

Perbandingan Metode Klasifikasi dalam Memprediksi Penyakit Ginjal Kronis

Ermanto^{1✉}, Nurhadi Surojudin²

^{1,2}Universitas Pelita Bangsa

ermanto@pelitabangsa.ac.id

Abstract

Chronic Kidney Disease (CKD) is a global health issue with an increasing prevalence that poses a significant economic burden on healthcare systems. Early detection of CKD is crucial to provide proper treatment before the disease progresses to end-stage renal failure. With technological advancements, machine learning methods have been widely utilized to support medical diagnosis with greater speed and accuracy. This study aims to compare the performance of two popular classification algorithms, Decision Tree C4.5 and Naïve Bayes, in predicting CKD using a public dataset from the UCI Machine Learning Repository consisting of 400 patient records with 24 clinical attributes. The research process involved systematic preprocessing steps, including handling missing values, transforming categorical data into numerical form, and selecting relevant attributes. Model evaluation was conducted using 10-Fold Cross Validation with performance metrics such as accuracy, precision, recall, Area Under the Curve (AUC), and statistical T-Test. The results show that Decision Tree C4.5 achieved an accuracy of 93.00%, precision of 84.27%, recall of 100%, and an AUC of 0.944, while Naïve Bayes obtained an accuracy of 93.50%, precision of 85.23%, recall of 100%, and an AUC of 0.948. Although the performance differences between both algorithms are relatively small and statistically insignificant, Naïve Bayes demonstrated slightly better results in terms of accuracy and AUC, while Decision Tree C4.5 offers advantages in interpretability through its classification rules. In conclusion, both algorithms are effective for early CKD diagnosis, and the choice may depend on practical needs, whether emphasizing interpretability or computational efficiency. This study contributes to the development of more accurate and efficient clinical decision support systems for improving healthcare services in CKD management.


Keywords: Chronic Kidney, Decision Tree C4.5, Naïve Bayes, ROC Curve, RapidMiner

Abstrak

Penyakit ginjal kronis (Chronic Kidney Disease/CKD) merupakan masalah kesehatan global dengan prevalensi yang terus meningkat dan menimbulkan beban ekonomi besar pada layanan kesehatan. Deteksi dini CKD sangat penting agar pasien dapat memperoleh penanganan tepat sebelum berkembang menjadi gagal ginjal stadium akhir. Seiring kemajuan teknologi, metode machine learning mulai dimanfaatkan untuk membantu diagnosis secara cepat dan akurat. Penelitian ini bertujuan membandingkan kinerja dua algoritma klasifikasi populer, yaitu Decision Tree C4.5 dan Naïve Bayes, dalam memprediksi penyakit ginjal kronis menggunakan dataset publik dari UCI Machine Learning Repository yang berisi 400 data pasien dengan 24 atribut klinis. Proses penelitian dilakukan melalui tahapan preprocessing, meliputi penanganan missing value, transformasi data ke bentuk numerik, dan seleksi atribut. Evaluasi model dilakukan menggunakan metode 10-Fold Cross Validation dengan metrik akurasi, presisi, recall, AUC (Area Under Curve), serta uji statistik T-Test. Hasil penelitian menunjukkan bahwa Decision Tree C4.5 mencapai akurasi 93,00%, presisi 84,27%, recall 100%, dan AUC 0,944, sedangkan Naïve Bayes memperoleh akurasi 93,50%, presisi 85,23%, recall 100%, dan AUC 0,948. Meskipun perbedaan performa kedua algoritma relatif kecil dan tidak signifikan secara statistik, Naïve Bayes terbukti lebih unggul dalam hal akurasi dan AUC, sementara Decision Tree C4.5 memiliki kelebihan pada interpretabilitas aturan klasifikasi. Kesimpulannya, kedua algoritma sama-sama efektif digunakan untuk diagnosis dini CKD, dengan pemilihan metode dapat disesuaikan berdasarkan kebutuhan praktis. Penelitian ini diharapkan berkontribusi pada pengembangan sistem pendukung keputusan medis yang lebih akurat, efisien, dan bermanfaat bagi peningkatan layanan kesehatan.

Kata kunci: Ginjal Kronis, *Decision Tree C4.5*, *Naïve Bayes*, *ROC Curve*, *RapidMiner*

INFEB is licensed under a Creative Commons 4.0 International License.



1. Pendahuluan

Penyakit ginjal kronis [1] (Chronic Kidney Disease/CKD) merupakan salah satu masalah kesehatan masyarakat global dengan tingkat prevalensi yang terus meningkat dari tahun ke tahun. CKD [2] ditandai dengan penurunan fungsi ginjal yang berlangsung secara progresif dan bersifat permanen, sehingga jika tidak ditangani sejak dini dapat berujung pada gagal ginjal stadium akhir. Menurut laporan World Health Organization (WHO), CKD termasuk


dalam sepuluh besar penyebab kematian di dunia, terutama di negara-negara dengan pendapatan tinggi [3]. Di Indonesia, penyakit ginjal menempati posisi kedua setelah penyakit jantung dalam hal pembiayaan kesehatan yang ditanggung oleh BPJS [4] dengan pengeluaran mencapai triliunan rupiah setiap tahunnya. Tingginya beban biaya tersebut disebabkan oleh lamanya perawatan yang harus dijalani pasien, baik melalui dialisis maupun transplantasi ginjal. Oleh karena itu, deteksi dini CKD menjadi sangat penting agar pasien dapat memperoleh penanganan medis yang

tepat sebelum penyakit berkembang menjadi lebih parah. Seiring dengan kemajuan teknologi, metode komputasi cerdas seperti machine learning kini mulai dimanfaatkan untuk membantu tenaga medis dalam melakukan diagnosis secara cepat, akurat, dan efisien. Dalam beberapa tahun terakhir, perkembangan teknologi komputasi telah membuka peluang baru dalam bidang kesehatan, khususnya melalui penerapan *machine learning*. Metode ini mampu membantu dokter dalam diagnosis dini penyakit dengan memanfaatkan data pasien yang besar dan kompleks. Teknik klasifikasi berbasis *machine learning* telah banyak digunakan dalam mendiagnosis berbagai penyakit maupun menentukan tindakan perawatan [5]. Berbagai algoritma seperti *Naïve Bayes*, *Support Vector Machine (SVM)*, *Artificial Neural Network (ANN)*, *Logistic Regression*, *K-Nearest Neighbor (KNN)*, dan *Decision Tree* telah digunakan dalam pengklasifikasian CKD dengan tingkat akurasi yang bervariasi [6].

