidak dimaksudkan menggantikan asesmen lapangan oleh tenaga kesehatan.

TABEL 1
SKEMA KLASIFIKASI KEBUTUHAN PELAYANAN
KESEHATAN PASCABENCANA

Kategori	Deskripsi	Ruang Operasional	Lingkup
Rendah	Kebutuhan pelayanan kesehatan primer dasar	Mobilisasi primer lokal; pengisian kembali obat-obatan standar	klinik
Sedang	Kebutuhan pelayanan kesehatan sekunder tingkat menengah dan khusus	Penggerakan unit medis bergerak; mobilisasi tim klinis lapangan khusus	lapangan
Tinggi	Kebutuhan pelayanan trauma darurat kritis dan perawatan intensif	Penggerakan unit trauma tingkat lanjut; dukungan bedah; logistik medis skala besar	lapangan

Tabel 1 memberikan definisi operasional tiga kelas target yang digunakan dalam penelitian. Kelas Rendah merepresentasikan kebutuhan pelayanan kesehatan primer dasar; kelas Sedang merepresentasikan kebutuhan pelayanan sekunder tingkat menengah dan khusus; sedangkan kelas Tinggi merepresentasikan kebutuhan trauma darurat dan perawatan intensif. Kategori tersebut digunakan sebagai label klasifikasi dan tetap memerlukan konfirmasi melalui asesmen lapangan.

TABEL 2.
DATASET EMPIRIS BENCANA DI PROVINSI SUMATERA
UTARA

Kabupaten/Kota	Jenis Bencana	Korban Luka	Korban Meninggal	Pengungsi	Faskes Rusak	RS Aktif	Puskesmas Aktif
Batu Bara	Banjir	0	0	55.596	0	1	15
Asahan	Banjir	0	0	3.149	0	1	30
Deli Serdang	Banjir	0	17	331.111	15	4	34
Tapanuli Utara	Banjir	3	36	15.230	67	1	21
Tapanuli Tengah	Banjir	11	130	298.076	14	1	25
Tapanuli Selatan	Banjir	160	93	281.836	5	3	17
Mandailing Natal	Banjir	0	0	13.072	10	2	26
Mandailing Natal	Cuaca Ekstrem	0	0	65	10	2	26
Pakpak Bharat	Banjir	0	2	1.835	0	1	8
Humang Hasundutan	Banjir	0	10	7.435	1	1	12
Serdang Bedagai	Banjir	0	0	73.448	0	1	20
Kota Medan	Banjir	0	12	46.587	9	10	41
Kota Sibolga	Banjir	68	55	91.751	0	1	5
Kota Binjai	Banjir	0	0	28.739	0	2	8
Kota Tinggi	Banjir	0	0	24.332	0	2	9
Kota Padangsidimpuan	Banjir	0	0	1.702	0	2	10
Nias	Banjir	0	3	34.029	0	1	12

Dataset pada Tabel 2 menunjukkan variasi dampak bencana antarwilayah. Tapanuli Selatan memiliki 160 korban luka dan 281.836 pengungsi, sedangkan beberapa wilayah lain memiliki jumlah korban dan kerusakan fasilitas yang lebih rendah. Variasi tersebut digunakan sebagai dasar pembelajaran distribusi probabilitas oleh Gaussian Naive Bayes.

b. Analisis Statistik Deskriptif

TABEL 3.
STATISTIK DESKRIPTIF PREDIKTOR PENELITIAN

Variabel Prediktor	Mini mum	Maksi mum	Rata-rata (μ)
Korban Luka	0	160	14,24
Korban Meninggal	0	130	21,06
Penduduk Mengungsi	65	331.111	76.940,76
Fasilitas Kesehatan Rusak	0	67	7,71
Rumah Sakit Aktif	1	10	2,12
Puskesmas Aktif	5	41	18,76

Jumlah penduduk mengungsi memiliki rentang paling lebar, yaitu 65 hingga 331.111 orang, dengan rata-rata 76.940,76 orang. Jumlah fasilitas kesehatan rusak berkisar antara 0 hingga 67 fasilitas dengan rata-rata 7,71. Jumlah korban luka memiliki rata-rata 14,24, korban meninggal 21,06, rumah sakit aktif 2,12, dan puskesmas aktif 18,76. Variasi tersebut memberikan perbedaan karakteristik yang digunakan model untuk membedakan kelas target.

