



Perbandingan Algoritma *Naïve Bayes Classifier* (NBC) dengan *Random Forest* Untuk Klasifikasi Penyakit Ginjal Kronis (PGK)

Caterina Paras Dewi ^{1*}, Jasmir Jasmir ², Willy Riyadi ³, Alya Rafina⁴

¹⁻³ Fakultas Ilmu Komputer, Universitas Dinamika Bangsa, Jambi, Indonesia

Email: parastaehyung@gmail.com^{1*}, ijay_jasmir@yahoo.com², wriyadi@gmail.com³,

alyarafina03@gmail.com⁴

Alamat: Jl. Jend. Sudirman, The Hok, Kec. Jambi Sel., Kota Jambi, Jambi 36138

*Penulis Korespondensi: parastaehyung@gmail.com

Abstract. *Chronic Kidney Disease (CKD) is a heterogeneous disorder that gradually affects the structure and function of the kidneys, is difficult to recover, and causes the body to be unable to maintain metabolism and fail to maintain fluid and electrolyte balance, leading to increased urea levels. Chronic kidney disease data was obtained from Kaggle, in this study a comparison was made between two classification algorithms, namely Naïve Bayes Classifier (NBC) and Random Forest because it is not yet known what algorithm is best in classifying chronic kidney disease (CKD). Both algorithms are evaluated based on performance metrics such as accuracy, precision, recall, and confusion matrix. The results of the evaluation showed that in a dataset of 400 samples, the performance of the Naïve Bayes Classifier (NBC) algorithm obtained an accuracy of 94%, while Random Forest had an accuracy of 93%. Then in the small dataset (158 data), Random Forest got a better accuracy score with 87% compared to the Naïve Bayes Classifier (NBC) of 78%. Based on the results of the evaluation, Random Forest has a more stable performance on small datasets, while Naïve Bayes Classifier (NBC) provides higher performance on larger datasets in the context of chronic kidney disease classification.*

Keywords: *Chronic Kidney Disease; Classification; Machine Learning; Naïve Bayes Classifier; Random Forest.*

Abstrak. Penyakit Ginjal Kronis (PGK) atau dalam bahasa Inggris *Chronic Kidney Disease* (CKD) adalah gangguan heterogen yang secara bertahap memengaruhi struktur dan fungsi ginjal, sulit untuk pulih, dan menyebabkan tubuh tidak dapat menjaga metabolisme serta gagal dalam menjaga keseimbangan cairan dan elektrolit, yang berujung pada peningkatan kadar ureum. Data penyakit ginjal kronis didapat dari Kaggle, dalam penelitian ini dilakukan perbandingan antara dua algoritma klasifikasi, yaitu *Naïve Bayes Classifier* (NBC) dan *Random Forest* karena belum diketahui algoritma apa yang terbaik dalam mengklasifikasi penyakit ginjal kronis (PGK). Kedua algoritma dievaluasi berdasarkan metrik kinerja seperti akurasi, presisi, recall, dan confusion matrix. Hasil evaluasi menunjukkan bahwa pada dataset berukuran 400 data, performa algoritma *Naïve Bayes Classifier* (NBC) mendapatkan akurasi sebesar 94%, sedangkan *Random Forest* memiliki akurasi 93%. Kemudian pada dataset berukuran kecil (158 data), *Random Forest* mendapatkan skor akurasi lebih baik dengan 87% dibandingkan *Naïve Bayes Classifier* (NBC) sebesar 78%. Berdasarkan hasil evaluasi tersebut, *Random Forest* memiliki performa yang lebih stabil pada dataset berukuran kecil, sedangkan *Naïve Bayes Classifier* (NBC) memberikan performa lebih tinggi pada dataset yang lebih besar dalam konteks klasifikasi penyakit ginjal kronis.

Kata kunci: Klasifikasi; Machine Learning; Naïve Bayes Classifier; Penyakit Ginjal Kronis; Random Forest.