Berbagai penelitian telah dilakukan dengan memanfaatkan algoritma [7]. untuk prediksi dan diagnosis penyakit ginjal. Algoritma klasifikasi seperti *Naïve Bayes* [8] [9], *K-Nearest Neighbor (KNN)* [10], *Logistic Regression*, dan *Support Vector Machine (SVM)* [11], telah diaplikasikan pada dataset medis dengan tingkat akurasi yang beragam. Namun, hasil dari penelitian sebelumnya menunjukkan bahwa performa suatu algoritma sangat bergantung pada kualitas dataset, teknik preprocessing yang digunakan, serta metode evaluasi yang diterapkan. Beberapa studi hanya menguji satu algoritma tanpa melakukan perbandingan yang mendalam, sementara sebagian lainnya tidak menjelaskan secara detail tahap penanganan missing value atau transformasi data yang dapat memengaruhi hasil akhir. Kondisi ini menimbulkan kesenjangan penelitian (research gap) mengenai algoritma mana yang paling tepat dan konsisten digunakan untuk diagnosis dini CKD [12]. Selain itu, sebagian besar penelitian hanya berfokus pada akurasi semata tanpa memperhatikan metrik evaluasi lain seperti presisi, recall [13] dan Area Under Curve (AUC) [14] yang sebenarnya lebih penting dalam konteks medis karena berhubungan langsung dengan minimisasi kesalahan diagnosis [15]. Oleh karena itu, penelitian ini dilakukan untuk membandingkan secara langsung kinerja algoritma *Decision Tree C4.5* dan *Naïve Bayes* dalam mengklasifikasikan penyakit ginjal kronis berdasarkan dataset publik dari UCI Machine Learning Repository. Kebaruan penelitian ini adalah menghadirkan analisis komparatif dengan pendekatan evaluasi komprehensif menggunakan *confusion matrix*, *ROC curve*, dan *T-Test* [16], sehingga hasil penelitian dapat memberikan gambaran yang lebih objektif mengenai keunggulan masing-masing algoritma. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi akademis sekaligus praktis dalam pengembangan sistem pendukung keputusan medis untuk diagnosis dini CKD [17].

Berdasarkan permasalahan tersebut, penelitian ini dilakukan dengan tujuan membandingkan secara langsung performa algoritma *Decision Tree C4.5* [18] dan *Naïve Bayes* [19] dalam memprediksi penyakit ginjal kronis menggunakan dataset publik dari UCI Machine Learning Repository [20] yang berisi 400 data pasien. Proses penelitian dilakukan melalui tahapan preprocessing yang sistematis [21], mencakup penanganan missing value dengan metode substitusi serta transformasi atribut ke bentuk numerik agar sesuai dengan kebutuhan pemodelan. Model kemudian dievaluasi menggunakan metode 10-Fold Cross Validation untuk memastikan tingkat generalisasi yang lebih baik, dengan metrik evaluasi berupa confusion matrix, ROC curve, dan uji statistik T-Test. Kebaruan dari penelitian ini terletak pada perbandingan dua algoritma populer dengan pendekatan evaluasi yang komprehensif, sehingga menghasilkan analisis yang lebih objektif mengenai keunggulan masing-masing metode.

2. Metode Penelitian



Gambar 1. Tahapan Penelitian

Gambar 1 menunjukkan sebuah diagram alir (flowchart) proses penelitian klasifikasi penyakit Chronic Kidney Disease (CKD) menggunakan dataset dari UCI. Proses dimulai dari tahap pengumpulan data, yaitu mengambil dataset CKD dari UCI Machine Learning Repository. Selanjutnya dilakukan preprocessing data yang mencakup penanganan missing value, transformasi data, dan pemilihan data yang relevan untuk dianalisis. Setelah data siap, dilakukan pembagian data dengan metode 10-Fold Cross Validation untuk memastikan hasil pemodelan lebih valid dan tidak bias. Tahap berikutnya adalah pemodelan menggunakan algoritma *Decision Tree C4.5* dan *Naïve Bayes* untuk melakukan klasifikasi. Model yang dihasilkan kemudian dievaluasi melalui beberapa metode, yaitu confusion matrix, ROC Curve (AUC), dan uji statistik T-Test guna mengukur performa serta signifikansi model. Setelah evaluasi selesai, dilakukan analisis hasil untuk menarik kesimpulan penelitian, sebelum akhirnya proses diakhiri dengan tahap selesai.

Penelitian ini menggunakan pendekatan kuantitatif

dengan metode klasifikasi untuk menganalisis data penyakit ginjal kronis (*Chronic Kidney Disease/CKD*). Dataset yang digunakan bersumber dari UCI Machine Learning. Objek penelitian difokuskan pada pemodelan prediksi CKD menggunakan dua algoritma klasifikasi, yaitu *Decision Tree C4.5* dan *Naïve Bayes*. Metode pengumpulan data dibagi menjadi dua sumber data yaitu data primer dan data sekunder. Data primer yaitu data yang dikumpulkan dari sumbernya langsung, sedangkan data sekunder yaitu data yang dikumpulkan dari penelitian sebelumnya. Sumber data yang digunakan pada penelitian adalah data sekunder yang berasal dari <https://archive.ics.uci.edu/dataset/336/chronic+kidney+disease> yaitu CKD_Input (*Chronic Kidney Disease*) dengan jumlah data sebanyak 400 data dengan 24 atribut dan 1 class yang sempelnya terdapat didalam Tabel 1.

Tabel 1. Sample Datasate

Tabel 1 merupakan sumber data berisi karakteristik klinis, hasil laboratorium, serta status pasien terkait Chronic Kidney Disease (CKD) yang digunakan sebagai dasar analisis penelitian. Selanjutnya Replace Missing Values pada Tabel 2.

