

Penerapan Algoritma Klasifikasi Naive Bayes dalam Klasifikasi Kebutuhan Perawatan Pasien Demam Berdarah *Dengue*

Moch. Anjas Apriharta*, Zulhandi Putrawan, Dicky Zulhan

Universitas Dian Nuswantoro, Semarang, Indonesia

Email Korespondensi: anjas.aprihartha@dsn.dinus.ac.id

Genesis Artikel: Diterima: 11 Agustus 2025 Diterbitkan: 23 Agustus 2025

ABSTRACT: *Dengue fever (DF) is an illness caused by the Dengue virus, transmitted to humans through the bite of female Aedes aegypti mosquitoes, and the rise in DF cases often leads to a surge in hospital visits that can result in shortages of beds and medical personnel. In severe conditions, patients require treatment from health professionals experienced in managing this disease, and with advancements in scientific methods, classification techniques have become essential in identifying the severity level of DF patients to determine immediate and necessary treatment. This study aims to classify DF patients who require inpatient care by applying the Naive Bayes method to 230 observation records obtained from medical data of DF patients at Anwar Makkatutu Hospital in Bantaeng Regency during the 2019–2020 period, with model performance evaluated using a confusion matrix. The findings show that the Naive Bayes algorithm demonstrates fairly good performance in identifying patients who need hospitalization and those who do not, indicated by its AUC, accuracy, sensitivity, and specificity values of 0.702, 70.11%, 59.09%, and 81.40%, respectively. These results support more efficient allocation of limited healthcare resources and offer practical implications for clustering DF patients who require medical attention, enabling health authorities to improve planning, prepare adequate medical facilities, and optimize treatment readiness, while also contributing valuable insights to the scientific literature on related topics.*

Keyword: *classification; DHF; Naive Bayes; patients.*

ABSTRAK: Demam berdarah *Dengue* (DBD) merupakan penyakit yang disebabkan oleh virus *Dengue*. Virus ini menyebar ke tubuh manusia melalui gigitan nyamuk *Aedes Aegypti* betina. Terjadinya kasus DBD menyebabkan banyak pasien mengunjungi ke rumah sakit. Dalam situasi ini, rumah sakit kerap kali kekurangan kamar dan tenaga medis. Pada tahap yang sangat parah pasien DBD memerlukan perawatan medis oleh tenaga kesehatan yang ahli dalam menangani penyakit ini. Dalam kemajuan ilmu pengetahuan, metode klasifikasi memiliki peran vital dalam mendeteksi pasien DBD menurut tingkat keparahan sehingga pasien perlu mendapatkan perawatan atau tidak. Penelitian ini bertujuan untuk mengidentifikasi pasien DBD yang butuh perawatan atau tidak dengan mengaplikasikan metode Naive Bayes. Penelitian ini menerapkan metode klasifikasi Naive Bayes pada sebanyak 230 data amatan yang berasal dari data rekam medis pasien DBD di Rumah Sakit Anwar Makkatutu Kabupaten Bantaeng pada periode 2019 sampai 2020 dan *Confusion matrix* untuk menguji performa model Hasil penelitian diperoleh algoritma Naive Bayes memberikan kinerja yang cukup baik dalam mengidentifikasi status pasien DBD yang dirawat dan tidak dirawat, dengan dibuktikan nilai AUC, akurasi, sensitivitas, dan spesifisitas masing-masing sebesar 0,702; 70,11%; 59,09%; 81,40%. Hal ini dapat membantu mengatasi masalah dalam alokasi sumber daya yang terbatas secara lebih efisien. Temuan penelitian ini memiliki implikasi dalam proses klasterisasi pasien DBD yang membutuhkan perawatan, otoritas kesehatan akan lebih baik dalam membuat perencanaan termasuk persiapan fasilitas medis dan perawatan yang diperlukan dan menambah literatur ilmiah terkait riset pada topik serupa.

Kata Kunci: DBD; klasifikasi; Naive Bayes; pasien.

Ini adalah artikel akses terbuka dibawah lisensi [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/).