1. LATAR BELAKANG

Ginjal yang merupakan salah satu organ sistem kemih berperan menyaring dan mengeluarkan cairan serta sisa metabolisme tubuh, apabila terjadi penurunan fungsi ginjal seiring waktu dapat menyebabkan penyakit ginjal kronis. Penyakit Ginjal Kronis (PGK) merupakan suatu keadaan yang ditandai dengan meningkatnya prevalensi dan insiden gagal ginjal yang menyebabkan tubuh tidak dapat menjaga metabolisme serta keseimbangan cairan yang berujung meningkatnya kadar ureum (Listiana & Muslim, 2017). *World Health Organization* (WHO) pada tahun 2016 mencatat bahwa salah satu dari sepuluh penyebab utama kematian ialah penyakit ginjal dengan beban kesehatan ekstrem di negara-negara

berpendapatan rendah dan menengah melibatkan 188 juta penduduk (Yulianti et al., 2020). Di Indonesia sendiri diperkirakan terdapat 70.000 kasus penderita ginjal kronis dan menempati peringkat kedua dalam pembiayaan terbesar BPJS kesehatan setelah penyakit jantung. Penyakit ginjal stadium akhir memerlukan setidaknya skrining, diagnosis dan manajemen yang sesuai di bawah bimbingan dokter layanan primer (Husna & Maulina, 2018). Banyak individu yang tidak menyadari bahwa mereka memiliki penyakit ginjal kronis mengakibatkan penundaan dalam diagnosa dan akhirnya dapat mengancam nyawa mereka serta rumah sakit membutuhkan manajemen yang baik dalam mengelola data yang sudah ada.

Machine learning merupakan ilmu yang mempelajari tentang algoritma komputer yang bisa mengenali pola-pola di dalam data dengan tujuan untuk mengubah beragam data menjadi suatu tindakan nyata dengan sedikit campur tangan manusia (Ahmad, 2017). Umumnya *machine learning* terbagi menjadi dua kategori yaitu *supervised* dan *unsupervised learning* yang dimana metode *supervised learning* memiliki data yang sudah berlabel dan biasanya digunakan untuk memprediksi atau klasifikasi pada data. Sedangkan untuk *unsupervised* metode ini tidak terdapat label di dalam datanya, Di dalam *supervised learning* ada berbagai macam algoritma khususnya *Naïve Bayes Classifier* (NBC) dan *Random Forest* yang merupakan kumpulan dari *Decision tree*.

Naïve Bayes Classifier (NBC) digunakan untuk mengambil keputusan dari data pelatihan yang tidak terlalu besar. Metode ini efektif dalam mendiagnosa probabilitas gejala dan penyakit berdasarkan pengalaman sebelumnya (A'yuniyah & others, 2022). Sedangkan *Random Forest* merupakan metode yang dikembangkan dari 2 gabungan jenis pohon yaitu *Classification* dan *Regression Tree* (CART) dengan menerapkan *random feature selection* dan teknik *bagging* yang dimana data training dipilih secara random berdasarkan distribusi vektor acak X, Y (Rifqi, 2022).

Dari uraian di atas, belum dapat ditentukan algoritma apa yang terbaik dalam mengklasifikasi penyakit ginjal kronis (PGK) diantara kedua algoritma tersebut. Sehingga dilakukannya perbandingan algoritma dalam klasifikasi penyakit ginjal kronis (PGK) antara *Naïve Bayes Classifier* (NBC) dengan *Random Forest*.

2. KAJIAN TEORITIS

Penyakit Ginjal Kronis (PGK) merupakan penyakit yang perlu dideteksi sejak dini untuk mencegah adanya komplikasi yang lebih serius. Pemanfaatan teknologi *machine learning* di bidang kesehatan banyak digunakan saat ini untuk membantu proses klasifikasi dan prediksi sebuah penyakit dari data yang relevan.

Berdasarkan penelitian sebelumnya, telah banyak penerapan algoritma *machine learning* dalam klasifikasi penyakit ginjal kronis. Penelitian yang dilakukan oleh (A'yuniyah & others, 2022) menunjukkan bahwa algoritma *Naïve Bayes Classifier* (NBC) dapat mengklasifikasikan Penyakit Ginjal Kronis dengan skor akurasi 94–95% dengan F1-score >0.95. Hasil dari penelitian tersebut menjadi pendukung karakteristik NBC efektif pada data medis.

Selain itu, pendekatan *Random Forest* pada klasifikasi Penyakit Ginjal Kronis yang diteliti oleh (Rifqi, 2022) dengan melakukan optimasi menggunakan Particle Swarm Optimization menghasilkan akurasi 98-99,16%. Penelitian tersebut menunjukkan bahwa algoritma *Random Forest* memberikan performa yang lebih baik pada data yang kompleks dengan memanfaatkan metode *ensemble* dari beberapa pohon keputusan.

