

OPTIMASI KLASIFIKASI NAÏVE BAYES BERBASIS PARTICLE SWARM OPTIMIZATION UNTUK PREDIKSI PENYAKIT GINJAL

Andi Arfian^{1*}, Juarni Siregar², Sigit Widawa³, Rahmiliasari Samnufida⁴, Andi Sanjaya⁵

^{1,3,4,5} Program Studi Teknik Informatika, Fakultas Teknologi Informasi, UBSI, Indonesia.

² Program Studi Sistem Informasi, Fakultas Teknologi Informasi, UNIVERSITAS NUSAMANDIRI, Indonesia.

Informasi Artikel:

Dikirim: 24-05-2026; Diterima: 01-07-2026; Diterbitkan: 10-07-2026

Doi : <http://dx.doi.org/10.31602/tji.v17i3.24029>

Abstrak

Penyakit Ginjal Kronis (PGK) adalah suatu keadaan kesehatan yang ditandai dengan penurunan fungsi ginjal yang terjadi secara bertahap dan sering tidak terdeteksi pada tahap awal. Keterlambatan dalam mendeteksi kondisi ini dapat meningkatkan kemungkinan terjadinya komplikasi serius, sehingga penting untuk memiliki metode prediksi yang tepat berdasarkan data medis. Penelitian ini bertujuan untuk menerapkan teknik Data Mining dengan memadukan algoritma Naïve Bayes dan Particle Swarm Optimization (PSO) untuk memprediksi risiko PGK. Dataset yang digunakan terdiri dari data dari 100 pasien yang mencakup 16 variabel klinis, termasuk usia, tekanan darah, densitas urine, kadar albumin, kadar gula, hemoglobin, kadar ureum, kreatinin, serta kadar sodium, potassium, jumlah sel darah putih, jumlah sel darah merah, riwayat hipertensi, dan diabetes. Proses penelitian mencakup penyiapan data awal, pemilihan fitur menggunakan PSO untuk menemukan parameter paling berpengaruh, dan klasifikasi dengan Naïve Bayes. Hasil dari analisis data menunjukkan bahwa pasien yang termasuk dalam kategori PGK positif (label kelas 1) menunjukkan peningkatan signifikan pada kadar ureum dan kreatinin, penurunan pada kadar hemoglobin, serta tingkat hipertensi yang tinggi dibandingkan dengan kategori normal (label kelas 0). Penggunaan metode hibrida ini terbukti efektif dalam mengoptimalkan model prediksi dengan mengurangi fitur redundan, yang menghasilkan tingkat akurasi klasifikasi yang lebih baik dibandingkan metode tradisional. Sistem prediksi ini diharapkan dapat berfungsi sebagai alat bantu yang efisien bagi tenaga medis dalam proses pengambilan keputusan klinis.

Keywords : Penyakit Ginjal Kronis, Data Mining, Naïve Bayes, Particle Swarm Optimization, Seleksi Fitur



This is an open-access article under a Creative Commons Attribution 4.0 International (CC-BY 4.0) License. Copyright ©2026 by authors.

Pendahuluan

Ginjal merupakan organ vital yang berperan krusial dalam menjaga homeostasis cairan tubuh, menyaring limbah metabolisme, dan mengatur tekanan darah. Penyakit Ginjal Kronis (PGK) didefinisikan sebagai kelainan struktur atau fungsi ginjal yang berlangsung selama lebih dari tiga bulan [1][2]. Data Global Burden of Disease menunjukkan bahwa prevalensi PGK terus

meningkat secara global dan telah menjadi salah satu penyebab utama morbiditas dan mortalitas. Kondisi ini seringkali asimtomatik pada tahap awal, sehingga banyak pasien baru menyadari kondisinya saat penyakit sudah memasuki stadium lanjut atau gagal ginjal terminal. Keterlambatan diagnosis ini berdampak serius pada peningkatan biaya pengobatan dan penurunan kualitas hidup pasien [3].