Cara Sitasi:

Apriharta, M.A., Putrawan, Z., & Zulhan, D. (2025). Penerapan Algoritma Klasifikasi Naive Bayes dalam Klasifikasi Kebutuhan Perawatan Pasien Demam Berdarah *Dengue* (DBD). *UPGRADE: Jurnal Pendidikan Teknologi Informasi*, 4(1), 34-42. <https://doi.org/10.30812/upgrade.v3i1.5457>

PENDAHULUAN

Demam berdarah *Dengue* (DBD) merupakan penyakit yang disebabkan oleh virus *Dengue*. Virus ini menular ke tubuh manusia melewati gigitan nyamuk *Aedes aegypti* betina (Desfita et al., 2021). Terdapat beberapa nyamuk lain yang dapat menjadi vektor DBD yaitu nyamuk *Aedes Polynesiensis*, *Aedes scutellaris* dan *Aedes albopictus* (Fitria and Samudra, 2025). Penyakit DBD tersebar luas di berbagai belahan dunia, terutama di negara-negara dengan iklim tropis dan subtropis salah satunya Indonesia. Ketika curah hujan meningkat maka akan meningkatkan aktivitas vektor penyebab *Dengue* (Dissa Nur Olivia et al., 2025).

Melonjaknya jumlah penderita DBD diberbagai wilayah menyebabkan meningkatnya pasien yang datang untuk mendapatkan perawatan ke rumah sakit sehingga mendorong terjadinya kepadatan layanan kesehatan (Widianawati and Widiyanti, 2022). Dalam situasi darurat seperti ini, rumah sakit sering kali menghadapi tantangan serius seperti kekurangan kamar dan tenaga medis (Yeremia Tiopan Pandapotan Purba, 2024). Pada tahap yang sangat parah pasien DBD memerlukan penanganan intensif oleh dokter dan perawat yang ahli dalam mengelola penyakit ini (Fitria and Samudra, 2025). Perawatan yang diberikan oleh tenaga kesehatan berpengalaman dapat menolong nyawa pasien dan memperkecil tingkat kematian.

Agar perawatan yang diberikan oleh tenaga kesehatan berpengalaman dapat lebih tepat sasaran dan optimal dalam membatasi angka kematian, diperlukan suatu proses klasifikasi pasien DBD dengan cara mengelompokkan data setiap pasien berdasarkan aspek-aspek penting yang memengaruhi tingkat keparahan mereka (Pascawati et al., 2022). Proses ini meliputi analisis kemungkinan perkembangan penyakit berdasarkan diagnosis yang dilakukan (Rianti et al., 2023). Pasien DBD umumnya mengalami gejala yang ditandai dengan fluktuasi trombosit dan hematokrit, sesuai dengan kondisi klinis yang dialami (Tandjungbulu et al., 2025). Oleh karena itu, penting untuk mengidentifikasi faktor-faktor yang berhubungan dengan lama perawatan, jumlah trombosit, hematokrit, serta aspek lain, guna mendukung proses diagnosis pasien DBD baik yang dirawat di rumah sakit maupun yang tidak (Ningsih et al., 2023; Siregar et al., 2021).

Dalam kemajuan ilmu pengetahuan, metode klasifikasi memiliki peran penting dalam mengklasifikasikan pasien DBD menurut tingkat keparahan sehingga pasien tersebut perlu mendapatkan perawatan atau tidak (Anwar et al., 2024). Salah satu metode klasifikasi yang dapat digunakan adalah metode Naive Bayes. Metode ini memanfaatkan teorema Bayes dalam perhitungannya dan umumnya digunakan untuk memprediksi probabilitas kejadian yang ada di masa depan dengan melihat pengalaman yang terjadi di masa lalu (Bugis, 2022). Watratan et al. (2020) memaparkan metode Naive Bayes dapat digunakan untuk jumlah dataset *training* yang kecil dalam menaksir estimasi parameter yang diperlukan pada proses membangun model. Beberapa penelitian penggunaan metode Naive Bayes seperti klasifikasi penyakit diabetes melitus (Apriharta et al., 2024). Dalam penelitiannya, peneliti melakukan klasifikasi untuk menentukan pasien yang telah melakukan pemeriksaan kesehatan pada penyakit diabetes melitus atau tidak. Hasil penelitian diperoleh tingkat akurasi model sebesar 92,07% yang menunjukkan model sangat baik dalam mendiagnosa pasien yang menderita diabetes melitus. Selain itu, penerapan algoritma Naive Bayes dalam menentukan tingkat kenyamanan pada rumah sakit terhadap pasien (Nizam Fadli et al., 2021). Hasil penelitian diperoleh model Naive Bayes memiliki tingkat keakuratan dalam memprediksi tingkat kepuasan pasien rumah sakit sebesar 80%, yang tergolong model cukup sempurna. Penelitian oleh Suhendar et al. (2024) mengidentifikasi pasien DBD yang membutuhkan perawatan dengan menggunakan algoritma *Classification and Regression Tree* (CART), hasil penelitian menunjukkan CART mampu mengolah data epidemiologi, iklim, dan demografi untuk menghasilkan klasifikasi indeks DBD, meskipun akurasi masih perlu ditingkatkan. Pada hasil temuan ini, disarankan agar penelitian selanjutnya dapat mengaplikasikan metode yang lain dengan penerapan kasus yang sama.