c. Prapemrosesan dan Pembagian Data

Pemeriksaan data menunjukkan bahwa seluruh 17 catatan lengkap sehingga tidak diperlukan imputasi nilai hilang atau penghapusan baris. Nama atribut distandarisasi menggunakan format snake case dan seluruh prediktor dikonversi ke tipe numerik integer atau float. Dataset kemudian dibagi secara terstratifikasi menjadi 11 data latih dan 6 data uji. Indeks data latih adalah [8, 13, 2, 9, 16, 4, 7, 10, 12, 3, 6], sedangkan indeks data uji adalah [0, 1, 5, 15, 11, 14].

d. Evaluasi Kinerja Model

TABEL 4
METRIK KINERJA KLASIFIKASI

Metode Evaluasi Kinerja	Nilai Keluaran	Persentase
Akurasi Klasifikasi	0,8333	83,33%
Weighted Precision	0,7083	70,83%
Weighted Recall	0,8333	83,33%
Weighted F1-score	0,7619	76,19%
Macro Precision	0,5833	58,33%
Macro Recall	0,6667	66,67%
Macro F1-score	0,6190	61,90%

Model mengklasifikasikan lima dari enam observasi data uji dengan benar sehingga menghasilkan accuracy sebesar 83,33%. Weighted precision sebesar 70,83%, weighted recall sebesar 83,33%, dan weighted F1-score sebesar 76,19%. Nilai macro precision, macro recall, dan macro F1-score masing-masing sebesar 58,33%, 66,67%, dan 61,90%. Perbedaan nilai weighted dan macro menunjukkan bahwa distribusi kelas pada data uji memengaruhi kinerja agregat.

e. Analisis Confusion Matrix

TABEL 5
CONFUSION MATRIX MULTIKELAS

Aktual \ Prediksi	Tinggi	Rendah	Sedang
Tinggi	0	0	1
Rendah	0	2	0
Sedang	0	0	3

Confusion matrix menunjukkan bahwa dua observasi kelas Rendah dan tiga observasi kelas Sedang berhasil diklasifikasikan dengan benar. Satu observasi aktual kelas Tinggi diprediksi sebagai Sedang. Dengan demikian, recall kelas Rendah dan Sedang masing-masing sebesar 100%, sedangkan recall kelas Tinggi sebesar 0% karena satu-satunya observasi kelas Tinggi pada data uji tidak berhasil dikenali.

Temuan ini menunjukkan pentingnya evaluasi per kelas selain metrik agregat.

PEMBAHASAN

a. Kinerja Algoritmik dan Interpretasi Hasil

Accuracy sebesar 83,33% menunjukkan bahwa lima dari enam observasi data uji diklasifikasikan secara benar. Namun, ukuran data uji yang sangat kecil membuat perubahan satu prediksi dapat mengubah nilai accuracy secara substansial. Oleh karena itu, hasil tersebut lebih tepat dipandang sebagai indikasi awal kemampuan model pada dataset penelitian daripada bukti generalisasi yang kuat.

Gaussian Naive Bayes menggunakan pendekatan probabilistik dengan mengestimasi parameter distribusi setiap prediktor pada masing-masing kelas. Model relatif sederhana sehingga sesuai untuk eksperimen dengan sumber daya komputasi terbatas. Asumsi independensi bersyarat merupakan penyederhanaan utama metode dan dapat memengaruhi probabilitas posterior apabila prediktor memiliki hubungan yang kuat.

Jumlah pengungsi memiliki rentang nilai yang jauh lebih besar dibandingkan beberapa prediktor lain. Gaussian Naive Bayes tidak menggunakan jarak antar fitur seperti beberapa algoritma berbasis jarak, tetapi tetap mengestimasi rata-rata dan varians masing-masing fitur pada setiap kelas. Karena itu, distribusi data dan keberadaan nilai ekstrem tetap perlu diperhatikan dalam interpretasi hasil.

b. Penguraian Metrik Evaluasi dan Analisis Kesalahan

Weighted recall sebesar 83,33% tidak berarti bahwa seluruh kelas memiliki recall yang tinggi. Confusion matrix menunjukkan bahwa kelas Tinggi tidak berhasil dikenali pada data uji. Hal ini merupakan temuan penting karena kebutuhan pelayanan kesehatan dengan tingkat tinggi merupakan kelas yang secara operasional memerlukan perhatian khusus.