Penelitian serupa yang dilakukan oleh (Chotimah & Rozzaqi, 2023) juga menerapkan algoritma *Naïve Bayes Classifier* (NBC) dalam mengklasifikasi diagnosis Penyakit Ginjal Kronis. Penelitian ini fokus pada tahap preprocessing data dengan performa akurasi 94.25%, presisi 98.40%, recall 94.23%, serta AUC 0.961. Ini menunjukkan bahwa NBC mempunyai keunggulan dari segi efektivitas dan kecepatan dalam sistem diagnosis penyakit.


Sejumlah penelitian terdahulu juga telah mengkaji perbandingan performa antara algoritma *Naïve Bayes Classifier* dan *Random Forest* dalam proses klasifikasi penyakit ginjal kronis dengan *Random Forest* unggul pada F-1 Score mendekati 100%. Studi yang dilakukan oleh [8] mengevaluasi penggunaan *Naïve Bayes*, *Support Vector Machine*, serta *Random Forest*, dan menunjukkan bahwa algoritma *Random Forest* menghasilkan tingkat akurasi yang lebih baik dalam prediksi PGK dengan akurasi 99,64%. Temuan tersebut diperkuat oleh penelitian [9] yang menyimpulkan bahwa *Random Forest* memiliki kemampuan yang lebih stabil dalam menangani perbedaan dan keragaman data dibandingkan *Naïve Bayes Classifier* dengan RF 99.3%, NBC+AdaBoost 98.6% , dan NBC 95.4%.

Namun, beberapa penelitian tersebut belum menguji pengaruh ukuran dataset terhadap stabilitas performa model. Celah ini mendasari fokus utama penelitian ini. Oleh sebab itu, penelitian ini diarahkan untuk melakukan analisis komparatif antara algoritma *Naïve Bayes*

Classifier dan *Random Forest* dengan memanfaatkan variasi ukuran dataset, guna mengidentifikasi algoritma yang paling optimal dalam klasifikasi penyakit ginjal kronis.

3. METODE PENELITIAN

Metode penelitian ini menggunakan alur kerja *machine learning* yang terstruktur untuk mengembangkan dan mengevaluasi model klasifikasi Penyakit Ginjal Kronis (PGK) dengan memanfaatkan dataset dari Kaggle. Seluruh tahapan penelitian, mulai dari pengolahan data hingga evaluasi kinerja model, ditampilkan dalam bentuk flowchart pada Gambar 1.



Gambar 1. Alur Metode Penelitian

Pengumpulan Data

Penelitian ini menggunakan *Kidney Disease Dataset* yang bersumber dari platform Kaggle yang merupakan salah satu situs terkenal di dunia *data science* dan *machine learning* yang diakses melalui laman: <https://www.kaggle.com/datasets/steve92510/kidney-disease-dataset>. Dataset tersebut berisi 400 catatan medis pasien dan 24 atribut yang disajikan dalam bentuk data tabular yang digunakan untuk mengklasifikasikan kondisi Penyakit Ginjal Kronis (PGK) serta non-PGK. Atribut yang tersedia mencerminkan parameter klinis pasien dan digunakan sebagai data pelatihan serta pengujian dalam proses pengembangan dan evaluasi model klasifikasi PGK.

Pre-processing

Tahapan awal penelitian ini melibatkan alur kerja pra-pemrosesan data yang diimplementasikan pada *Kidney Disease Dataset* dengan tujuan mengubah data menjadi lebih efektif untuk diolah oleh algoritma *machine learning*.

Data Selection

Pada dataset penyakit ginjal kronis ini terdapat 400 data yang memiliki 24 atribut dan 1 label (*Class*) yaitu *Age* (umur), *Blood Pressure* (tekanan darah), *Specific Gravity*, *Albumin*, *Sugar* (gula), *Red Blood Cells* (sel darah merah), *Pus Cell* (sel nanah), *Pus Cell Clumps*

(gumpalan sel nanah), *Bacteria*, *Blood Glucose Random* (gula darah), *Blood Urea*, *Serum Creatinine*, *Sodium*, *Potassium*, *Hemoglobin*, *Packed Cell Volume*, *White Blood Cell* (sel darah putih), *Red Blood Cell Count*, *Hypertension*, *Diabetes Mellitus*, *Coronary Artery Disease* (jantung koroner), *Appetite* (nafsu makan), *Pedal Edema* (pembengkakan) dan *Anemia*, serta 1 label (*class*). Atribut-atribut tersebut diseleksi menjadi 14 atribut model yang dipilih berdasarkan ciri-ciri serta gejala penyakit ginjal kronis. Hasil seleksi yang telah dilakukan dapat dilihat seperti pada Tabel 1 di bawah ini (Gliselda, 2021).