Berdasarkan *gap* penelitian sebelumnya, penelitian ini bertujuan untuk mengidentifikasi pasien DBD yang butuh perawatan atau tidak dengan mengaplikasikan metode Naive Bayes dan menguji potensi *overfitting* atau *underfitting* pada model dengan membandingkan kinerjanya terhadap data *training* dan data testing. Penerapan metode Naive Bayes diharapkan dapat membantu memecahkan permasalahan dalam alokasi sumber daya yang terbatas secara lebih efisien. Dalam mengetahui pasien DBD yang

membutuhkan perawatan, otoritas kesehatan akan lebih baik dalam membuat perencanaan termasuk persiapan fasilitas medis dan perawatan yang diperlukan.

METODE

Data dan Variabel Penelitian

Data yang digunakan pada penelitian ini adalah data sekunder dengan jumlah data sebanyak 230 amatan yang berasal dari data rekam medis pasien DBD di Rumah Sakit Anwar Makkatutu Kabupaten Bantaeng pada periode 2019 sampai 2020. Pemilihan periode satu tahun mencakup variasi kasus pada musim hujan dan kemarau, sehingga dapat menggambarkan distribusi kasus DBD secara menyeluruh. Variabel penelitian terdiri dari variabel independen (X) dan variabel dependen (Y). Keterangan tiap variabel disajikan pada Tabel 1.

Tabel 1. Variabel Penelitian

Variabel	Kategori
Pasien Penderita DBD (Y)	1) Pasien Penderita DBD yang dirawat 2) Pasien Penderita DBD yang tidak dirawat
Jenis Kelamin (X_1)	1) Laki-laki 2) Perempuan
Jumlah Trombosit (X_2)	1) $< 100000/\mu l$ 2) $> 100000/\mu l$
Jumlah Hematokrit (X_3)	1) Menurun 2) Normal
Lama Rawat (X_4)	1) 1 - 5 hari 2) 6 - 10 hari

Metode Naive Bayes

Klasifikasi Bayesian adalah proses yang memperkirakan probabilitas suatu observasi baru yang termasuk dalam kategori yang telah ditentukan, menggunakan model probabilitas yang ditentukan menurut teori Bayes (Jawalageri et al., 2024). Teknik ini menilai probabilitas sebelumnya dari setiap kategori berdasarkan sekumpulan besar data pelatihan, yang dijelaskan oleh sejumlah variabel, dan mengasumsikan bahwa klasifikasi dapat diperkirakan dengan menghitung fungsi kepadatan probabilitas bersyarat dan probabilitas posteriori. Metode Naive Bayes karena mampu mengklasifikasikan data medis yang memadukan gejala klinis dan hasil laboratorium secara efisien dengan pendekatan probabilistik, serta tetap akurat dan cepat meskipun jumlah data terbatas (Novaldy and Herliana, 2021).

Metode Naive Bayes mengasumsikan semua variabel independen tidak saling bergantung satu sama lain (Li et al., 2022). Diberikan himpunan sampel, $X = \{x_1, x_2, \dots, x_m\}$ yang memiliki n variabel independen. Berdasarkan variabel tersebut, sampel dapat dipartisi dalam $Y = \{c_1, c_2, \dots, c_N\}$ kategori berbeda. Tujuannya dari pengklasifikasi Bayesian adalah untuk memaksimalkan probabilitas posterior, sehingga dapat dinyatakan sebagai berikut.