Pada kelas Rendah, dua observasi aktual berhasil diklasifikasikan dengan benar. Pada kelas Sedang, tiga observasi aktual juga berhasil diklasifikasikan dengan benar. Sementara itu, satu observasi aktual kelas Tinggi diprediksi sebagai Sedang. Kesalahan tersebut menunjukkan bahwa indikator yang tersedia pada observasi tersebut belum cukup membedakan kelas Tinggi dari kelas Sedang dalam model yang dilatih pada dataset kecil. Penjelasan ini tidak digunakan untuk menyatakan bahwa satu variabel tertentu menjadi penyebab tunggal kesalahan karena analisis kontribusi fitur secara individual tidak dilakukan.

c. Efisiensi Komputasi

Waktu eksekusi pada perangkat yang digunakan dalam eksperimen tercatat kurang dari 12 milidetik. Hasil ini menunjukkan kebutuhan komputasi yang rendah pada

konfigurasi eksperimen. Waktu tersebut tidak dapat langsung digeneralisasikan ke seluruh perangkat karena dipengaruhi spesifikasi hardware, versi perangkat lunak, ukuran data, dan cara pengukuran. Oleh karena itu, hasil ini diposisikan sebagai benchmark internal dan bukan sebagai klaim kesiapan deployment lapangan.

d. Kesesuaian Konteks dan Kontribusi Ilmiah

Penelitian menunjukkan bahwa Gaussian Naive Bayes dapat digunakan untuk menguji klasifikasi kebutuhan pelayanan kesehatan pascabencana menggunakan indikator dampak dan kapasitas fasilitas kesehatan. Kontribusi utama penelitian terletak pada penerapan model probabilistik ringan pada konteks wilayah Sumatera Utara dengan dataset empiris yang terbatas. Hasil penelitian belum cukup untuk menyatakan bahwa model dapat langsung digunakan sebagai sistem operasional penanggulangan bencana. Validasi dengan jumlah observasi yang lebih besar, periode waktu yang lebih panjang, serta data dari wilayah lain diperlukan untuk menilai stabilitas dan kemampuan generalisasi model.

e. Implikasi Praktis untuk Logistik Kesehatan Masyarakat

Secara praktis, model berpotensi digunakan sebagai komponen awal sistem pendukung keputusan untuk membantu memprioritaskan kebutuhan pelayanan kesehatan. Prediksi kelas Tinggi dapat menjadi salah satu informasi tambahan untuk menentukan wilayah yang perlu memperoleh asesmen lapangan lebih lanjut. Prediksi model tidak dimaksudkan sebagai dasar tunggal untuk pengeralahan tenaga medis, obat-obatan, atau fasilitas kesehatan.

Penggunaan model bersama asesmen lapangan dapat membantu menggabungkan informasi kuantitatif dan kondisi aktual di lokasi bencana. Pendekatan tersebut lebih sesuai untuk lingkungan bencana karena kondisi lapangan dapat berubah cepat dan data historis tidak selalu merepresentasikan seluruh faktor yang memengaruhi kebutuhan pelayanan kesehatan.

f. Keterbatasan dan Arah Penelitian Masa Depan

Keterbatasan utama penelitian adalah ukuran dataset yang hanya terdiri atas 17 observasi dan data uji sebanyak enam observasi. Selain itu, kelas Tinggi hanya diwakili oleh satu observasi pada data uji sehingga recall kelas tersebut menjadi 0%. Kondisi ini menyebabkan metrik agregat memiliki ketidakpastian yang tinggi.

Keterbatasan berikutnya adalah asumsi independensi bersyarat pada Gaussian Naive Bayes. Dalam konteks bencana, jumlah korban, pengungsi, dan kerusakan fasilitas dapat saling berkorelasi. Dataset juga hanya merepresentasikan Sumatera Utara sehingga kemampuan generalisasi ke wilayah lain belum dapat dipastikan.