Tabel 1. Hasil Seleksi Atribut

No	Nama Atribut	Nilai Atribut
1.	Age	2-90 tahun
2.	Red Blood Cell	Normal/Abnormal
3.	Pus Cell	Normal/Abnormal
4.	Bacteria	Present/Notpresent
5.	Blood Glucose Random	22-490 mg/dL
6.	Blood Urea	10-39 mg/dL
7.	Sodium	45-163 mEq/L
8.	Potassium	2.5-7.6 mmol/L
9.	Hypertension	Yes/No
10.	Diabetes Mellitus	Yes/No
11.	Coronary Artery Disease	Yes/No
12.	Appetite	Good/Poor
13.	Pedal Edema	Yes/No
14.	Anemia	Yes/No

Transformasi Atribut

Pada tahap ini, dilakukan proses penyederhanaan nama atribut dengan menggunakan teknik *feature renaming* untuk mempersingkat dan mengurangi kesalahan penulisan pada tahap selanjutnya. Transformasi data ini menggunakan *python* yang dimana diaplikasikan pada *Google Colab* yang dapat dilihat pada Tabel 2 di bawah ini.

Tabel 2. Transformasi Atribut

Sebelum Transformasi Data	Sesudah Transformasi Data
Age	Age
Blood Pressure	Bp
Specific Gravity	Sg
Albumin	Al
Sugar	Su
Red Blood Cells	Rbc
Pus Cell	Pc
Pus Cell Clumps	Pcc
Bacteria	Ba
Blood Glucose Random	Bgr
Blood Urea	Bu
Serum Creatinine	Sc

Sodium	Sod
Potassium	Pot
Hemoglobin	Hemo
Packed Cell Volume	Pcv
White Blood Cell Count	Wc
Red Blood Cell Count	Rc
Hypertension	Htn
Diabetes Mellitus	Dm
Coronary Artery Disease	Cad
Appetite	Appet
Pedal Edema	Pe
Anemia	Ane

1. Binary Encoding

Setelah melakukan transformasi atribut dengan *feature renaming*, maka selanjutnya dilakukan *binary encoding*. Data yang bersifat kategorikal diubah menjadi nilai numerik 1 dan 0. Teknik ini dilakukan agar data dapat diproses secara sistematis oleh model *machine learning*. Hasil *binary encoding* terlampir pada Tabel 3.

Tabel 3. Binary Encoding

Sebelum	Sesudah
Normal/Abnormal	0/1
Normal/Abnormal	0/1
Present/Notpresent	1/0
Present/Notpresent	1/0
Yes/No	1/0
Yes/No	1/0
Yes/No	1/0
Good/Poor	1/0
Yes/No	1/0
Yes/No	1/0
Ckd/Notckd	1/0

2. Cleaning Data

Pada penelitian ini diterapkan dua cara untuk membersihkan data guna mengatasi nilai yang hilang (NaN) pada dataset penyakit ginjal kronis. Metode pertama adalah *mean imputation*, yang berarti mengisi nilai yang kosong dengan nilai rata-rata dari setiap atribut sehingga terbentuk dataset yang utuh dengan total 400 data, seperti ditunjukkan pada Gambar 2. Metode kedua adalah penghapusan baris (*drop*), yaitu dengan mengeliminasi data yang memiliki nilai kosong (NaN/“?”), sehingga jumlah data yang tersisa menjadi 158 data yang dapat dilihat pada Gambar 3.