Tabel 2. Replace Missing Values

No	Atribut	Jumlah Missing Value
1	Age	9
2	Blood Pressure (BP)	12
3	Specific Gravity (SG)	47
4	Albumin (AL)	46
5	Sugar (SU)	49
6	Red Blood Cells (RBC)	152
7	Pus Cell (PC)	65
8	Pus Cell Clumps (PCC)	4
9	Bacteria (BA)	4
10	Blood Glucose Random (BGR)	44
11	Blood Urea (BU)	19

Tabel 2 merupakan distribusi jumlah data hilang (missing values) pada setiap atribut dalam dataset Chronic Kidney Disease (CKD) yang perlu ditangani sebelum proses analisis lebih lanjut. Selanjutnya transformation data pada Tabel 3.

Tabel 3. Transformation Data

No	Atribut	Tingkat	Tranformasi	Type
1	Age	<18	0	Polinomial
		18-50	1	
		>50	2	
2	BP	<80	0	Polinomial
		80-120	1	
		>120	2	
		1005	0	
		1010	1	
3	SG	1015	2	Polinomial
		1020	3	
		1025	4	
		0	0	
		1	1	
4	AL	2	2	Polinomial
		3	3	
		4	4	
		5	5	
		0	0	
5	SU	1	1	Polinomial
		2	2	
		3	3	
		4	4	
		5	5	
6	RBC	Abnormal	0	Binominal
		Normal	1	
7	PC	Abnormal	0	Binominal
		Normal	1	
8	PCC	Present	0	Binominal
		Notpresent	1	
9	BA	Present	0	Binominal
		Notpresent	1	
10	BGR	70-150	1	Binominal
		>150	0	
11	BU	5-23	1	Binominal
		>23	0	
		<0,5	0	
12	SC	0,5-1,2	1	Polinomial
		>1,2	2	
		<135	0	
13	SOD	135-145	1	Polinomial
		>145	2	
		<3,5	0	
14	POT	3,5-5	1	Polinomial
		>5	2	
		<12	0	
15	HEMO	12-17	1	Polinomial
		>17	2	
		<37	0	
16	PCV	37-48	1	Polinomial
		>48	2	
		<4000	0	
17	WBCC	4000-12000	1	Polinomial
		>12000	2	
		<4,1	0	
18	RBCC	4,1-6	1	Polinomial
		>6	2	
		Yes	0	
19	HTN	No	1	Binominal
		Yes	0	
20	DM	No	1	Binominal
		Yes	0	
21	CAD	No	1	Binominal
		Yes	0	
22	APPET	Poor	0	Binominal
		Good	1	
23	PE	Yes	0	Binominal
		No	1	
24	ANE	Yes	0	Binominal
		No	1	
25	Class	CKD	CKD	Binominal
		NOTCKD	NOTCKD	

Tabel 3 merupakan skema transformasi data pada setiap atribut dalam dataset Chronic Kidney Disease (CKD) yang mengubah nilai asli menjadi bentuk

numerik (polinomial atau binomial) agar dapat digunakan dalam proses analisis dan pemodelan. Selanjutnya selection data pada Tabel 4.

Tabel 4. Selection Data

No.	Atribut	Keterangan
1	AGE	Umur
2	BP	Tekanan Darah (<i>Blood Pressure</i>)
3	SG	Spesifik Graffiti Urin (<i>Specific Gravity</i>)
4	AL	Albumin
5	SU	Gula Darah (<i>Sugar</i>)
6	RBC	Sel Darah Merah (<i>Red Blood Cells</i>)
7	PC	Sel Darah (<i>Pus Cell</i>)
8	PCC	Gumpalan Sel Darah (<i>Pus Cell Clumps</i>)
9	BA	Bakteri (<i>Bacteria</i>)
10	BGR	Glukosa Darah Acak (<i>Blood Glucose Random</i>)
11	BU	Urea Darah (<i>Blood Urea</i>)
12	SC	Kreatinin (<i>Serum Creatinine</i>)
13	SOD	Natrium (<i>Sodium</i>)
14	POT	Kalium (<i>Potassium</i>)
15	HEMO	Hemoglobin
16	PCV	Banyaknya Sel Darah Merah Per Liter (<i>Packed Cell Volume</i>)
17	WBCC	Jumlah Sel Darah Putih (<i>White Blood Cell Count</i>)
18	RBCC	Jumlah Sel Darah Merah (<i>Red Blood Cell Count</i>)
19	HTN	Tekanan Darah Tinggi (<i>Hypertension</i>)
20	DM	<i>Diabetes Mellitus</i>
21	CAD	Penyakit Arteri Koroner (<i>Coronary Artery Disease</i>)
22	APPET	Nafsu Makan (<i>Appetite</i>)
23	PE	Pembengkakan (<i>Pedal Edema</i>)
24	ANE	Kurang Darah (<i>Anemia</i>)
25	CLASS	Kurang Darah (<i>Anemia</i>)

Tabel 4 merupakan daftar atribut yang terpilih beserta keterangan masing-masing pada dataset Chronic Kidney Disease (CKD) yang digunakan dalam penelitian setelah melalui proses seleksi data. Berikut tampilan dari aplikasi RapidMiner, dimana *Hypertensi* berpengaruh cukup besar dalam menentukan keputusan CKD atau NOTCKD pada Gambar 2.

Attribute	rbc	pc	hgr	htn	dm	appet	pe	ane	class
rbc	1	0.377	0.130	-0.141	-0.146	0.101	0.180	0.100	-0.283
pc	0.377	1	0.250	-0.282	-0.281	0.275	0.350	0.281	-0.375
hgr	0.130	0.250	1	-0.434	-0.557	0.279	0.181	0.113	-0.447
htn	-0.141	-0.282	-0.434	1	0.906	-0.345	-0.371	-0.348	0.589
dm	-0.146	-0.281	-0.557	0.906	1	-0.325	-0.308	-0.184	0.059
appet	0.101	0.275	0.279	-0.345	-0.325	1	0.417	0.255	-0.383
pe	0.180	0.350	0.181	-0.371	-0.308	0.417	1	0.287	-0.375
ane	0.100	0.281	0.113	-0.348	-0.184	0.255	0.287	1	-0.325
class	-0.283	-0.375	-0.447	0.589	0.059	-0.383	-0.375	-0.325	1

Gambar 2. RapidMiner Selection Data

Pada setiap iterasi, sembilan subset berfungsi sebagai *training set* (warna biru), sementara satu subset berfungsi sebagai *testing set* (warna jingga). Proses ini diulang sebanyak sepuluh kali sehingga setiap subset berkesempatan menjadi *testing set*. Hasil evaluasi model diperoleh dari rata-rata performa di seluruh iterasi, sehingga memberikan estimasi yang lebih stabil dan mengurangi risiko *overfitting*. Selanjutnya gambar 3. menunjukkan proses validasi silang dengan membagi dataset ke dalam 10 subset (fold).