Penelitian selanjutnya perlu memperluas dataset antarperiode dan antarprovinsi, memperbaiki representasi kelas Tinggi, melakukan validasi silang yang sesuai dengan jumlah data, serta membandingkan Gaussian Naive Bayes dengan algoritma klasifikasi lain. Penelitian lanjutan juga dapat menguji metode seleksi atau transformasi fitur dan melakukan validasi operasional dengan data lapangan.

g. Analisis Distribusi dan Karakteristik Dataset

Analisis distribusi dilakukan untuk memberikan konteks terhadap hasil klasifikasi dan untuk melihat variasi numerik pada enam prediktor yang digunakan. Statistik deskriptif pada Tabel 3 menunjukkan bahwa sebagian besar prediktor memiliki rentang yang lebar dan median yang lebih rendah daripada rata-rata. Kondisi tersebut mengindikasikan bahwa sejumlah kecil observasi dengan nilai dampak tinggi memberikan kontribusi besar terhadap nilai rata-rata. Karakteristik seperti ini penting diperhatikan ketika Gaussian Naive Bayes mengestimasi parameter rata-rata dan varians pada setiap kelas.

Berdasarkan 17 catatan pada Tabel 2, median korban luka adalah 0, median korban meninggal adalah 2, median penduduk mengungsi adalah 28.739, median fasilitas kesehatan rusak adalah 0, median rumah sakit aktif adalah 1, dan median puskesmas aktif adalah 17. Perbedaan antara median dan rata-rata terutama terlihat pada jumlah penduduk mengungsi, korban luka, dan korban meninggal. Hal tersebut menunjukkan bahwa distribusi data tidak simetris dan terdapat observasi dengan dampak yang jauh lebih besar daripada sebagian besar catatan lainnya.

Sebagai analisis tambahan, median korban luka adalah 0, korban meninggal 2, penduduk mengungsi 28.739, fasilitas kesehatan rusak 0, rumah sakit aktif 1, dan puskesmas aktif 17. Median yang lebih rendah daripada rata-rata pada sebagian besar variabel menunjukkan bahwa sebagian besar catatan berada pada tingkat dampak relatif rendah, sementara beberapa kejadian memiliki nilai dampak yang jauh lebih besar.

Simpangan baku masing-masing prediktor adalah 41,01 untuk korban luka; 37,81 untuk korban meninggal; 111.636,05 untuk penduduk mengungsi; 16,22 untuk fasilitas kesehatan rusak; 2,20 untuk rumah sakit aktif; dan 10,32 untuk puskesmas aktif. Nilai tersebut digunakan sebagai informasi pendukung mengenai variasi data dan bukan sebagai parameter tambahan di luar proses estimasi Gaussian Naive Bayes.

Statistik tambahan tersebut dihitung dari 17 observasi pada dataset empiris yang ditampilkan pada Tabel 2. Nilai median dan simpangan baku digunakan untuk memperjelas sebaran data dan membantu interpretasi hasil model.

Dari sudut pandang pemodelan, variasi tersebut memberikan dua implikasi. Pertama, model perlu memperkirakan distribusi fitur pada masing-masing kelas dari jumlah observasi yang sangat terbatas. Kedua, observasi dengan nilai ekstrem dapat memengaruhi estimasi parameter Gaussian, sehingga hasil klasifikasi perlu dibaca bersama karakteristik data dan confusion matrix. Temuan ini

memperkuat alasan bahwa accuracy sebesar 83,33% tidak cukup dijadikan satu-satunya dasar untuk menyatakan model memiliki kemampuan generalisasi yang tinggi.

Karakteristik dataset juga menunjukkan bahwa data penelitian belum dapat dipandang sebagai sampel yang representatif untuk seluruh kejadian bencana di Sumatera Utara. Dataset hanya terdiri atas 17 catatan dan beberapa wilayah muncul dengan karakteristik dampak yang sangat berbeda. Oleh karena itu, analisis deskriptif dalam penelitian ini berfungsi terutama untuk menjelaskan kondisi data eksperimen dan bukan untuk membuat estimasi statistik mengenai populasi bencana secara keseluruhan.

h. Formulasi Evaluasi dan Reproduksi Eksperimen

Untuk memastikan evaluasi dapat direproduksi, kinerja klasifikasi dihitung berdasarkan matriks konfusi multikelas pada enam observasi data uji. Accuracy dihitung sebagai proporsi seluruh prediksi yang benar terhadap jumlah observasi. Untuk setiap kelas c , precision dan recall masing-masing dapat dirumuskan sebagai:

$$\text{Precision}_c = TP_c / (TP_c + FP_c)$$

$$\text{Recall}_c = TP_c / (TP_c + FN_c)$$

$$F1_c = 2 \times \text{Precision}_c \times \text{Recall}_c / (\text{Precision}_c + \text{Recall}_c)$$