Gambar 2. Hasil Cleaning Data Mean

	age	bp	sg	al	su	rbc	pc	pcc	ba	bgr	...	sod	pot	hemo	htn	dm	cad	appet	pe	ane	class
0	48.0	80.0	1.020	1.0	0.0	0.0	0.0	0.0	0.0	121.000000	...	137.528754	4.627244	15.4	1.0	1.0	0.0	1.0	0.0	0.0	1.0
1	7.0	50.0	1.020	4.0	0.0	0.0	0.0	0.0	0.0	148.036517	...	137.528754	4.627244	11.3	0.0	0.0	0.0	1.0	0.0	0.0	1.0
2	62.0	80.0	1.010	2.0	3.0	0.0	0.0	0.0	0.0	423.000000	...	137.528754	4.627244	9.6	0.0	1.0	0.0	0.0	0.0	1.0	1.0
3	48.0	70.0	1.005	4.0	0.0	0.0	1.0	1.0	0.0	117.000000	...	111.000000	2.500000	11.2	1.0	0.0	0.0	0.0	1.0	1.0	1.0
4	51.0	80.0	1.010	2.0	0.0	0.0	0.0	0.0	0.0	106.000000	...	137.528754	4.627244	11.6	0.0	0.0	0.0	1.0	0.0	0.0	1.0
...
395	55.0	80.0	1.020	0.0	0.0	0.0	0.0	0.0	0.0	140.000000	...	150.000000	4.900000	15.7	0.0	0.0	0.0	1.0	0.0	0.0	0.0
396	42.0	70.0	1.025	0.0	0.0	0.0	0.0	0.0	0.0	75.000000	...	141.000000	3.500000	16.5	0.0	0.0	0.0	1.0	0.0	0.0	0.0
397	12.0	80.0	1.020	0.0	0.0	0.0	0.0	0.0	0.0	100.000000	...	137.000000	4.400000	15.8	0.0	0.0	0.0	1.0	0.0	0.0	0.0
398	17.0	60.0	1.025	0.0	0.0	0.0	0.0	0.0	0.0	114.000000	...	135.000000	4.900000	14.2	0.0	0.0	0.0	1.0	0.0	0.0	0.0
399	58.0	80.0	1.025	0.0	0.0	0.0	0.0	0.0	0.0	131.000000	...	141.000000	3.500000	15.8	0.0	0.0	0.0	1.0	0.0	0.0	0.0

Gambar 3. Hasil Drop Data

```
Before dropping all NaN values: (400, 25)
After dropping all NaN values: (158, 25)
```

3. Pembagian Data (*Data Splitting*)

Tahap ini bertujuan untuk membagi dataset yang diperoleh dari proses *cleaning*, yaitu dataset hasil imputasi *mean* dengan jumlah 400 data dan dataset hasil penghapusan baris (*drop*) dengan jumlah 158 data. Pembagian data berfungsi untuk membagi data yang akan digunakan dalam proses pelatihan (*training*) dan pengujian (*testing*) pada model klasifikasi. Adapun skema pembagian data (*data splitting*) yang digunakan pada penelitian ini adalah sebagai berikut:

a) Dataset Hasil Imputasi (400 Data)

Dataset ini dibagi dengan menggunakan rasio 70% data latih dan 30% data uji, sehingga diperoleh 280 sampel untuk data pelatihan (X_{train} , y_{train}) dan 120 sampel untuk data pengujian (X_{test} , y_{test}).

b) Dataset Hasil *Drop* (158 Data)

Pada data ini, pembagian dilakukan dengan rasio 10% data latih dan 90% data uji. Rasio ini dipilih sebagai bentuk pengujian pada model dalam kondisi data latih yang terbatas, yang kemudian dapat dianalisis pengaruh ukuran dataset terhadap performa algoritma yang digunakan. Dengan jumlah data yang digunakan untuk pelatihan (X_{train} , y_{train}) adalah 16 sampel, dan 142 sampel untuk data pengujian (X_{test} , y_{test}).

Proses Klasifikasi

Hasil dari proses split data kemudian digunakan sebagai input pada proses pemodelan klasifikasi. Pemodelan klasifikasi pada penelitian ini menggunakan dua algoritma yaitu *Naïve Bayes Classifier* (NBC) dan *Random Forest* yang menggunakan *Google Colab* dalam membantu menghitung data yang telah dipersiapkan terlebih dahulu.

Naïve Bayes Classifier (NBC)

Algoritma klasifikasi ini termasuk kedalam *machine learning* yang berdasarkan *teorema bayes*, mengasumsikan independensi sempurna antara fitur-fitur yang digunakan untuk mengklasifikasikan data dan digunakan untuk memprediksi data berdasarkan probabilitas (Chotimah & Rozzaqi, 2023). Persamaan dari naïve bayes dapat dilihat sebagai berikut (Sartika & Sensuse, 2017):

$$P(C_i|X) = \frac{P(X|C_i)P(C_i)}{P(X)}$$

Keterangan:

- X : Kriteria suatu kasus berdasarkan input
- C_i : Kelas solusi pola ke-i, dimana i adalah jumlah label kelas
- $P(C_i|X)$: Probabilitas kemunculan label kelas C_i dengan kriteria masukan X
- $P(X|C_i)$: Probabilitas kriteria masukan X dengan label kelas C_i
- $P(C_i)$: Probabilitas label kelas C_i

Random Forest

Algoritma *Random Forest* terdiri dari berbagai kombinasi pohon dimana setiap pengklasifikasi menggunakan vector acak yang diambil sampelnya secara independen dari vector input dan setiap pohon memberikan unit untuk kelas paling populer (Harahap & others, 2021). Selain itu, *Random Forest* memiliki tingkat error rate yang lebih kecil dibandingkan dengan algoritma klasifikasi lainnya dan memiliki kinerja yang baik dalam klasifikasi (Suryanegara et al., 2021).