Di era digital, pemanfaatan teknologi informasi dalam bidang kesehatan telah berkembang pesat. Teknik Data Mining menjadi salah satu pendekatan andalan untuk mengekstraksi pengetahuan dari repositori data medis berskala besar. Melalui pendekatan ini, pola tersembunyi yang berkaitan dengan diagnosis penyakit dapat diidentifikasi secara otomatis, membantu tenaga medis dalam mengambil keputusan klinis secara lebih cepat dan akurat. Banyak metode klasifikasi yang telah diaplikasikan dalam prediksi penyakit, salah satunya adalah algoritma Naïve Bayes. Algoritma ini dipilih karena kesederhanaannya, efisiensi komputasional, serta kemampuannya memberikan performa kompetitif dalam klasifikasi data medis berbasis probabilitas[4]. Meskipun demikian, Naïve Bayes memiliki keterbatasan ketika dihadapkan pada dataset dengan dimensionalitas tinggi. Dalam dataset PGK, terdapat beragam parameter klinis; tidak semuanya memberikan kontribusi signifikan terhadap kelas target. Keberadaan fitur yang tidak relevan atau redundan dapat memicu overfitting dan menurunkan akurasi model. Oleh karena itu, proses seleksi fitur (feature selection) menjadi esensial untuk memilih subset fitur yang paling informatif[5].

Particle Swarm Optimization (PSO) merupakan algoritma metaheuristik yang terinspirasi dari perilaku sosial kawanan burung. PSO telah banyak diaplikasikan sebagai metode seleksi fitur karena kemampuannya menemukan solusi optimal dalam ruang pencarian yang kompleks. Integrasi PSO dengan algoritma klasifikasi membentuk metode hibrida yang diharapkan dapat meningkatkan performa prediksi secara signifikan[6]. Penelitian sebelumnya oleh Singh (2020) menunjukkan bahwa optimasi fitur mampu meningkatkan akurasi prediksi penyakit jantung. Hal ini menjadi landasan penerapan metode serupa pada kasus Penyakit Ginjal Kronis (PGK)[20]. Berdasarkan latar belakang tersebut, penelitian ini berfokus pada integrasi supervised learning Naïve Bayes dengan optimasi PSO untuk memprediksi PGK berbasis Data Mining, guna menghasilkan model yang akurat sekaligus efisien[7].

Tinjauan Pustaka

Penyakit Ginjal Kronis (PGK) adalah kondisi patologis yang ditandai dengan penurunan kapasitas fungsi ginjal secara progresif dan ireversibel selama beberapa bulan hingga tahun. [8] Organ ginjal memiliki fungsi vital dalam menyaring sisa metabolisme, menjaga keseimbangan cairan, serta memproduksi hormon esensial seperti eritropoietin.[9] Gangguan fungsi ini memicu akumulasi zat beracun uremik dalam darah yang dapat mengancam jiwa [10]. Deteksi dini sangat krusial mengingat intervensi medis yang cepat mampu memperlambat progresivitas penyakit menuju gagal ginjal terminal[11]. Saat ini, sistem rekam medis elektronik menyediakan variabel klinis seperti kreatinin serum, hemoglobin, specific gravity urin, dan tekanan darah yang potensial untuk prediksi dini.[12]

Sementara itu, Data Mining merupakan teknik eksplorasi dan analisis terstruktur pada kumpulan data berskala besar untuk menemukan pola laten.[13] Pada ranah kesehatan, pendekatan ini dimanfaatkan untuk mengoptimalkan keputusan klinis dan memprediksi risiko penyakit, sekaligus memangkas durasi diagnosis konvensional dan menekan human error. Proses ini umumnya mengikuti kerangka CRISP-DM, dari pemahaman data hingga evaluasi model[14].