Pada evaluasi multikelas, macro-average dihitung sebagai rata-rata aritmetika nilai metrik dari seluruh kelas, sedangkan weighted-average memberikan bobot berdasarkan jumlah observasi pada setiap kelas. Penggunaan kedua jenis agregasi diperlukan pada dataset kecil karena nilai weighted dapat lebih dipengaruhi oleh kelas yang memiliki jumlah observasi lebih besar. Dengan confusion matrix pada Tabel 5, weighted precision sebesar 70,83%, weighted recall sebesar 83,33%, dan weighted F1-score sebesar 76,19%, sedangkan macro precision, macro recall, dan macro F1-score masing-masing sebesar 58,33%, 66,67%, dan 61,90%.

Gaussian Naive Bayes menghitung probabilitas posterior dengan menggabungkan prior kelas dan likelihood setiap fitur. Untuk fitur numerik x_i pada kelas c , likelihood Gaussian dapat dinyatakan sebagai:

$$P(x_i | c) = [1 / \sqrt{(2\pi\sigma_c^2)}] \times \exp[-(x_i - \mu_c)^2 / (2\sigma_c^2)]$$

Parameter μ_c dan σ_c^2 diestimasi dari data latih untuk setiap kelas. Selanjutnya, posterior setiap kelas dibandingkan dan kelas dengan probabilitas posterior terbesar dipilih menggunakan aturan Maximum A Posteriori (MAP). Formulasi tersebut menjelaskan mengapa model dapat digunakan untuk fitur numerik tanpa transformasi kategorikal tambahan.

Tahapan implementasi dapat direproduksi melalui urutan berikut: (1) membaca dataset dan memeriksa kelengkapan atribut; (2) menghapus duplikasi apabila ditemukan; (3) menstandarkan nama atribut menggunakan format snake_case; (4) memastikan enam prediktor bertipe numerik; (5) memisahkan prediktor dan target; (6) membagi data secara terstratifikasi menjadi 11 data latih dan 6 data uji; (7) melatih Gaussian Naive Bayes pada data latih; (8) menghasilkan prediksi terhadap data uji; dan (9) menghitung accuracy, precision, recall, F1-score, serta confusion matrix. Urutan tersebut sejalan dengan praktik umum penerapan Naive Bayes pada permasalahan klasifikasi [11], [12], [13], [19].

Reproduksibilitas penelitian juga dipengaruhi oleh parameter pembagian data. Oleh karena itu, implementasi final sebaiknya mencatat nilai random_state yang digunakan pada proses stratified train-test split. Informasi tersebut tidak mengubah algoritma Gaussian Naive Bayes, tetapi penting agar pembagian 11 data latih dan 6 data uji dapat dihasilkan kembali ketika eksperimen diulang.

Penelitian terdahulu memperlihatkan bahwa machine learning dapat digunakan untuk berbagai permasalahan prediksi kesehatan dan klasifikasi risiko [15], [16], [17], [18]. Posisi penelitian ini berbeda karena fokusnya bukan diagnosis penyakit, melainkan klasifikasi kebutuhan pelayanan kesehatan pada konteks pascabencana. Dengan demikian, hasil model harus diposisikan sebagai informasi analitik awal yang melengkapi, bukan menggantikan, asesmen kesehatan dan keputusan petugas.

i. Analisis Sensitivitas, Validitas, dan Implikasi Sistem

Ukuran data uji merupakan faktor penting dalam menafsirkan hasil penelitian. Dari enam observasi pengujian, lima diklasifikasikan dengan benar. Dengan demikian, satu perubahan prediksi akan mengubah accuracy sebesar 16,67 poin persentase. Apabila jumlah prediksi benar turun menjadi empat dari enam observasi, accuracy akan menjadi 66,67%. Sebaliknya, jika seluruh enam observasi diprediksi benar, accuracy menjadi 100%. Rentang perubahan tersebut menunjukkan bahwa accuracy pada dataset ini sangat sensitif terhadap satu observasi.