Persamaan Teorema Bayes (1) menyatakan bahwa klasifikasi dilakukan dengan memilih kelas yang memiliki peluang terbesar untuk data x . Melalui Teorema Bayes, peluang tersebut diuraikan pada persamaan (2) menjadi kombinasi antara peluang awal kelas dan peluang kemunculan data pada kelas tersebut. Karena $P(x)$ bernilai sama untuk semua kelas, bagian ini dapat diabaikan sehingga diperoleh bentuk sederhana pada persamaan (3). Jika setiap atribut dianggap independen, peluang gabungan dapat dipecah menjadi perkalian peluang tiap atribut, seperti ditunjukkan pada persamaan (4). Dengan demikian, Naive Bayes menentukan kelas terbaik berdasarkan produk antara peluang awal kelas dan peluang setiap atribut yang muncul.

$$h^*(x) = \arg \max_{c \in Y} P\left(\frac{c}{x}\right) \quad (1)$$

$$h^*(x) = \arg \max_{c \in Y} \frac{P(x, c)}{P(x)} = \arg \max_{c \in Y} \frac{P(c)P(x/c)}{P(x)} \quad (2)$$

$$h^*(x) = \arg \max_{c \in Y} P(c)P\left(\frac{x}{c}\right) \quad (3)$$

$$h^*(x) = \arg \max_{c \in Y} P(c) \prod_{i=1}^m P\left(\frac{x_i}{c}\right) \quad (4)$$

Uji Performa Model

Confusion matrix merupakan tabel yang memberikan hasil diuji dari data testing. Metode ini paling intuitif untuk melihat kinerja klasifikasi (Aprihartha et al., 2024). Tabel 2 menunjukkan penjabaran *Confusion matrix* yang digunakan pada penelitian ini.

Tabel 2. Confusion Matrix

		Kelas Prediksi	
		Ya	Tidak
Kelas Observasi	Ya	<i>a</i>	<i>b</i>
	Tidak	<i>c</i>	<i>d</i>

Metrik evaluasi yang digunakan meliputi akurasi, sensitivitas, spesifisitas, dan AUC. Akurasi digunakan untuk menilai kinerja umum model, sensitivitas untuk memastikan kasus pasien yang tidak dirawat terdeteksi secara optimal, spesifisitas untuk menghindari salah diagnosis pada pasien yang dirawat (Suhendar et al., 2024), dan AUC untuk mengukur kemampuan model membedakan kedua kelas secara keseluruhan.

$$Akurasi = \frac{a + d}{a + b + c + d} \times 100\% \quad (5)$$

$$Sensitivitas = \frac{a}{a + b} \times 100\% \quad (6)$$

$$Spesifisitas = \frac{d}{c + d} \times 100\% \quad (7)$$

$$AUC = \frac{1 + \left(\frac{a}{a+b}\right) - \left(\frac{1-d}{c+d}\right)}{2} \quad (8)$$

HASIL DAN PEMBAHASAN

Eksplorasi Data

Pada Gambar 2, grafik jenis kelamin memperlihatkan jumlah penderita DBD perempuan lebih tinggi dibandingkan laki-laki. Terdapat 63 pasien perempuan yang dirawat sedangkan 64 lainnya tidak dirawat. Grafik tromposit menunjukkan bahwa pasien yang memiliki trombosit < 100000 paling banyak dirawat dibandingkan pasien yang memiliki trombosit ≥ 100000. Grafik hematokrit menunjukkan 74 pasien dengan hematokrit menurun memilih tidak dirawat dan 65 pasien dengan hematokrit normal memilih dirawat. Grafik lama rawat menunjukkan hampir tidak ada perbedaan signifikan antara jumlah pasien yang dirawat dengan tidak dirawat pada periode 1-5 hari. Pada periode 6-10 hari, jumlah pasien yang dirawat cukup tinggi dibandingkan dengan pasien tidak dirawat.