Supervised learning merupakan pendekatan utama dalam pembelajaran mesin, di mana model dilatih menggunakan dataset berlabel (ground truth) [15]. Dalam prediksi PGK, algoritma memetakan atribut klinis (fitur masukan) ke dalam label diagnostik biner: CKD Positif atau CKD Negatif [19]. Beberapa algoritma klasifikasi medis yang umum diaplikasikan meliputi:

1. Support Vector Machine (SVM): Metode ini bekerja dengan mencari hyperplane optimal yang mampu memisahkan dua kelas data dengan memaksimalkan margin di antara keduanya. Pendekatan ini terbukti sangat efektif, khususnya saat menangani dataset berdimensi tinggi[16].
2. K-Nearest Neighbors (KNN): Algoritma ini melakukan klasifikasi dengan mengukur kedekatan jarak (seperti jarak Euclidean) antara data uji terhadap k-tetangga terdekat di dalam data latih, di mana kelas mayoritas dari tetangga tersebut akan menjadi hasil prediksi [17].
3. Naive Bayes: Metode ini berlandaskan pada prinsip probabilistik Teorema Bayes dengan asumsi kuat bahwa seluruh fitur prediktif bersifat saling bebas (independen) satu sama lain[18].

$$P(H|X) = \frac{P(X|H)P(H)}{P(X)} \quad (1)$$

4. Pohon Keputusan (Decision Tree): Pendekatan ini menstrukturkan data ke dalam format percabangan yang diatur oleh aturan if-then (jika-maka), sehingga sangat intuitif dan mudah diinterpretasikan oleh tenaga medis profesional [23].

Particle Swarm Optimization (PSO) adalah algoritma optimasi heuristik berbasis kecerdasan kolektif, terinspirasi dinamika kawanan burung/ikan. Dalam ruang pencarian multidimensi, setiap kandidat solusi adalah "partikel" yang bergerak dengan kecepatan dinamis, dipengaruhi oleh pencapaian optimal historisnya (pbest) dan kawanan (gbest). Dalam Data Mining, PSO diadopsi untuk Pemilihan Fitur (Feature Selection), yaitu menyeleksi atribut esensial dan mengeliminasi fitur redundan guna mereduksi beban komputasi [24]. Berikut riset terdahulu yang mendukung esensialnya teknik optimasi ini:

1. Studi oleh Ma et al. (2021): Melakukan prediksi CKD menggunakan algoritma Support Vector Machine (SVM) konvensional dan berhasil meraih akurasi sebesar 91,2%. Akan tetapi, keterbatasan krusial dari riset ini adalah pemrosesan sejumlah besar fitur medis secara simultan tanpa seleksi, yang berdampak pada durasi komputasi yang panjang dan risiko overfitting.
2. Studi oleh Al-Obeidat et al. (2022): Mengaplikasikan algoritma K-Nearest Neighbors (KNN) untuk deteksi dini CKD dan memperoleh akurasi sebesar 88,5%. Penelitian tersebut menyoro bahwa penentuan nilai parameter K secara manual (tuning) menjadi faktor pembatas utama yang menghambat pencapaian akurasi yang lebih optimal.
3. Studi oleh Alshamlan & Al-Bakri (2021): Mengintegrasikan Pohon Keputusan dengan PSO untuk klasifikasi penyakit kardiovaskular. Bukti empiris menunjukkan bahwa penerapan PSO sebagai mekanisme pemilihan fitur mampu meningkatkan akurasi dari 84,3% menjadi 94,5%, serta memangkas waktu pelatihan model secara signifikan[19].

Berdasarkan evaluasi literatur tersebut, kesenjangan penelitian (research gap) sangat jelas: penerapan algoritma supervised learning secara mandiri kerap berujung pada kinerja suboptimal akibat noise dan kendala penalaan parameter manual. Oleh karena itu, studi ini mengusulkan integrasi PSO untuk menghasilkan model prediksi CKD yang lebih akurat dan andal. Optimasi pemilihan atribut ini telah terbukti mampu mengerek akurasi algoritma seperti hingga 97,75% berkat presisi bobot atribut.[16]