Gambar 3. Ilustrasi 10-Fold Cross Validation

Pada penelitian ini dilakukan pemodelan dengan menggunakan algoritma Decision Tree C4.5 dan Naïve Bayes untuk melakukan prediksi dini terhadap penyakit ginjal kronis. Tahapan pemodelan dimulai dengan Choosing the Appropriate Data Mining Task, yaitu menentukan jenis data mining yang digunakan, di mana dalam penelitian ini dipilih teknik klasifikasi. Selanjutnya adalah Choosing the Data Mining Algorithm, yakni menentukan algoritma yang digunakan dalam proses klasifikasi, yaitu Decision Tree C4.5 dan Naïve Bayes. Setelah itu, pada tahap Employing the Data Mining Algorithm, data yang telah dipersiapkan diolah menggunakan algoritma yang dipilih dengan bantuan aplikasi RapidMiner. Proses berikutnya adalah Evaluation, di mana hasil pemodelan dievaluasi melalui perhitungan akurasi dan analisis confusion matrix untuk mengetahui performa dari kedua algoritma tersebut.

Tahap terakhir adalah Using the Discovered Knowledge, di mana hasil evaluasi yang diperoleh dapat dimanfaatkan untuk melakukan prediksi terhadap data baru dari hasil tes ginjal pasien, sehingga dapat mendukung deteksi dini penyakit ginjal kronis. Confusion matrix adalah suatu metode yang biasanya digunakan untuk melakukan perhitungan akurasi konsep data mining. Confusion matrix digambarkan dengan tabel yang menyatakan jumlah data uji yang benar diklasifikasikan dan jumlah data uji yang salah diklasifikasikan. Selanjutnya confusion matrix pada Tabel 5.

Tabel 5. Confusion Matrix

Correct classification	Classified as	
	Predicted “+”	Predicted “-”
Actual “+”	True Positives	False Negatives
Actual “-”	False negatives	True Negatives

Accuracy adalah jumlah proposal prediksi yang benar. Adapun rumus perhitungan akurasi dapat dilihat dari persamaan (1).

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \times 100\% \quad (1)$$

Precision adalah proposal jumlah dokumen teks yang relevan terkendali diantara semua dokumen teks yang terpilih oleh sistem. Rumus precision dapat dilihat pada persamaan (2).

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (2)$$

Recall adalah proporsi jumlah dokumen teks yang relevan terkendali diantara semua dokumen teks relevan yang ada pada koleksi. Rumus recall dapat dinyatakan dengan (3).

$$Recall = \frac{TP}{TP + FP} \times 100\% \quad (3)$$

Kurva ROC dibagi dalam dua dimensi, dimana tingkat TP diplot pada sumbu Y dan tingkat FP diplot pada sumbu X. tetapi untuk mempresentasikan grafis yang menentukan klasifikasi mana yang lebih baik, digunakan metode yang menghitung luas daerah dibawah kurva ROC yang disebut AUC (area under Curve) yang diartikan sebagai probabilitas. AUC mengukur kinerja diskriminatif dengan memperkirakan probabilitas output dari sampel yang dipilih secara acak dan populasi positif atau negative, semakin besar AUC, semakin kuat klasifikasi yang digunakan. Karena AUC adalah bagian dari daerah unit persegi, nilainya akan selalu antara 0,0 dan 1,0. Selanjutnya ROC Curve pada Tabel 6.

Tabel 6. ROC Curve

Nilai AUC	Klasifikasi
0.90 – 1.00	Sangat Baik
0.80 – 0.90	Baik
0.70 – 0.80	Andil atau Sama
0.60 – 0.70	Rendah
0.50 – 0.60	Gagal

Pada Tabel 6 merupakan Kurva ROC yang menggambarkan hubungan antara *True Positive Rate* (TPR) dan *False Positive Rate* (FPR) dalam mengevaluasi performa model klasifikasi. Luas area di bawah kurva (AUC) menjadi indikator akurasi model. Semakin besar nilai AUC, semakin baik kemampuan model dalam membedakan antara kelas positif dan negatif. Berdasarkan interpretasi nilai AUC, kriteria klasifikasi adalah sebagai berikut: 0,90–1,00 sangat baik, 0,80–0,90 baik, 0,70–0,80 cukup, 0,60–0,70 rendah, dan 0,50–0,60 gagal.

Uji t-test digunakan sebagai dasar pengambilan keputusan dalam penelitian ini. Kriteria yang digunakan adalah sebagai berikut: jika nilai probabilitas signifikansi lebih besar dari 0,05, maka hipotesis ditolak, yang berarti variabel independen tidak berpengaruh signifikan terhadap variabel dependen. Sebaliknya, jika nilai probabilitas signifikansi lebih kecil dari 0,05, maka hipotesis diterima, yang menunjukkan bahwa variabel independen berpengaruh signifikan terhadap variabel dependen.