Sensitivitas tersebut juga terlihat pada evaluasi per kelas. Kelas Rendah mempunyai dua observasi yang seluruhnya diklasifikasikan benar, sedangkan kelas Sedang mempunyai tiga observasi yang seluruhnya diklasifikasikan benar. Sebaliknya, satu observasi kelas Tinggi salah diklasifikasikan sebagai Sedang sehingga recall kelas Tinggi adalah 0%. Dalam konteks pelayanan kesehatan pascabencana, kondisi tersebut perlu mendapatkan perhatian khusus karena kesalahan terhadap kelas kebutuhan tinggi berpotensi lebih penting secara operasional dibandingkan kesalahan pada kelas dengan kebutuhan lebih rendah.

Dari sisi validitas internal, penelitian memiliki kelebihan berupa penggunaan data numerik yang konsisten, tahapan

prapemrosesan yang sederhana, dan evaluasi menggunakan confusion matrix serta beberapa jenis metrik. Namun, validitas internal tetap dibatasi oleh ukuran sampel yang kecil dan ketidakpastian dalam representasi masing-masing kelas. Validitas eksternal lebih terbatas lagi karena seluruh catatan berada pada konteks Sumatera Utara dan belum diuji pada provinsi atau periode yang berbeda.

Salah satu aspek yang perlu diperhatikan dalam penelitian lanjutan adalah pembentukan label target. Tabel 1 memberikan definisi operasional untuk kelas Rendah, Sedang, dan Tinggi, tetapi penelitian ini belum menyediakan threshold numerik atau prosedur pembentukan label secara rinci. Karena label merupakan variabel yang dipelajari model, dokumentasi mekanisme pelabelan menjadi bagian penting dari reproduksibilitas. Penelitian lanjutan perlu menjelaskan apakah label berasal dari penilaian ahli, aturan berbasis indikator, atau sumber resmi tertentu, serta menguji konsistensi label tersebut. Keterbatasan lain berkaitan dengan asumsi independensi bersyarat Gaussian Naive Bayes. Dalam kondisi bencana, jumlah korban, jumlah pengungsi, kerusakan fasilitas, dan kapasitas pelayanan dapat saling berhubungan. Ketergantungan tersebut dapat menyebabkan asumsi sederhana model tidak sepenuhnya terpenuhi. Oleh karena itu, penelitian selanjutnya dapat mengukur korelasi antarprediktor, mengevaluasi seleksi fitur, dan membandingkan performa Gaussian Naive Bayes dengan metode lain. Perbandingan tersebut akan memberikan dasar yang lebih kuat untuk menentukan apakah kesederhanaan model memberikan keuntungan yang memadai.

Dari perspektif sistem informasi, model dapat ditempatkan sebagai lapisan klasifikasi dalam sistem pendukung keputusan. Alur konseptualnya adalah data kejadian bencana → validasi dan prapemrosesan → pembentukan fitur → klasifikasi Gaussian Naive Bayes → keluaran tingkat kebutuhan → verifikasi petugas. Arsitektur tersebut menempatkan model sebagai alat bantu analitik, sedangkan keputusan akhir tetap berada pada pengguna yang memiliki informasi lapangan. Pendekatan ini konsisten dengan kebutuhan sistem pendukung keputusan yang menggabungkan informasi berbasis data dengan pertimbangan manusia.

Keluaran sistem dapat dirancang dalam bentuk tiga tingkat prioritas yang disertai indikator input dan probabilitas kelas. Dengan menyimpan riwayat prediksi, sistem juga dapat menyediakan bahan evaluasi untuk pembaruan model ketika data baru tersedia. Namun, pengembangan dashboard, integrasi basis data real-time, dan pengujian penerimaan pengguna belum dilakukan pada penelitian ini sehingga tidak boleh diklaim sebagai bagian dari hasil eksperimen.

Secara keseluruhan, temuan penelitian memberikan bukti awal bahwa Gaussian Naive Bayes dapat digunakan untuk eksperimen klasifikasi kebutuhan pelayanan kesehatan pascabencana pada dataset yang tersedia. Kontribusi empirisnya perlu dipahami bersama keterbatasan ukuran data, ketidakseimbangan representasi kelas, dan kebutuhan validasi eksternal. Penelitian berikutnya dapat memperluas data lintas

tahun dan lintas provinsi, menambah observasi kelas Tinggi, serta menggunakan skema evaluasi yang lebih robust agar kesimpulan mengenai kemampuan generalisasi model dapat diperoleh secara lebih meyakinkan.