Evaluasi Model

Tahap evaluasi dilakukan untuk menilai kinerja dan konsistensi model klasifikasi yang dikembangkan pada penelitian ini. Evaluasi hasil pada penelitian ini menggunakan nilai *Confusion Matrix* sebagai dasar untuk menghitung metrik klasifikasi yaitu accuracy, precision,

dan recall untuk mengukur kemampuan model yang digunakan. Berikut ini merupakan penjabaran dari bentuk evaluasi model yang digunakan.

Confusion Matrix

Alat evaluasi berbentuk matriks 2x2 yang digunakan untuk mengukur sejauh mana model dapat mengklasifikasikan data ke dalam kelas positif (PGK) dan kelas negatif (Non-PGK) pada dua algoritma yang berbeda (Ismail & Sri, 2023). Struktur *confusion matrix* yang digunakan ditunjukkan pada Tabel 4.

Tabel 4. Confusion Matrix

Kelas	Positive	Negative
Positive	True Positive (TP)	False Positive (FP)
Negative	False Negative (FN)	True Negative (TN)

Tabel 4 di atas menunjukkan kelas-kelas dari *confusion matrix*. *True positive* (TP) merupakan model klasifikasi yang menyatakan benar dengan memberi label tupel positif. *True negative* (TN) menunjukkan bahwa model klasifikasi memberikan label negatif dengan benar pada tupel negatif. *False Positive* (FP) yaitu memberi label yang salah untuk jumlah tupel yang seharusnya negatif, sedangkan *False Negative* (FN) memberi label yang salah untuk jumlah tupel positif (Khalim et al., 2023). Kelas-kelas *confusion matrix* tersebut menjadi dasar dalam perhitungan performa evaluasi model klasifikasi. Berikut merupakan rumus confusion matrix untuk menghitung *accuracy*, *precision* dan *recall* (Normawati & Prayogi, 2021).

- 1) $Accuracy = \frac{TN+TP}{TN+FP+TP+FN}$, mengukur tingkat ketepatan model.
- 2) $Precision = \frac{TP}{TP+FP}$, mengukur ketepatan prediksi positif.
- 3) $Recall = \frac{TP}{TP+FN}$, mengukur kemampuan model untuk mendeteksi seluruh data kelas positif.

Analisis dan Perbandingan Kinerja

Analisis dan perbandingan kinerja pada penelitian ini dilakukan sebagai bentuk evaluasi performa algoritma *Naïve Bayes Classifier* (NBC) dan *Random Forest* dalam mengklasifikasikan penyakit ginjal kronis berdasarkan metrik evaluasi yang digunakan, yaitu *accuracy*, *precision* dan *recall*.

4. HASIL DAN PEMBAHASAN

Hasil Pengujian Model

Pengujian ini dilakukan untuk mengukur keakuratan hasil masing-masing model dengan menghitung *Accuracy*, *Precision*, dan *Recall*. Hasilnya dikategorikan menjadi dua yaitu, berdasarkan data lengkap (400 sampel) dan dengan data 158 sampel.

Hasil Evaluasi Naïve Bayes Classifier Dengan 400 Data

Capaian evaluasi dari model *Naïve Bayes Classifier* (NBC) dengan 400 data menunjukkan TP = 44, TN = 69, FP = 7 dan FN = 0, dengan menghasilkan akurasi 94%, presisi 86 %, dan recall 100%. Hasil evaluasi NBC dengan 400 data dapat dilihat seperti pada Tabel 5.

Tabel 5. Hasil Evaluasi *Naïve Bayes Classifier* 400 Data

Accuracy (%)	Recall (%)	Precision (%)
94%	100%	86%

Hasil Evaluasi Random Forest Dengan 400 Data

Model *Random Forest* memperoleh nilai TP = 44, TN = 68, FP = 8 dan FN = 0 yang menghasilkan akurasi 93%, presisi 85%, dan recall 100%. Hasil evaluasi tersebut ditunjukkan pada Tabel 6.