Metodologi

Subjek penelitian ini adalah data sekunder dari rekam medis pasien penyakit ginjal (Tabel 1). Dataset mencakup 100 sampel pasien (ID P001–P100) dengan status diagnosis terbagi menjadi dua kelas: nilai 1 (positif PGK) dan nilai 0 (negatif/norm). Data yang digunakan adalah data kuantitatif berupa rekam medis terstruktur dari berkas (Tabel.2). Prosedur pelaksanaan penelitian ini dibagi menjadi beberapa tahapan sistematis sebagai berikut:

1. Tahap Pra-proses Data Melakukan pembersihan data, penanganan nilai yang hilang, serta normalisasi data numerik pada variabel klinis pasien.
2. Tahap Optimasi Seleksi Fitur (PSO) Membentuk populasi partikel di mana posisi setiap partikel merepresentasikan kombinasi fitur terpilih menggunakan representasi biner. Partikel bergerak memperbarui kecepatan dan posisinya berdasarkan nilai pBest dan gBest untuk menemukan subset fitur terbaik.
3. Tahap Klasifikasi (Naïve Bayes) Subset fitur optimal hasil seleksi PSO kemudian dimasukkan ke dalam algoritma Naïve Bayes untuk dilakukan proses pembelajaran menggunakan metode pembagian data K-Fold Cross Validation.
4. Tahap Evaluasi Menghitung dan mencatat performa keluaran model berdasarkan matriks pengujian.

Tabel 1. Dataset Penelitian

ID Pasien	age	bp	sg	al	su	rbc	bu	sc	sod	pot	hemo	wbcc	rbcc	htn	dms	class
P001	48	70	1.025	0	0	1	36	1.2	137	4.5	15.4	7800	5.2	0	0	0
P002	55	80	1.02	1	0	0	68	2.8	135	4.8	11.2	9500	4.1	1	0	1
P003	42	60	1.025	0	0	1	25	1.1	140	4	16	7200	5.5	0	0	0
P004	60	90	1.015	2	1	0	110	5.5	130	5.2	9.5	11200	3.5	1	1	1
P005	35	70	1.02	0	0	1	30	1	139	4.2	14.8	6500	5	0	0	0
P006	65	100	1.01	3	2	0	145	7.2	125	6.1	8.4	15600	2.8	1	1	1
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
P100	60	60	1.02	1	0	0	145	7.2	125	6.1	8.4	15600	2.8	1	1	1

Tabel 2. Deskripsi Dataset Penelitian

No	Nama Atribut	Deskripsi	Tipe Data
1	age	Usia pasien	Numerik
2	bp	Tekanan darah	Numerik
3	sg	Berat jenis urin	Numerik
4	al	Kadar albumin dalam urin	Numerik
5	su	Kadar gula dalam urin	Numerik
6	rbc	Sel darah merah	Kategorik
7	bu	Urea darah	Numerik
8	sc	Kreatinin serum	Numerik
9	sod	Kadar natrium	Numerik
10	pot	Kadar kalium	Numerik
11	hemo	Kadar hemoglobin	Numerik
12	wbcc	Jumlah sel darah putih	Numerik
13	rbcc	Jumlah sel darah merah	Numerik

14	htn	Riwayat hipertensi	Kategorik
15	dm	Riwayat diabetes melitus	Kategorik
16	class	Label target klasifikasi	Kategorik

Teknik analisis data dilakukan dengan metode statistik inferensial dan evaluasi performa data mining menggunakan Confusion Matrix. Performa dari model klasifikasi diukur secara kuantitatif melalui tiga rumus metrik utama, yaitu:

$$\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN}) \quad (2)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (3)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (4)$$

Keterangan:

- a) True Positive (TP) : Jumlah data positif yang diprediksi benar sebagai positif.
- b) True Negative (TN) : Jumlah data negatif yang diprediksi benar sebagai negatif.
- c) False Positive (FP) : Jumlah data negatif yang salah diprediksi sebagai data positif.
- d) False Negative (FN): Jumlah data positif yang salah diprediksi sebagai data negatif.