3. Hasil dan Pembahasan

Pengujian dilakukan menggunakan *10-Fold Cross Validation* dengan variasi nilai K. Hasil evaluasi menunjukkan bahwa akurasi tertinggi dicapai ketika K = 6 hingga K = 10 dengan nilai 93,00%, *precision* 84,27%, dan *recall* 100%. Selain itu, nilai Area Under Curve (AUC) yang diperoleh sebesar $0,944 \pm 0,026$,

yang dikategorikan sangat baik. Hal ini mengindikasikan bahwa algoritma *Decision Tree C4.5* mampu memberikan hasil klasifikasi yang cukup akurat dalam diagnosis penyakit ginjal kronis. Metode *Naïve Bayes* menggunakan pendekatan probabilistik dengan menghitung nilai *prior* dan *likelihood* dari setiap atribut. Hasil perhitungan menunjukkan bahwa *Naïve Bayes* mampu mengklasifikasikan 374 data dengan benar dari total 400 data. Evaluasi menggunakan *10-Fold Cross Validation* menghasilkan akurasi sebesar 93,50%, *precision* 85,23%, dan *recall* 100%. Lebih lanjut, nilai AUC yang diperoleh sebesar $0,948 \pm 0,030$, yang juga termasuk kategori sangat baik. Hal ini menunjukkan bahwa *Naïve Bayes* memiliki performa yang konsisten dan lebih stabil dibandingkan dengan *Decision Tree C4.5* pada dataset penelitian ini disajikan pada Tabel 7.

Tabel 7. Kinerja Algoritma Decision Tree C4.5 dan Naïve Bayes


Algoritma	Akurasi (%)	Precision (%)	Recall (%)	AUC
Decision Tree C4.5	93,00	84,27	100,00	$0,944 \pm 0,026$
Naïve Bayes	93,50	85,23	100,00	$0,948 \pm 0,030$

Tabel 7 merupakan ringkasan perbandingan kinerja algoritma Decision Tree C4.5 dan Naïve Bayes. Tabel ini menampilkan hasil pengujian kedua algoritma dengan menggunakan metode *10-Fold Cross Validation*. Secara umum, kedua algoritma menunjukkan performa yang sangat baik dengan nilai akurasi di atas 93%. *Naïve Bayes* menghasilkan akurasi (93,50%), *precision* (85,23%), dan nilai AUC ($0,948 \pm 0,030$) yang lebih tinggi dibandingkan *Decision Tree C4.5*. Sementara itu, nilai *recall* dari kedua algoritma sama-sama mencapai 100%, yang menunjukkan kemampuan maksimal dalam mendeteksi kasus CKD.

Secara umum, kedua algoritma menunjukkan kinerja yang sangat baik dalam mendiagnosis penyakit ginjal kronis. Namun, terdapat beberapa perbedaan yang dapat dicatat. Dari segi akurasi, algoritma Naïve Bayes menghasilkan nilai sedikit lebih tinggi, yaitu 93,50%, dibandingkan dengan Decision Tree C4.5 yang mencapai 93,00%. Pada aspek *precision* dan *recall*, keduanya memiliki nilai *recall* sempurna (100%), yang menunjukkan bahwa semua kasus CKD berhasil teridentifikasi dengan benar. Meski demikian, Naïve Bayes memiliki nilai *precision* lebih tinggi (85,23%) dibandingkan Decision Tree C4.5 (84,27%), sehingga risiko terjadinya false positive lebih rendah. Selanjutnya, pada pengukuran AUC, Naïve Bayes juga unggul dengan nilai 0,948 dibandingkan 0,944 pada Decision Tree C4.5, yang menandakan kemampuan diskriminatif Naïve Bayes dalam membedakan kelas CKD dan non-CKD sedikit lebih baik.


Dengan demikian, dapat disimpulkan bahwa kedua metode efektif dalam klasifikasi penyakit ginjal kronis, namun *Naïve Bayes* menunjukkan kinerja yang lebih unggul secara konsisten. Hasil ini mendukung temuan

bahwa metode probabilistik sederhana seperti *Naïve Bayes* dapat bekerja sangat baik pada dataset medis yang memiliki distribusi atribut yang jelas. Selanjutnya pengujian decision tree C4.5 pada Gambar 4.



Gambar 4. Proses Pengujian

Gambar 4 menunjukkan bahwa *Decision Tree C4.5* mampu mengklasifikasikan data dengan akurasi sebesar 93,00%, *precision* 84,27%, dan *recall* 100%, serta menghasilkan nilai AUC sebesar $0,944 \pm 0,026$ yang masuk kategori sangat baik. Selanjutnya, nilai performa tersebut diuji menggunakan uji *T-Test* dengan tingkat signifikansi 0,05 untuk memastikan tidak terdapat perbedaan signifikan antara hasil pengujian model dengan algoritma pembandingan. Dengan demikian, dapat disimpulkan bahwa *Decision Tree C4.5* memiliki kinerja yang andal dan layak digunakan dalam klasifikasi diagnosis penyakit ginjal kronis. Selanjutnya proses pengujian algoritma decision tree C4.5 pada Gambar 5.




Gambar 5. Proses Pengujian Algoritma Decision Tree C4.5

Gambar 5 merupakan proses pengujian, algoritma *Decision Tree C4.5* diuji menggunakan metode *10-Fold Cross Validation* yang membagi dataset menjadi sepuluh bagian dengan proporsi 90% sebagai data latih (*training set*) dan 10% sebagai data uji (*testing set*) pada setiap iterasi. Pada tahap *training*, model dibentuk berdasarkan data latih, kemudian diterapkan pada data uji menggunakan operator *Apply Model*. Selanjutnya, hasil prediksi dibandingkan dengan label sebenarnya untuk menghitung nilai kinerja seperti akurasi, *precision*, dan *recall*. Proses ini diulang sepuluh kali hingga seluruh bagian data mendapat giliran sebagai data uji, sehingga hasil evaluasi yang diperoleh lebih stabil dan representatif. Dengan rancangan ini, kinerja algoritma *Decision Tree C4.5* dapat diuji secara menyeluruh serta mengurangi risiko

overfitting pada data penelitian. Selanjutnya import dataset pada Gambar 6.

Gambar 6. Import Dataset

Berdasarkan Gambar 6, proses *import dataset*, terlihat bahwa data penelitian terdiri atas 400 contoh (examples) dengan 1 atribut khusus sebagai *class label* (ckd/notckd) dan 8 atribut prediktor utama, yaitu rbc (sel darah merah), pc (protein), bgr (gula darah acak), htn (hipertensi), dm (diabetes mellitus), appet (nafsu makan), pe (pembengkakan), dan ane (anemia). Setiap atribut telah dikodekan dalam bentuk numerik biner (0 dan 1) agar lebih mudah diproses oleh algoritma klasifikasi. Atribut *class* berfungsi sebagai variabel target yang membedakan kasus CKD dengan non-CKD, sedangkan atribut lainnya digunakan sebagai variabel input untuk membangun model klasifikasi. Proses import dataset ini memastikan bahwa seluruh data tersusun rapi dan siap digunakan dalam tahap pelatihan dan pengujian model algoritma *Decision Tree C4.5* dan *Naïve Bayes*. Selanjutnya pohon keputusan rapidminer pada Gambar 7.