Tabel 6. Hasil Evaluasi *Random Forest* 400 Data

Accuracy (%)	Recall (%)	Precision (%)
93%	100%	85%

Hasil Evaluasi Naïve Bayes Classifier Dengan 158 Data

Berikutnya evaluasi model algoritma menggunakan 158 data yang dimana algoritma *Naïve Bayes Classifier* (NBC) mendapatkan nilai TP = 102, TN = 10, FP = 31, FN = 0, dengan akurasi 78%, presisi 77%, dan recall 100%. Rincian tabel hasil evaluasi *Naïve Bayes Classifier* dengan 158 data dapat dilihat pada Tabel 7.

Tabel 7. Hasil Evaluasi *Naïve Bayes Classifier* 158 Data

Accuracy (%)	Recall (%)	Precision (%)
78%	100%	77%

Hasil Evaluasi Random Forest Dengan 158 Data

Hasil evaluasi model algoritma menggunakan *Random Forest* dengan 158 sampel data memperoleh nilai TP = 102, TN = 22, FP = 19, dan FN = 0 yang menghasilkan akurasi 87%, presisi 84%, dan recall 100%. Berikut hasil evaluasi *Random Forest* dengan 158 data yang disajikan pada Tabel 8.

Tabel 8. Hasil Evaluasi Random Forest 158 Data

Accuracy (%)	Recall (%)	Precision (%)
87%	100%	84%

Perbandingan Kinerja Algoritma

Perbandingan Kinerja Naïve Bayes Classifier dan Random Forest

Dari hasil evaluasi model di atas didapatkan perbandingan akurasi dari dua algoritma *Naïve Bayes Classifier* (NBC) dan *Random Forest* yang dirincikan pada tabel 9 berikut.

Tabel 9. Perbandingan Hasil Algoritma

Data	Algoritma	Accuracy (%)	Recall (%)	Precision (%)
400	NBC	94%	100%	86%
	RF	93%	100%	85%
158	NBC	78%	100%	77%
	RF	87%	100%	84%

Pembahasan Hasil Penelitian

Dari tabel di atas model NBC pada dataset 1 memberikan hasil yang baik dengan akurasi tinggi (94%), recall 100%, dan presisi 86%. Model *Random Forest* pada dataset 1 juga memberikan hasil yang baik dengan akurasi tinggi (93%), recall 100%, dan presisi 85%. Performa kedua model cenderung stabil pada dataset 1 dengan ukuran yang lebih besar (400 data). Pada dataset 1, NBC lebih unggul dari pada *Random Forest*. Pada dataset 2 dengan ukuran yang lebih kecil (158 data), performa model cenderung menurun, terlihat dari skor akurasi yang lebih rendah. *Random Forest* cenderung memberikan hasil yang lebih baik daripada NBC pada kedua dataset tersebut, akan tetapi pada dataset 158 data tidak disarankan untuk digunakan kembali dalam penelitian mendatang. Hasil ini memperkuat bahwa perbedaan ukuran data secara signifikan memengaruhi stabilitas performa model terutama algoritma yang sensitif pada ukuran data seperti *Naïve Bayes Classifier* (NBC).

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa algoritma *Naïve Bayes Classifier* (NBC) dan *Random Forest* keduanya sama-sama mampu mengenali pola data Penyakit Ginjal Kronis (PGK) dengan cukup baik dengan performa yang berbeda tergantung ukuran dataset. NBC menunjukkan hasil terbaik dalam dataset besar (400 data), dengan akurasi 94%, recall 100%, dan presisi 86%. Di sisi lain, RF menunjukkan hasil terbaik dalam dataset kecil (158 data), dengan akurasi 87%, recall 100%, dan presisi 84%. Temuan ini mendukung hipotesis bahwa ukuran dan kompleksitas data memengaruhi tingkat efektivitas algoritma secara signifikan.

Hasil ini sejalan dengan penelitian (A'yuniyah & others, 2022), yang menunjukkan bahwa NBC efektif untuk data medis dengan struktur sederhana, serta (Rifqi, 2022) dan (Rizky et al., 2023), yang menunjukkan bahwa RF lebih baik untuk menangani data kecil dan kompleks. Secara teoretis, penelitian ini memperkuat gagasan bahwa pemilihan algoritma klasifikasi harus disesuaikan dengan karakteristik dan ukuran data daripada popularitas metode. Secara praktis, temuan penelitian ini dapat membantu pengembang sistem diagnosis berbasis *machine learning* menemukan model terbaik untuk deteksi dini PGK. Untuk meningkatkan akurasi dan generalisasi model pada dataset medis yang lebih besar, penelitian selanjutnya disarankan untuk menggunakan teknik optimasi hiperparameter atau *ensemble learning* lanjutan seperti *AdaBoost* dan *Bagging*.