Hasil dari perhitungan ketiga metrik tersebut pada model Naïve Bayes standar akan dianalisis dan dibandingkan secara deskriptif dengan hasil dari model Naïve Bayes berbasis PSO untuk menarik kesimpulan mengenai efektivitas optimasi yang dilakukan. Hasil PenelitianEksperimen dilakukan terhadap dataset rekam medis penyakit ginjal yang bersumber dari Tabel 1. Tahapan pengujian dibagi menjadi dua skenario utama, yaitu pengujian klasifikasi menggunakan algoritma Naïve Bayes standar dengan melibatkan keseluruhan 15 fitur klinis, serta pengujian klasifikasi menggunakan integrasi Naïve Bayes berbasis Particle Swarm Optimization (PSO) untuk menyaring fitur-fitur yang paling optimal.

Hasil

Proses optimasi dengan PSO dijalankan untuk mereduksi dimensi data dengan mengeliminasi atribut yang bersifat redundan atau tidak relevan (noise feature). Untuk memastikan eksperimen ini dapat direproduksi secara akurat, algoritma PSO dikonfigurasi menggunakan beberapa parameter penentu performa, antara lain jumlah partikel (swarm size) ditetapkan sebanyak 30 partikel, dengan batas iterasi maksimum (maximum iteration) sebesar 100 epoch. Selain itu, nilai bobot inersia (inertia weight / w) diatur secara dinamis menggunakan metode linear decreasing dari 0.9 hingga 0.4 untuk menyeimbangkan proses eksplorasi dan eksploitasi global. Parameter koefisien kognitif (c₁) dan koefisien sosial (c₂) masing-masing disetel pada nilai standar baku yaitu 2.0

Dari total 15 fitur klinis awal yang tersedia pada dataset, pergerakan konvergensi partikel PSO berhasil mereduksi dimensi data secara signifikan. Algoritma mengeliminasi fitur-fitur yang tidak berkontribusi positif terhadap nilai fitness dan merekomendasikan subset fitur terbaik yang terdiri dari 7 fitur klinis utama. Hasil reduksi dan pemilihan subset fitur oleh algoritma PSO disajikan secara mendetail pada Tabel 3.


Tabel.3. Hasil Reduksi dan Seleksi Atribut Klinis Penyakit Ginjal

No	Nama Fitur Awal (15 Atribut)	Status Seleksi PSO	Keterangan Atribut Terpilih
1	Age (Usia)	Tereliminasi	Tidak digunakan
2	BP (Blood Pressure)	Tereliminasi	Tidak digunakan
3	SG (Specific Gravity)	Terpilih	Fitur Utama
4	Al (Albumin)	Terpilih	Fitur Utama
5	Su (Sugar)	Tereliminasi	Tidak digunakan
6	Rbc (Red Blood Cells)	Tereliminasi	Tidak digunakan
7	Bu (Blood Urea)	Terpilih	Fitur Utama
8	Sc (Serum Creatinine)	Terpilih	Fitur Utama
9	Sod (Sodium)	Tereliminasi	Tidak digunakan
10	Pot (Potassium)	Tereliminasi	Tidak digunakan
11	Hemo (Hemoglobin)	Terpilih	Fitur Utama
12	Wbcc (White Blood Cell Count)	Tereliminasi	Tidak digunakan
13	Rbcc (Red Blood Cell Count)	Tereliminasi	Tidak digunakan
14	Htn (Hypertension)	Terpilih	Fitur Utama
15	Dm (Diabetes Mellitus)	Terpilih	Fitur Utama

Perbandingan Performa Klasifikasi Setelah mendapatkan subset fitur optimal dari proses evaluasi PSO, dilakukan pengujian klasifikasi menggunakan metode K-Fold Cross Validation (dengan nilai $K=10$) untuk mengukur tingkat akurasi (Accuracy), presisi (Precision), dan sensitivitas (Recall). Pengujian ini membandingkan dua skenario utama, yaitu implementasi algoritma Naïve Bayes standar (menggunakan seluruh 15 fitur) dan Naïve Bayes hibrida (hanya menggunakan 7 fitur hasil optimasi PSO). Perbandingan performa komputasi dan metrik evaluasi antara kedua skenario pengujian tersebut diringkas dan dipaparkan secara mendetail pada Grafik Gambar 1 dan Tabel 4. Perbandingan Performa Klasifikasi Setelah mendapatkan subset fitur optimal dari proses evaluasi PSO, dilakukan pengujian klasifikasi menggunakan metode K-Fold Cross Validation untuk mengukur nilai tingkat akurasi (Accuracy), presisi (Precision), dan sensitivitas (Recall). Perbandingan performa komputasi antara kedua skenario pengujian tersebut diringkas dan dipaparkan secara mendetail pada gambar 1 dan table 4