Gambar 7. Pohon Keputusan RapidMiner

Gambar 7 menunjukkan bahwa mayoritas jalur klasifikasi berakhir pada kategori CKD, sedangkan kategori NOTCKD muncul pada kondisi tertentu, khususnya pada pasien tanpa hipertensi, tanpa diabetes, dengan kondisi urin normal, nafsu makan baik, sel darah merah normal, kadar gula darah normal, tidak mengalami pembengkakan, dan anemia. Hal ini mengindikasikan bahwa faktor hipertensi dan diabetes menjadi indikator utama dalam diagnosis CKD, sementara atribut lain berperan sebagai faktor pendukung dalam memperkuat akurasi klasifikasi. Selanjutnya correlation matrix algoritma decision tree C4.5 pada Gambar 8.



Gambar 8. Correlation Matrix Algorithm Decision Tree C4.5

Berdasarkan Gambar 8, *Confusion Matrix* hasil pengujian algoritma *Decision Tree C4.5*, diperoleh akurasi sebesar $93,00\% \pm 3,29\%$. Dari total 250 data pasien dengan kelas CKD, sebanyak 222 kasus berhasil diprediksi dengan benar sebagai CKD, sementara 28 kasus salah diprediksi sebagai NOTCKD. Untuk kelas NOTCKD, seluruh 150 kasus berhasil diklasifikasikan dengan benar tanpa kesalahan. Hasil ini menunjukkan bahwa nilai *precision* untuk kelas CKD mencapai 100%, sedangkan untuk kelas NOTCKD sebesar 84,27%. Sementara itu, nilai *recall* untuk kelas CKD adalah 88,80% dan untuk kelas NOTCKD mencapai 100%. Dengan demikian, algoritma *Decision Tree C4.5* terbukti memiliki kemampuan klasifikasi yang sangat baik, terutama dalam mengidentifikasi pasien tanpa penyakit ginjal kronis, meskipun masih terdapat sejumlah kecil kasus CKD yang salah terklasifikasi. Selanjutnya area under curve algoritma decision C4.5 ditampilkan pada Gambar 9.



Gambar 9. Area Under Curve Algorithm Decision Tree C4.5

Gambar 9 menunjukkan hasil evaluasi kinerja model klasifikasi menggunakan kurva ROC (Receiver Operating Characteristic) dengan nilai AUC (Area Under Curve) sebesar 0.944 dengan margin error ± 0.026 , yang menunjukkan bahwa model memiliki kemampuan prediksi yang sangat baik dalam membedakan kelas positif (notckd). Kurva ROC merah mewakili performa model yang optimal, sementara kurva biru menunjukkan performa model aktual dengan ambang batas yang bervariasi, dimana nilai sensitivitas dan spesifisitas model dapat dilihat dari perubahan ambang batas pada sumbu horizontal. Pada sumbu vertikal, nilai true positive rate (recall) yang tinggi mendekati dengan 1 menunjukkan model memiliki tingkat deteksi yang baik terhadap kelas positif, sementara nilai false positive rate tetap rendah di sebagian besar ambang batas, memperkuat model dalam menghindari kesalahan klasifikasi positif palsu. Secara keseluruhan, grafik ini menggambarkan bahwa model yang diuji efektif dan memiliki kinerja tinggi dalam tugas klasifikasi yang diberikan. Selanjutnya pengujian algoritma naive bayes pada gambar 10.



Gambar 10. Proses Pengujian Algoritma Naive Bayes

Gambar 10 merupakan proses pengujian algoritma Naive Bayes dimulai dengan tahap pelatihan (training), dimana sebuah model dibangun menggunakan data pelatihan yang tersedia. Pada tahap ini, sekitar 90% data digunakan untuk membangun model secara default, dan proses ini dilakukan sebanyak 10 kali untuk memastikan kestabilan hasil. Setelah model selesai dibuat, model tersebut kemudian diterapkan pada pengujian data (testing) yang merupakan 10% data sisanya. Pada tahap pengujian ini, model yang telah dibuat pada tahap pelatihan digunakan untuk memprediksi data uji dan memancarkan kinerja model. Hasil evaluasi kinerja ini kemudian disampaikan ke operator untuk dijelaskan lebih lanjut. Selain itu, metode validasi silang (cross-validation) juga digunakan sebagai parameter proses, dengan pengaturan jumlah lipatan (number offolds) sebanyak 10 dan tipe sampling yang bersifat stratified, sehingga proses validasi ini dapat memberikan estimasi yang lebih akurat terhadap kualitas model yang dihasilkan. Secara keseluruhan, tahapan ini memastikan bahwa model Naive Bayes yang dihasilkan tidak hanya tepat dalam tetapi pelatihan juga handal ketika diterapkan pada data baru. Selanjutnya correlation matrix algoritma naive bayes pada Gambar 11.



Gambar 11. Correlation Matrix Algoritma Naive Bayes

Gambar 11 Merupakan hasil evaluasi kinerja algoritma Naive Bayes pada data yang diuji menunjukkan tingkat akurasi sebesar 93,50% dengan margin kesalahan $\pm 3,76\%$. Matriks korelasi (confusion matriks) menampilkan bahwa dari kelas ckd (penyakit ginjal kronis), sebanyak 224 data berhasil diklasifikasikan dengan benar, sedangkan 26 data diklasifikasikan salah sebagai notckd. Untuk kelas notckd, seluruh 150 data berhasil diklasifikasikan dengan tepat tanpa adanya kesalahan prediksi. Tingkat presisi pada kelas "ckd" mencapai 100%, menandakan bahwa semua prediksi positif untuk kelas ini benar adanya. Sementara itu, presisi kelas "notckd" sebesar 85,23%, yang menunjukkan bahwa sebagian kecil prediksi positif

pada kelas ini mengalami kesalahan. Recall untuk kelas ckd adalah 89,60%, mengindikasikan bahwa sekitar 10% data sebenarnya dari kelas ini tidak terdeteksi dengan benar. Selanjutnya nilai area under curve (AUC) dari algoritma naive bayes pada Gambar 12.