DAFTAR REFERENSI

- A'yuniyah, Q., & others. (2022). Implementasi Algoritma Naïve Bayes Classifier (NBC) untuk Klasifikasi Penyakit Ginjal Kronis. *Jurnal Sistem Komputer Dan Informatika (JSON)*, 4(1), 72–76. <https://doi.org/10.30865/json.v4i1.4781>
- Ahmad, A. (2017). Mengenal Artificial Intelligence, Machine Learning, Neural Network, dan Deep Learning. *Jurnal Teknologi Indonesia*, 3(1).
- Chotimah, S. N., & Rozzaqi, A. R. (2023). Klasifikasi Diagnosis Penyakit Ginjal Kronis Dengan Menerapkan Konsep Algoritma Naive Bayes. *Jurnal Ilmiah Penelitian Teknologi Informasi & Komputer (JIPETIK)*, 4(1), 8–15.
- Gliselda, V. K. (2021). Diagnosis dan Manajemen Penyakit Ginjal Kronis (PGK). *Jurnal Medika Utama (JMH)*, 2(4), 1135–1142.
- Harahap, A. H., & others. (2021). Klasifikasi Diagnosa Penyakit Jantung menggunakan Algoritma Random Forest. *Gunung Djati Conference Series*, 3, 43–51.
- Husna, H., & Maulina, N. (2018). Hubungan antara Lamanya Hemodialisis dengan Kualitas Hidup Pasien Penyakit Ginjal Kronis Di Rumah Sakit Umum Cut Meutia Kabupaten Aceh Utara. *Jurnal Kedokteran Dan Kesehatan Malikussaleh*, 1(2), 39–45.

- Ismail, N., & Sri, L. (2023). Mendiagnosa Penyakit Ginjal Kronis Menggunakan Algoritma C4.5. *Seminar Nasional Hasil Penelitian Dan Pengabdian Masyarakat*, 1, 25–31.
- Khalim, K. A., Hayati, U., & Bahtiar, A. (2023). Perbandingan Prediksi Penyakit Hipertensi Menggunakan Metode Random Forest Dan Naive Bayes. *Jurnal Mahasiswa Teknik Informatika*, 7(1), 498–504.
- Listiana, E., & Muslim, M. A. (2017). Penerapan Adaboost Untuk Klasifikasi Support Vector Machine Guna Meningkatkan Akurasi Pada Diagnosa Chronic Kidney Disease. *Prosiding SNATIF*, 875–881.
- Normawati, D., & Prayogi, S. A. (2021). Implementasi Naïve Bayes Classifier Dan Confusion Matrix Pada Analisis Sentimen Berbasis Teks Pada Twitter. *Jurnal Sains Komputer \& Informatika (J-SAKTI)*, 5(2), 697–711.
- Rifqi, S. N. (2022). Optimasi Random Forest Untuk Diagnosis Penyakit Ginjal Kronik Dengan Menggunakan Particle Swarm Optimization. *Seminar Nasional Mahasiswa Ilmu Komputer Dan Aplikasinya (SENAMIKA)*, 3(2), 696–705.
- Rizky, I. I. M., Irianto, S. Y., & Sriyanto. (2023). Perbandingan Kinerja Algoritma Naive Bayes, Support Vector Machine dan Random Forest untuk Prediksi Penyakit Ginjal Kronis. *Seminar Nasional Hasil Penelitian Dan Pengabdian Masyarakat*, 1, 139–151.
- Sartika, D., & Sensuse, D. I. (2017). Perbandingan Algoritma Klasifikasi Naive Bayes, Nearest Neighbour, dan Decision Tree pada Studi Kasus Pengambilan Keputusan Pemilihan Pola Pakaian. *Jatiji*, 1(2), 151–161.
- Suryanegara, G. A. B., Adiwijaya, & Purbolaksono, M. D. (2021). Peningkatan Hasil Klasifikasi pada Algoritma Random Forest untuk Deteksi Pasien Penderita Diabetes Menggunakan Metode Normalisasi. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(1), 114–122. <https://doi.org/10.29207/resti.v5i1.2880>
- Yulianti, I., Saputra, R. A., Mardiyanto, M. S., & Rahmawati, A. (2020). Optimasi Akurasi Algoritma C4.5 Berbasis Particle Swarm Optimization dengan Teknik Bagging pada Prediksi Penyakit Ginjal Kronis. *Techno.COM*, 19(4), 411–421.