Tabel.4 Hasil Perbandingan Performa Model

Model	Jumlah Fitur	Accuracy (%)	Precision (%)	Recall (%)
Naïve Bayes	15	85	84.2	86
Naïve Bayes + PSO	7	94	93.1	96.43



Gambar.1 Perbandingan Performa Model Sebelum dan Sesudah Optimasi


Pembahasan

Berdasarkan hasil eksperimen yang tertera pada Tabel 5, model klasifikasi Naïve Bayes standar yang memanfaatkan keseluruhan 15 atribut klinis awal menghasilkan nilai akurasi sebesar 85,00%, dengan Precision 84,20% dan Recall 86,00%.

Tabel 5. Hasil Penelitian

Model	Jumlah Fitur	Accuracy (%)	Precision (%)	Recall (%)
Naïve Bayes	15	85	84.2	86
Naïve Bayes + PSO	7	94	93.1	96.43

Hasil ini mengindikasikan bahwa algoritma Naïve Bayes pada dasarnya sudah memiliki performa dasar yang cukup tangguh dalam mengenali pola rekam medis pasien, meskipun bekerja di bawah asumsi independensi fitur yang ketat. Namun, pengujian pada skenario kedua membuktikan bahwa integrasi teknik metaheuristik melalui Particle Swarm Optimization (PSO) mampu mendongkrak performa klasifikasi secara signifikan. Nilai akurasi model meningkat tajam menjadi 94,00% (mengalami kenaikan sebesar 9,00%), yang diikuti oleh lonjakan nilai Precision menjadi 93,10% serta Recall yang menyentuh angka 96,43%. Visualisasi perbandingan peningkatan metrik evaluasi antara kedua model tersebut disajikan pada Gambar 2.



Gambar.2 Perbandingan Performa Naïve Bayes dan Naïve Bayes + PSO

Secara teoretis dan praktis, lonjakan performa ini terjadi karena algoritma PSO berhasil menjalankan fungsinya sebagai instrumen seleksi fitur (feature selection) yang efektif. Dari 15 variabel medis awal, PSO mengeliminasi 8 fitur yang dinilai kurang relevan atau memicu terjadinya multikolinieritas (seperti Age, BP, dan Sugar). Proses optimasi ini hanya menyisakan 7 parameter klinis paling krusial yang memiliki korelasi kuat terhadap keputusan diagnosis, yaitu: berat jenis urin (sg), kadar albumin (al), urea darah (bu), kreatinin serum (sc), hemoglobin (hemo), serta riwayat penyakit penyerta seperti hipertensi (htn) dan diabetes melitus (dm).

Reduksi dimensi data dari 15 fitur menjadi 7 fitur utama ini terbukti menyederhanakan arsitektur perhitungan probabilitas pada algoritma Naïve Bayes. Dengan hilangnya informasi yang bersifat semu (noise), model Naïve Bayes dapat bekerja dengan lebih fokus pada atribut klinis yang berbobot tinggi. Hasil penelitian ini secara empiris menegaskan bahwa kombinasi supervised learning dengan swarm intelligence mampu menghasilkan model prediktif yang tidak hanya lebih ringan secara beban komputasi, melainkan juga jauh lebih akurat dan dapat diandalkan untuk membantu diagnosis klinis Penyakit Ginjal Kronis (PGK).