V. KESIMPULAN

Berdasarkan hasil eksperimen, Gaussian Naive Bayes dapat diterapkan untuk mengklasifikasikan tingkat kebutuhan pelayanan kesehatan pascabencana pada dataset penelitian. Model memperoleh accuracy sebesar 83,33% dengan lima dari enam observasi data uji diklasifikasikan secara benar. Weighted precision, weighted recall, dan weighted F1-score masing-masing sebesar 70,83%, 83,33%, dan 76,19%. Namun, satu-satunya observasi kelas Tinggi pada data uji salah diklasifikasikan sebagai kelas Sedang sehingga recall kelas Tinggi sebesar 0%. Temuan ini menunjukkan bahwa hasil agregat harus ditafsirkan secara hati-hati karena ukuran dataset dan data uji sangat kecil. Waktu eksekusi kurang dari 12 milidetik pada konfigurasi perangkat yang digunakan menunjukkan kebutuhan komputasi yang rendah dalam eksperimen. Penelitian selanjutnya perlu memperluas dataset, memperbaiki representasi kelas, dan melakukan validasi eksternal sebelum model dipertimbangkan untuk penggunaan operasional.

UCAPAN TERIMA KASIH

Para penulis menyampaikan terima kasih kepada Universitas Prima Indonesia atas dukungan institusional dalam pelaksanaan penelitian. Terima kasih juga disampaikan kepada Badan Nasional Penanggulangan Bencana (BNPB) atas penyediaan data bencana publik yang digunakan sebagai sumber penelitian.

PERNYATAAN KONTRIBUSI PENULIS

AS merancang kerangka penelitian dan metodologi machine learning di bawah supervisi dan bimbingan JR sebagai penasihat penelitian. AS, RG, dan GN mengumpulkan dataset historis bencana serta melakukan tahapan prapemrosesan data. AS dan GV melaksanakan implementasi algoritma Gaussian Naive Bayes dan menghasilkan metrik evaluasi. RG, GN, dan GV menyusun hasil dan pembahasan. JR memberikan revisi kritis, arahan struktural, dan persetujuan akhir terhadap naskah.

REFERENCES

- [1] M. A. Hariri-Ardebili, S. Sattar, K. Johnson, C. Clavin, J. Fung, and L. Ceferino, "A perspective towards multi-hazard resilient systems: natural hazards and pandemics," *Sustainability*, vol. 14, no. 8, p. 4508, 2022.
- [2] E. Z. Heanoy and N. R. Brown, "Impact of natural disasters on mental health: evidence and implications," in *Healthcare*, MDPI, 2024, p. 1812.
- [3] A. Ramada, "Strategic approaches in disaster management: Analyzing the roles of public health professionals from emergency response to post-disaster recovery," *J. Evidence-based Nurs. Public Heal.*, vol. 1, no. 2, 2024.
- [4] C. D. Onyejesi et al., "Pediatric emergency disaster preparedness: a narrative review of global disparities, challenges, and policy solutions," *Int. J. Emerg. Med.*, vol. 18, no. 1, p. 91, 2025.
- [5] N. Y. Panma et al., *Disaster Management (Manajemen Bencana)*. Rizmedia Pustaka Indonesia, 2024.
- [6] M. Taiwo, "Optimizing public health infrastructure through predictive modelling for resource distribution and crisis management," *Int. J. Res. Publ. Rev.*, vol. 6, no. 1, pp. 1706–1724, 2025.
- [7] D. D. Wijaya, "A space-based geodetic approach for mitigating hydro-meteorological disasters in Indonesia," *Rep. Grant-Supported Res. Asahi Glas. Found.*, vol. 91, 2022.
- [8] N. Nasri et al., "Ecological Disaster in Northern Sumatra: How Extreme Rainfall and Land-Cover Disturbance Triggered Widespread Flash Flooding," *J. Penelit. Kehutan. Wallacea*, vol. 14, no. 2, pp. 111–121, 2025.
- [9] D. Arockiam, "Fuzzy Logic System Implementation in Health Data Management Frameworks," *Healthc. 5.0 with Fuzzy Log. Artif. Intell. Cyber-Physical Syst. Med. Internet Things*, p. 83, 2025.
- [10] M. Arunkumar, K. Rajkumar, W. R. Jeyaseelan, and N. A. Natraj, "Data mining, machine learning, and statistical modeling for predictive analytics with behavioral big data," *Teh. Vjesn.*, vol. 32, no. 1, pp. 72–77, 2025.
- [11] R. Kumar, B. Goswami, S. M. Mhatre, and S. Agrawal, "Naive bayes in focus: a thorough examination of its algorithmic foundations and use cases," *Int. J. Innov. Sci. Res. Technol.*, vol. 9, no. 5, pp. 2078–2081, 2024.
- [12] P. J. B. Pajila, B. G. Sheena, A. Gayathri, J. Aswini, and M. Nalini, "A comprehensive survey on naive bayes algorithm: Advantages, limitations and applications," in *2023 4th International Conference on Smart Electronics and Communication (ICOSEC)*, IEEE, 2023, pp. 1228–1234.
- [13] A. A. Purnama and Y. R. Sipayung, "Sentiment analysis of public service using naïve Bayes classifier," *J. Inf. Syst. Informatics*, vol. 7, no. 3, pp. 2439–2457, 2025.
- [14] M. Hussein et al., "The utility of artificial intelligence in the management of dengue fever: a perspective on