Gambar 12. Area Under Curve Algoritma Naive bayes

Nilai Area Under Curve (AUC) dari algoritma Naive Bayes yang ditampilkan menunjukkan performa yang sangat baik dalam membedakan kelas positif dan negatif. Dengan nilai AUC sebesar 0.948 ± 0.030 , model ini memiliki kemampuan prediksi yang tinggi, dimana nilai mendekati 1 menandakan bahwa algoritma mampu mengklasifikasikan data dengan akurasi yang hampir sempurna. Kurva ROC (Receiver Operating Characteristic) yang ditunjukkan dengan garis merah melengkung naik tajam menuju nilai TPR (True Positive Rate) yang tinggi pada nilai FPR (False Positive Rate) yang rendah memperkuat indikasi bahwa Naive Bayes berhasil dalam meminimalkan kesalahan klasifikasi. Selain itu, adanya jarak pendek (interval kepercayaan) yang relatif sempit juga menunjukkan kestabilan model. Secara keseluruhan, AUC ini mengimplikasikan bahwa Naive Bayes sangat efektif untuk tugas klasifikasi ini dan dapat diandalkan sebagai metode prediksi dalam konteks data yang diuji. Selanjutnya hasil uji T-Test pada Gambar 13.

Parameter	Group A	Group B	Group C
Mean	0.920	0.920	0.935
Standard Deviation	0.014	0.014	0.014
T-Test Result	0.000	0.000	0.000

Gambar 13. Evaluasi T-Test

Berdasarkan hasil uji T-Test pasangan yang ditampilkan pada gambar, terdapat perbandingan nilai rata-rata dan standar deviasi dari tiga kelompok, yaitu A, B, dan C. Kelompok A memiliki nilai rata-rata sebesar 0,920 dengan standar deviasi $\pm 0,014$, kelompok B menunjukkan nilai rata-rata yang sama yaitu 0,920 dengan standar deviasi $\pm 0,014$, sementara kelompok C memiliki nilai rata-rata yang sedikit lebih tinggi, yaitu 0,935 dengan standar deviasi $\pm 0,014$. Dari hasil ini terlihat bahwa nilai kelompok A dan B sangat mirip, sedangkan kelompok C memiliki nilai yang sedikit lebih tinggi. Namun, nilai signifikansi yang tercatat sebesar 0,400 menandakan bahwa perbedaan nilai antar kelompok ketiga tersebut tidak

signifikan secara statistik, sehingga dapat disimpulkan bahwa tidak ada perbedaan yang berarti antara kelompok A, B, dan C dalam konteks pengukuran yang dilakukan.

4. Hasil dan Pembahasan

Penelitian ini membandingkan kinerja algoritma Decision Tree C4.5 dan Naïve Bayes dalam mendiagnosis penyakit ginjal kronis (CKD) menggunakan dataset publik dari UCI Machine Learning Repository. Hasil pengujian menunjukkan bahwa kedua algoritma memiliki performa yang sangat baik dengan tingkat akurasi di atas 93%. Algoritma Naïve Bayes memperoleh akurasi sebesar 93,50%, presisi 85,23%, recall 100%, dan AUC 94,8%, sedangkan algoritma Decision Tree C4.5 menghasilkan akurasi 93,00%, presisi 84,27%, recall 100%, dan AUC 94,4%. Meskipun perbedaan kinerja kedua algoritma relatif kecil dan tidak signifikan secara statistik berdasarkan uji *T-Test*, *Naïve Bayes* terbukti sedikit lebih unggul dalam hal akurasi dan AUC. Di sisi lain, *Decision Tree C4.5* tetap memberikan kelebihan dari sisi interpretabilitas karena menghasilkan aturan klasifikasi yang mudah dipahami. Dengan demikian, kedua algoritma sama-sama layak digunakan dalam mendukung diagnosis dini penyakit ginjal kronis, dan pemilihan metode dapat disesuaikan dengan kebutuhan praktis, apakah lebih menekankan pada transparansi pengambilan keputusan atau kecepatan komputasi. Penelitian ini memberikan kontribusi berupa analisis komparatif yang objektif antara dua algoritma klasifikasi populer, dengan tahapan preprocessing yang sistematis dan evaluasi komprehensif. Hasil penelitian diharapkan dapat menjadi dasar bagi pengembangan sistem pendukung keputusan medis yang lebih akurat, efisien, dan bermanfaat dalam meningkatkan kualitas pelayanan kesehatan khususnya pada diagnosis penyakit ginjal kronis.

Daftar Rujukan

- [1] Prasetya, D. C. T., Pateda, S. M., Ihsan, M., Yusuf, M. N. S., & Antu, Y. (2024). Karakteristik dan Komorbiditas Pasien Gagal Ginjal Kronis. *Jurnal Keperawatan Tropis Papua*, 7(2), 147–154. DOI: <https://doi.org/10.47539/jktp.v7i2.415>.
- [2] Rohmaniah, F. A., & Sunarno, R. D. (2022). Efikasi Diri untuk Meningkatkan Kualitas Hidup Pasien Gagal Ginjal Kronik yang Menjalani Hemodialisis. *Jurnal Ilmu Keperawatan dan Kebidanan*, 13(1), 164–175. DOI: <https://doi.org/10.26751/jikk.v13i1.1305>.
- [3] Gambaran Klaim Pelayanan Dialisis di Rumah Sakit dan Rekomendasi Kebijakan di Level Daerah: Studi Kasus Kota Pematangsiantar. (2024). *Jurnal Ekonomi Kesehatan Indonesia*, 9(1). DOI: <https://doi.org/10.7454/eki.v9i1.1123>.
- [4] Dharmarathne, G., Bogawaththa, M., McAfee, M., Rathnayake, U., & Meddage, D. P. P. (2024). On the Diagnosis of Chronic Kidney Disease Using a Machine Learning-Based Interface with Explainable Artificial Intelligence. *Intelligent Systems with Applications*, 22, 200397. DOI: <https://doi.org/10.1016/j.iswa.2024.200397>.
- [5] Nuresa Qodri, K., Rausan Fikri, M., & Ardi, L. (2025). Analytical Prediction for Chronic Kidney Disease: A Comparison of Machine Learning Methods. *JKTI Jurnal*