Gambar 1. Asosiasi Variabel Independen Terhadap Variabel Dependen

Evaluasi Performa Algoritma Naive Bayes

Langkah pertama adalah membagi data *training* dan data testing. Pembagian data ini perlu dilakukan untuk melatih algoritma dengan data *training* kemudian melakukan evaluasi algoritma menggunakan data testing. Pengambilan sampel data *training* sebanyak 143 amatan yang dilakukan menggunakan teknik *simple random sampling* kemudian sisanya 87 amatan sebagai data testing. Langkah perhitungan Naive Bayes sebagai berikut:

1. Probabilitas Prior

$$P(Y = \text{Dirawat}) = \frac{\text{Jumlah pasien dirawat}}{\text{Total Pasien}} \quad (9)$$

$$P(Y = \text{Tidak dirawat}) = \frac{\text{Jumlah pasien tidak dirawat}}{\text{Total Pasien}} \quad (10)$$

2. Probabilitas kondisional (*likelihood*)

Lakukan untuk setiap atribut dan kategori kelas. Misalnya:

$$P(X_1 = \text{Laki} - \text{laki} | Y = \text{Dirawat}) = \frac{\text{Jumlah pasien laki-laki dirawat}}{\text{Total pasien dirawat}} \quad (11)$$

3. Probabilitas Posterior

Untuk suatu pasien dengan atribut X_1, X_2, X_3 , dan X_4 . Hitung:

$$P(Y = c | X) \propto P(Y = c) P(X_1 | Y = c) P(X_2 | Y = c) P(X_3 | Y = c) P(X_4 | Y = c) \quad (12)$$

Lalu pilih kelas c dengan nilai posterior terbesar.

Proses pelatihan algoritma Naive Bayes memanfaatkan *software* Rstudio dengan *packages* *naive-bayes*. Tabel 3 ditampilkan hasil kinerja model pada data *training*. Hasil akurasi yaitu 59,44% menunjukkan bahwa model hanya mampu mengklasifikasikan data dengan benar sebesar 59,44% dari seluruh data *training* sehingga nilai ini masih tergolong rendah. Nilai 46,27% berarti model cukup sering gagal mendeteksi pasien yang seharusnya terklasifikasi sebagai yang perlu dirawat. Nilai 71,05% berarti model lebih baik dalam mengidentifikasi kelas pasien yang tidak dirawat dibanding pasien yang dirawat. Nilai 0,586 masih rendah karena nilai ideal mendekati 1.

Tabel 3. Kinerja Model Naive Bayes pada Data *Training*

Metrik Evaluasi	Hasil
Akurasi	59,44%
Sensitifitas	46,27%
Spesifikasi	71,05%
AUC	0,586

Kemudian, pada Tabel 4 disajikan hasil uji pada data testing dari algoritma Naive Bayes dalam bentuk confusion matrix. Menurut Tabel 4, terdapat 26 amatan yang tepat terklasifikasi pada kelas tidak dirawat sedangkan 35 amatan tepat terklasifikasi pada kelas dirawat. Namun, ada 26 amatan yang mengalami gagal klasifikasi. Kemudian menghitung performa model dengan menggunakan persamaan 5, 6, 7, 8.

Tabel 4. Confusion Matrix Naive Bayes

		Kelas Prediksi	
		Tidak Dirawat	Dirawat
Kelas Observasi	Tidak Dirawat	26	18
	Dirawat	8	35


$$Akurasi = \frac{26 + 35}{26 + 35 + 18 + 8} \times 100\% = 70,11\% \quad (13)$$

$$Sensitivitas = \frac{26}{26 + 18} \times 100\% = 59,09\% \quad (14)$$

$$Spesifisitas = \frac{35}{35 + 8} \times 100\% = 81,40\% \quad (15)$$

$$AUC = \frac{(1 + 0,5909) - (1 - 0,8140)}{2} = 0,702 \quad (16)$$

Akurasi 70,11% berarti persentase klasifikasi yang dibuat model adalah benar sebesar 70,11%. Sensitivitas 59,09% berarti model sukses mengidentifikasi 59,09% dari seluruh kasus pasien DBD yang tidak dirawat. Spesifisitas sebesar 81,40% berarti model berhasil mengidentifikasi 81,40% dari seluruh pasien DBD yang dirawat. Hasil ini sejalan dengan temuan (Anwar et al., 2024), yang menjelaskan bahwa metode Naive Bayes cenderung memiliki spesifisitas lebih tinggi dibandingkan sensitivitas pada klasifikasi penyakit berbasis data gejala dan laboratorium. Temuan ini menunjukkan perlunya peningkatan kualitas data input, misalnya dengan menambah variabel penunjang diagnosis, untuk meningkatkan sensitivitas tanpa mengorbankan spesifisitas.