Kesimpulan

Berdasarkan hasil pengujian dan analisis yang telah dilakukan, dapat disimpulkan bahwa penerapan metode hibrida Naïve Bayes berbasis Particle Swarm Optimization (PSO) terbukti efektif dalam meningkatkan akurasi prediksi Penyakit Ginjal Kronis (PGK). Implementasi PSO sebagai teknik seleksi fitur mampu mereduksi dimensi data secara signifikan dengan memangkas jumlah atribut klinis dari 15 variabel menjadi 7 fitur utama yang paling relevan, sekaligus mengeliminasi informasi semu (noise). Meskipun model Naïve Bayes standar tanpa optimasi sudah menunjukkan performa dasar yang cukup baik dengan akurasi 85,00%, Precision 84,20%, dan Recall 86,00%, integrasi PSO berhasil mendongkrak performa model secara dramatis. Pengujian skenario hibrida menghasilkan lonjakan nilai akurasi menjadi 94,00%, Precision menjadi 93,10%, dan Recall mencapai angka 96,43%. Dengan demikian, kombinasi algoritma Naïve Bayes dan PSO merupakan pendekatan yang jauh lebih optimal, akurat, dan efisien untuk digunakan sebagai alat bantu komputasi bagi tenaga medis dalam proses pengambilan keputusan klinis dan diagnosis dini penyakit ginjal kronis.

Daftar Pustaka

- [1] D. A. Putri, D. A. Kristiyanti, E. Indrayuni, A. Nurhadi, and D. R. Hadinata, "Comparison of Naive Bayes Algorithm and Support Vector Machine using PSO Feature Selection for Sentiment Analysis on E-Wallet Review," *J. Phys. Conf. Ser.*, vol. 1641, no. 1, 2020, doi: 10.1088/1742-6596/1641/1/012085.
- [2] Ermanto and N. Surojudin, "Perbandingan Metode Klasifikasi dalam Memprediksi Penyakit Ginjal Kronis," *J. Inform. Ekon. Bisnis*, vol. 7, pp. 715–723, 2025, doi: 10.37034/infv7i3.1263.
- [3] M. Rizal, M. Z. Syahaf, S. R. Priyambodo, and Y. Rhamdani, "Optimasi Algoritma Naïve Bayes Menggunakan Forward Selection Untuk Klasifikasi Penyakit Ginjal Kronis," *Naratif J. Nas. Riset, Apl. dan Tek. Inform.*, vol. 5, no. 1, pp. 71–80, 2023, doi: 10.53580/naratif.v5i1.200.
- [4] M. Badawy *et al.*, "AI-driven prognostics in pediatric bone marrow transplantation: a CAD approach with Bayesian and PSO optimization," *BMC Med. Inform. Decis. Mak.*, vol. 25, no. 1, pp. 1–22, 2025, doi: 10.1186/s12911-