- Keilmuan *Teknologi Informasi*, 1(1), 15–22. DOI: <https://doi.org/10.61902/jkti.v1i1.1686> .
- [6] Tanwar, S. (2024). Machine Learning. In *Computational Science and Its Applications* (pp. 13–42). *Apple Academic Press*. DOI: <https://doi.org/10.1201/9781003347484-2> .
- [7] Ikhromr, F. N., Sugiyarto, I., Faddillah, U., & Sudarsono, B. (2023). Implementasi Data Mining untuk Memprediksi Penyakit Diabetes Menggunakan Algoritma Naives Bayes dan K-Nearest Neighbor. *INTECOMS: Journal of Information Technology and Computer Science*, 6(1), 416–428. DOI: <https://doi.org/10.31539/intecom.v6i1.5916> .
- [8] Hana, F. M. (2020). Klasifikasi Penderita Penyakit Diabetes Menggunakan Algoritma Decision Tree C4.5. *Jurnal SISKOM-KB (Sistem Komputer dan Kecerdasan Buatan)*, 4(1), 32–39. DOI: <https://doi.org/10.47970/siskom-kb.v4i1.173> .
- [9] Jupri, M., & Sarno, R. (2018). Taxpayer Compliance Classification Using C4.5, SVM, KNN, Naive Bayes and MLP. *2018 International Conference on Information and Communications Technology (ICOIACT)*, 297–303. DOI: <https://doi.org/10.1109/ICOIACT.2018.8350710> .
- [10] Mahareek, E. A., Desuky, A. S., & El-Zhni, H. A. (2021). Simulated Annealing for SVM Parameters Optimization in Student's Performance Prediction. *Bulletin of Electrical Engineering and Informatics*, 10(3), 1211–1219. DOI: <https://doi.org/10.11591/eei.v10i3.2855> .
- [11] Indrayani, U. D., & Utami, K. D. (2022). Deteksi Dini Penyakit Ginjal Kronis pada Pasien Hipertensi dan Diabetes Melitus di Puskesmas Sronol. *Jurnal ABDIMAS-KU: Jurnal Pengabdian Masyarakat Kedokteran*, 1(1), 34. DOI: <https://doi.org/10.30659/abdmasku.1.1.34-38> .
- [12] Azhari, M., Situmorang, Z., & Rosnelly, R. (2021). Perbandingan Akurasi, Recall, dan Presisi Klasifikasi pada Algoritma C4.5, Random Forest, SVM dan Naive Bayes. *Jurnal Media Informatika Budidarma*, 5(2), 640. DOI: <https://doi.org/10.30865/mib.v5i2.2937> .
- [13] Maskoen, T. T., & Purnama, D. (2018). Area Under the Curve dan Akurasi Cystatin C untuk Diagnosis Acute Kidney Injury pada Pasien Politrauma. *Majalah Kedokteran Bandung*, 50(4), 259–264. DOI: <https://doi.org/10.15395/mkb.v50n4.1342> .
- [14] Dionisius Surya Ernawan. (2022). Tanggung Gugat Dokter Akibat Kesalahan Diagnosa terhadap Pasien dalam Layanan Kesehatan Telemedicine. *Jurist-Diction*, 5(5), 1711–1724. DOI: <https://doi.org/10.20473/jd.v5i5.38434> .
- [15] Qori'ah, A. A., & Fatah, Z. (2024). Implementasi Prediksi Penyakit Ginjal Kronis dengan Menggunakan Metode Decision Tree. *JUSIFOR : Jurnal Sistem Informasi dan Informatika*, 3(2), 180–186. DOI: <https://doi.org/10.70609/jusifor.v3i2.5803> .
- [16] Ali, S. I., Jung, S. W., Bilal, H. S. M., Lee, S.-H., Hussain, J., Afzal, M., Hussain, M., Ali, T., Chung, T., & Lee, S. (2021). Clinical Decision Support System Based on Hybrid Knowledge Modeling: A Case Study of Chronic Kidney Disease-Mineral and Bone Disorder Treatment. *International Journal of Environmental Research and Public Health*, 19(1), 226. DOI: <https://doi.org/10.3390/ijerph19010226> .
- [17] Aulia Fitri, L., & Baita, A. (2025). Optimization of Decision Tree Algorithm for Chronic Kidney Disease Classification Based on Particle Swarm Optimization (PSO). *Journal of Applied Informatics and Computing*, 9(1), 178–186. DOI: <https://doi.org/10.30871/jaic.v9i1.8940> .
- [18] Arifin, T., & Ariesta, D. (2019). Prediksi Penyakit Ginjal Kronis Menggunakan Algoritma Naive Bayes Classifier Berbasis Particle Swarm Optimization. *Jurnal Tekno Insentif*, 13(1), 26–30. DOI: <https://doi.org/10.36787/jti.v13i1.97> .
- [19] Islam, Md. A., Majumder, Md. Z. H., & Hussein, Md. A. (2023). Chronic Kidney Disease Prediction Based on Machine Learning Algorithms. *Journal of Pathology Informatics*, 14, 100189. DOI: <https://doi.org/10.1016/j.jpi.2023.100189> .
- [20] Venkatesan, V. K., Ramakrishna, M. T., Izonin, I., Tkachenko, R., & Havryliuk, M. (2023). Efficient Data Preprocessing with Ensemble Machine Learning Technique for the Early Detection of Chronic Kidney Disease. *Applied Sciences*, 13(5), 2885. DOI: <https://doi.org/10.3390/app13052885> .
- [21] Panggabean, M. S. (2022). Nutrisi Pasien Anak dengan Chronic Kidney Disease (CKD). *Cermin Dunia Kedokteran*, 49(6), 320–326. DOI: <https://doi.org/10.55175/cdk.v49i6.240> .