Gambar 2. ROC Naive Bayes

Selain itu, dihasilkan AUC sebesar 0,702 yang berarti model cukup baik dalam membedakan kelas pasien yang dirawat dengan dan kelas pasien yang dirawat. Nilai AUC ini disajikan dalam grafik ROC seperti pada Gambar 2. Pada Gambar 2, performa model dapat dikatakan berada pada kategori cukup baik. Model sudah bisa membantu dalam prediksi, tetapi masih ada ruang besar untuk peningkatan akurasi. Pada Tabel 5, diberikan perbandingan metrik evaluasi model Naive Bayes dari data *training* dan data testing.

Tabel 5. Perbandingan Kinerja Model Naive Bayes

Metrik Evaluasi	Hasil Uji pada Data <i>Training</i>	Hasil Uji pada Data <i>Testing</i>
Akurasi	59,44%	70,11%
Sensitivitas	46,27%	59,09%
Spesifisitas	71,05%	81,40%
AUC	0,586	0,702

Berdasarkan Tabel 5, ditunjukkan bahwa hasil uji performa model pada data *training* terlihat lebih rendah dibandingkan dengan data testing. Walaupun adanya peningkatan pada data testing, namun hasil evaluasinya masih cukup baik. Model tampaknya belum cukup kompleks atau belum optimal dalam menangkap pola data. Oleh karena itu, model terindikasi mengalami *underfitting*. Kondisi ini terjadi ketika performa *training* rendah dan tidak mampu belajar pola dengan baik (Firmansyach et al., 2023).

Disisi lain, pada penelitian sebelumnya yang dilakukan oleh (Suhendar et al., 2024) menggunakan metode CART mendeteksi pasien DBD yang membutuhkan perawatan, dengan menetapkan jumlah data *training* dan data testing masing-masing 143 amatan dan 87 amatan. Hasil uji dengan data testing diperoleh akurasi sebesar 56,32%, sensitivitas sebesar 25%, dan spesifisitas sebesar 82,97%. Jika dibandingkan penelitian ini dengan metode Naive Bayes pada data testing maka terjadi peningkatan akurasi sebesar 13,79%, peningkatan signifikan pada sensitivitas sebesar 34,09%, namun penurunan spesifisitas yang tidak terlalu tinggi sebesar 1,57%. Jadi dalam studi kasus ini metode Naive Bayes memberikan performa lebih baik dibandingkan metode CART.

KESIMPULAN

Penelitian ini mengklasifikasikan kebutuhan perawatan pasien DBD menggunakan metode Naive Bayes serta mengevaluasi potensi *overfitting* dan *underfitting* melalui perbandingan kinerja pada data *training* dan testing. Pendekatan ini diharapkan mendukung efisiensi alokasi sumber daya medis yang terbatas. Penerapan algoritma Naive Bayes menunjukkan kinerja yang cukup baik dalam mengklasifikasikan kebutuhan perawatan pasien DBD, dengan dibuktikan nilai AUC sebesar 0,702. Selain itu, kinerja model dalam akurasi, sensitivitas, dan spesifisitas masing-masing sebesar 70,11%; 59,09%; dan 81,40%. Namun, perbandingan performa antara *training* dan testing mengindikasikan model mengalami *underfitting*, karena tidak mampu belajar dengan baik dari data *training*. Oleh karena itu, penelitian ini masih membutuhkan variabel independen lebih banyak lagi untuk meningkatkan kinerja model. Terapkan validasi silang (*cross-validation*) untuk memastikan hasil evaluasi konsisten dan tidak bergantung pada pembagian data tertentu. Selain itu diharapkan penelitian selanjutnya dapat menggunakan metode klasifikasi lain seperti *k-nearest neighbour*, regresi logistik, *random forest*, *support vector machine*, dan lain-lain untuk meningkatkan kinerja model lebih baik mengoptimalkan penggunaan sumber daya medis yang terbatas.

UCAPAN TERIMAKASIH

DEKLARASI

Taksonomi Peran Kontributor

Tuliskan kontribusi tiap penulis dalam proses penulisan artikel naskah yang akan diterbitkan. Contoh: “Penulis 1: Penulisan – Draf Asli, Penulisan – Review & Editing, Konseptualisasi, Analisis Formal, Investigasi, Sumber Daya, Visualisasi. Penulis 2 dan Penulis 3: Konseptualisasi, Analisis Formal,

Penyelidikan, Pengawasan. Penulis 4: Writing – Review & Editing, Visualisasi, Supervisi”. Apabila penulis tidak mencantumkan maka editor akan secara langsung menuliskan “Semua penulis berkontribusi sama sebagai kontributor utama dari makalah ini. Semua penulis membaca dan menyetujui makalah akhir”.