- 025-03133-1.
- [5] Y. Kelpin and K. Ardila, "Analysis of User Satisfaction Level Of E-Pkh Application Using End User Computing Satisfaction (EUCS) Method," *Adpebi Sci. Ser.*, pp. 1–8, 2022, [Online]. Available: <http://series.adpebi.com/index.php/AICMEST/article/view/63>
 - [6] Y. Chen and J. Li, "Computer-Aided Recognition Algorithm for Students' Mental Health Problems using K-means Clustering," *Comput. Aided. Des. Appl.*, vol. 21, no. S9, pp. 19–37, 2024, doi: 10.14733/cadaps.2024.S9.19-37.
 - [7] A. Mustopa, Hermanto, Anna, E. B. Pratama, A. Hendini, and D. Risdiansyah, "Analysis of user reviews for the pedulilindungi application on google play using the support vector machine and naive bayes algorithm based on particle swarm optimization," *2020 5th Int. Conf. Informatics Comput. ICIC 2020*, vol. 19, 2020, doi: 10.1109/ICIC50835.2020.9288655.
 - [8] K. S. Arlandy *et al.*, "Mengoptimalkan Kinerja Naïve Bayes Pada Ancaman Modern Dengan Menggunakan PCA Pada Data Intrusion Detection System (IDS)," vol. 8, no. 1, 2025.
 - [9] F. Akbar *et al.*, "Penerapan Algoritma Naïve Bayes Untuk Mengetahui Pasien Penyakit Gagal Jantung," *J. Inform. Dan Rekayasa Komputer(JAKAKOM)*, vol. 2, no. 2, pp. 263–266, 2022, doi: 10.33998/jakakom.2022.2.2.117.
 - [10] A. F. B. Watratan, A. Puspita, and D. Moeis, "Implementasi Algoritma Naive Bayes Untuk Memprediksi Tingkat Penyebaran Covid-19 Di Indonesia," *J. Appl. Comput. Sci. Technol. (Jacost)*, vol. 1, no. 1, pp. 7–14, 2020.
 - [11] A. N. Am, M. Nurkholifah, and F. K. Oktorina, "Analisa Penyakit Jantung Menggunakan Algoritma Naïve Bayes," *J. Syst. Comput. Eng.*, vol. 4, no. 1, pp. 26–36, 2023, doi: 10.47650/jsce.v4i1.671.
 - [12] S. Muharni, S. Andriyanto, and S. Supardi, "Optimization of the Naïve Bayes Algorithm Using Particle Swarm Optimization (PSO) for Predicting Heart Disease Symptoms," *Prism. Sains J. Pengkaj. Ilmu dan Pembelajaran Mat. dan IPA IKIP Mataram*, vol. 13, no. 3, pp. 582–601, 2025, doi: 10.33394/j-ps.v13i3.15573.
 - [13] Andi arfian, "Integrasi model neural network dengan svm dan knn untuk deteksi dini penyakit jantung pada penderita hipertensi," vol. 16, no. 1, pp. 104–109, 2025.
 - [14] A. P. Fadillah and B. Hardiyana, "Penerapan Naïve Bayes Classifier Untuk Pemilihan Konsentrasi Mata Kuliah," *J. Teknol. dan Inf.*, vol. 8, no. 2, 2018, doi: 10.34010/jati.v8i2.1039.
 - [15] V. Beltrán *et al.*, "A rural teledentistry care experience: a geriatric approach to assessing oral health status and treatment needs in older adults from a Mapuche community in Chile," *Front. Public Heal.*, vol. 12, no. June, pp. 1–15, 2024, doi: 10.3389/fpubh.2024.1356622.
 - [16] I. Zulfahmi, H. Syahputra, S. I. Naibaho, M. A. Maulana, and E. P. Sinaga, "Perbandingan Algoritma Support Vector Machine (SVM) dan Decision Tree Untuk Deteksi Tingkat Depresi Mahasiswa," *Bina Insa. Ict J.*, vol. 10, no. 1, p. 52, 2023, doi: 10.51211/biict.v10i1.2304.
 - [17] G. I. Rusydy, B. Irawan, and C. Setianingsih, "Sistem Deteksi Gelombang Laut Dengan Algoritma Knn (K-Nearest Neighbor) Berbasis Android Android Based Sea Wave Detection System Using Knn (K-Nearest Neighbor) Algorithm," *e-Proceeding Eng.*, vol. 7, no. 1, pp. 1698–1702, 2020.

- [18] R. A. S. Prayoga, R. Basatha, M. S. Akbar, E. A. Elfaiz, and C. D. Putra, "Application of Naïve Bayes Method for Student Performance Classification," *Sistemasi*, vol. 14, no. 2, p. 536, 2025, doi: 10.32520/stmsi.v14i2.4852.
- [19] R. Hidayat, Y. S. Sy, T. Sujana, M. Husnah, and H. T. Saputra, "Implementasi Machine Learning Untuk Prediksi Penyakit Jantung Menggunakan Algoritma Support Vector Machine," vol. 5, no. 2, pp. 161–168, 2024.
- [20] A. Singh, R. Kumar, and G. Kumar, "Prediction of heart disease using optimized feature selection and machine learning," *International Journal of Recent Technology and Engineering (IJRTE)*, vol. 8, no. 6, pp. 2955-2962, 2020.