- future directions,” *Trans. R. Soc. Trop. Med. Hyg.*, vol. 119, no. 10, pp. 1215–1221, 2025.
- [15] D. K. Muhsen, B. F. Khmas, A. A. Ahmed, and A. T. Sadiq, “Comparative Analysis of Machine Learning Models for Predictive Healthcare in Chronic Disease Management,” *J. Intell. Syst. Internet Things*, vol. 17, no. 2, pp. 36–49, 2025.
- [16] Y. Singh and N. Gulati, “Machine Learning Techniques for Accurate Prediction and Detection of Chronic Diseases,” in *Machine Learning in Multimedia*, CRC Press, 2024, pp. 1–21.
- [17] B. Ogwel, V. Mzazi, B. O. Nyawanda, G. Otieno, and R. Omoro, “Predictive modeling for infectious diarrheal disease in pediatric populations: A systematic review,” *Learn. Heal. Syst.*, vol. 8, no. 1, p. e10382, 2024.
- [18] J. Amann, “Machine learning in stroke medicine: Opportunities and challenges for risk prediction and prevention,” *Artif. Intell. brain Ment. Heal. Philos. ethical policy issues*, pp. 57–71, 2022.
- [19] D. R. Anamisa, M. Yusuf, W. Agustiono, M. Syarief, and M. A. Syakur, “Identification of acute respiratory infections in toddlers based on the chi-square and naive bayes methods,” in *2021 IEEE 7th Information Technology International Seminar (ITIS)*, IEEE, 2021, pp. 1–5.




Abel Johannes Saragih, Lahir di Medan, 03 Mei 2004 Riwayat Pendidikan lulus dari Program Strata Satu (S1) Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Prima Indonesia, Medan, Indonesia pada Tahun 2026



Gita Valentina Br. Tarigan, Lahir di Medan, 04 Februari 2005 Riwayat Pendidikan lulus dari Program Strata Satu (S1) Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Prima Indonesia, Medan, Indonesia pada Tahun 2026



Rohitta Girsang, Lahir di Rakut Besi, 23 November 2003 Riwayat Pendidikan lulus dari Program Strata Satu (S1) Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Prima Indonesia, Medan, Indonesia pada Tahun 2026



Guddes Theresia Naibaho, Lahir di Onan Baru, 22 Januari 2005 Riwayat Pendidikan lulus dari Program Strata Satu (S1) Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Prima Indonesia, Medan, Indonesia pada Tahun 2026



Jijon Rapita Sagala. Lahir di Situnggaling 04 September 1984. Lulus Sarjana Komputer di STMIK Sisingamangaraja XII Medan pada tahun 2011. Lulus Magister Komputer di Universitas Sumatera Utara (USU) pada tahun 2013. Saat ini aktif sebagai Dosen Tetap di Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Prima Indonesia. Aktif juga sebagai peneliti dan penulis jurnal ilmiah nasional maupun internasional.