Pernyataan Pendanaan

Tuliskan sumber pendanaan utama penelitian seperti hibah khusus dari lembaga pendanaan di sektor publik, komersial, atau nirlaba. Jika sumber dana tidak diperoleh dari sumber diatas atau merupakan dari dana pribadi maka penulis dapat menuliskan “Penelitian ini tidak menerima hibah khusus dari lembaga pendanaan di sektor publik, komersial, atau nirlaba.”

Kepentingan Bersaing

Semua penulis harus mengungkapkan setiap hubungan keuangan dan pribadi dengan orang atau organisasi lain yang dapat secara tidak tepat mempengaruhi (bias) pekerjaan mereka. Contoh potensi konflik kepentingan termasuk pekerjaan, konsultan, kepemilikan saham, honorarium, kesaksian ahli berbayar, aplikasi/pendaftaran paten, dan hibah atau pendanaan lainnya. Penulis harus memberikan perhatian mereka tentang pernyataan pernyataan minat bersaing selama penyerahan hak cipta artikel ke jurnal bahwa penulis menyatakan bahwa mereka tidak mengetahui persaingan kepentingan keuangan atau hubungan pribadi yang mungkin tampak mempengaruhi pekerjaan yang dilaporkan dalam artikel ini.

Informasi Tambahan

Tuliskan informasi tambahan jika diperlukan.

DAFTAR PUSTAKA

- Anwar, S., Faujiah, R. L., Hartati, T., and Tohidi, E. (2024). Jurnal Informatika dan Rekayasa Perangkat Lunak Klasifikasi Penentuan Tingkat Penyakit Demam Berdarah dengan menggunakan Algoritma Naive Bayes (Studi Kasus Puskesmas Nagreg). *Jurnal Informatika dan Rekayasa Perangkat Lunak*, 6(1):205–212.
- Aprihartha, M. A., Prasetya, J., and Fallo, S. I. (2024). Implementasi CART-Real Adaboost dalam Memprediksi Minat Pelanggan Membeli Sepatu. *Jurnal EurekaMatika*, 12(1):35–46.
- Bugis, H. (2022). Metode Naive Bayes Untuk Memprediksi Penyakit Stroke. *Jurnal SISKOM-KB (Sistem Komputer dan Kecerdasan Buatan)*, 6(1). <https://doi.org/10.47970/siskom-kb.v6i1.317>.
- Desfita, S., Azzahra, M., Zulriyanti, N., Putri, M. N., and Anggraini, S. (2021). Jurnal Pengabdian Kesehatan Komunitas (Journal of Community Health Service). *Jurnal Pengabdian Kesehatan Komunitas*, 01(1):20–31.
- Dissa Nur Olivia, Suherman, and Sekarputri, A. L. (2025). Pengaruh Faktor Cuaca (Curah Hujan, Kelembapan, dan Suhu) Terhadap Kejadian DBD. *Health and Medical Sciences*, 2(3):16. <https://doi.org/10.47134/phms.v2i3.412>.
- Firmansyach, W. A., Hayati, U., and Arie Wijaya, Y. (2023). Analisa Terjadinya Overfitting Dan Underfitting Pada Algoritma Naive Bayes Dan Decision Tree Dengan Teknik Cross Validation. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(1). <https://doi.org/10.36040/jati.v7i1.6329>.
- Fitria, A. and Samudra, G. (2025). Edukasi Pemberantasan Sarang Nyamuk (PSN) sebagai Upaya Pencegahan Demam Berdarah Dengue di Kelurahan Kejambon Kecamatan Tegal Timur Kota Tegal. *JABI: Jurnal Abdimas Bhakti Indonesia*, 6(1):38–48.
- Jawalageri, S., Ghiasi, R., Jalilvand, S., Prendergast, L. J., and Malekjafarian, A. (2024). A data-driven approach for scour detection around monopile-supported offshore wind turbines using Naive Bayes classification. *Marine Structures*, 95. <https://doi.org/10.1016/j.marstruc.2023.103565>.

- Li, L., Zhou, Z., Bai, N., Wang, T., Xue, K. H., Sun, H., He, Q., Cheng, W., and Miao, X. (2022). Naive Bayes classifier based on memristor nonlinear conductance. *Microelectronics Journal*, 129. <https://doi.org/10.1016/j.mejo.2022.105574>.
- Ningsih, R., Hargono, A., and Ratgono, A. (2023). Analisis Masalah Kesehatan pada Program Demam Berdarah Dengue di Kabupaten Tulungagung Jawa Timur. *Malahayati Nursing Journal*, 5(8). <https://doi.org/10.33024/mnj.v5i8.9446>.
- Nizam Fadli, M., Sudahri Damanik, I., Irawan, E., Tunas Bangsa, S., and Utara, S. (2021). KLIK: Kajian Ilmiah Informatika dan Komputer Penerapan Metode Naive Bayes Dalam Menentukan Tingkat Kenyamanan Pada Rumah Sakit Terhadap Pasien. *Media Online*, 2(3).
- Novaldy, F. and Herliana, A. (2021). Penerapan Pso Pada Naive Bayes Untuk Prediksi Harapan Hidup Pasien Gagal Jantung. *Jurnal Responsif : Riset Sains dan Informatika*, 3(1). <https://doi.org/10.51977/jti.v3i1.396>.
- Pascawati, N. A., Sahid, S., Sukismanto, S., and Yuningrum, H. (2022). Faktor yang Berhubungan dengan Pola Pengelompokkan Kasus Demam Berdarah Dengue (DBD) di Temanggung, Jawa Tengah. *Balaba: Jurnal Litbang Pengendalian Penyakit Bersumber Binatang Banjarnegara*. <https://doi.org/10.22435/blb.v18i1.5957>.
- Rianti, E., Metasari, D., and Surahman S, F. (2023). Hubungan Trombosit Dan Hematokrit Dengan Kejadian DBD Di Rumah Sakit Tiara Sella Kota Bengkulu Tahun 2022. *Jurnal Vokasi Kesehatan*, 2(2). <https://doi.org/10.58222/juvokes.v2i2.164>.
- Siregar, S., Hutagaol, A., Damanik, H., and Manurung, S. S. (2021). Gambaran Pengetahuan Keluarga Tentang Pembuangan Limbah Sampah Terhadap Pencegahan Dbd Di Lingkungan V Kelurahan Labuhan Deli. *Jurnal Ilmiah Keperawatan Imelda*, 7(2). <https://doi.org/10.52943/jikeperawatan.v7i2.400>.
- Suhendar, A. H., Rohmawati, A. A., and Prasetyowati, S. S. (2024). Performance of CART Time-Based Feature Expansion in Dengue Classification Index Rate. *Sinkron*, 9(1). <https://doi.org/10.33395/sinkron.v9i1.13023>.
- Tandjungbulu, Y. F., Virgiawan, A. R., Widarti, W., and Suparmin, F. R. (2025). Tinjauan Hasil Pemeriksaan NS1 Dan IgG/IgM Dengue Metode Imunokromatografi Terhadap Hasil Pemeriksaan Total Jumlah Dan Indeks Trombosit Pada Penderita Demam Dengue. *Media Kesehatan Politeknik Kesehatan Makassar*, 20(1):216–226. <https://doi.org/10.32382/medkes.v20i1.1439>.
- Watratana, A. F., B, A. P., and Moeis, D. (2020). Implementasi Algoritma Naive Bayes Untuk Memprediksi Tingkat Penyebaran Covid-19 Di Indonesia. *Journal of Applied Computer Science and Technology*, 1(1). <https://doi.org/10.52158/jacost.v1i1.9>.
- Widianawati, E. and Widiyanti, T. (2022). Prediksi Sebaran Kasus DBD Selama Pandemi Covid 19 Di Unit Rawat Inap Rumah Sakit Telogorejo Tahun 2020. *Infokes: Jurnal Ilmiah Rekam Medis dan Informatika Kesehatan*, 12(1). <https://doi.org/10.47701/infokes.v12i1.1333>.
- Yeremia Tiopan Pandapotan Purba, I. T. (2024). Integrasi Algoritma Naive Bayes Dan Website Untuk Deteksi Dini Penyakit DBD Di RSUD. DR. Pirngadi. *Bulletin of Information Technology (BIT)*, 5(1).