

PREDIKSI RESIKO KEMATIAN PENDERITA GAGAL GINJAL KRONIS DENGAN *VOTING CLASSIFIER* DAN *RANDOM FOREST* PADA DATA TIDAK SEIMBANG

Luthfatul Amaliana^{*1}, Ani Budi Astuti², Rossanda Sevia Gadis³, Naurah Atikah Rabbani⁴, Nabila Ayunda Sovia⁵

^{1,2,3,4,5}Universitas Brawijaya, Malang

Email: ¹luthfatul@ub.ac.id, ²ani_budi@ub.ac.id, ³rossandasg@gmail.com, ⁴naurahrabbani@student.ub.ac.id

⁵nabilaayunda003@student.ub.ac.id

*Penulis Korespondensi

(Naskah masuk: 31 Oktober 2024, diterima untuk diterbitkan: 27 Agustus 2025)

Abstrak

Gagal ginjal kronis merupakan salah satu penyakit serius yang dapat menyebabkan kematian jika tidak terdeteksi dan ditangani secara dini. Penelitian ini bertujuan memprediksi risiko kematian pada pasien gagal ginjal kronis menggunakan metode *ensemble learning*, yaitu *random forest* dan *voting classifier* (*hard voting* dan *soft voting*). *Voting classifier* digunakan untuk menggabungkan prediksi dari beberapa model klasifikasi tunggal, di mana *hard voting* mengambil keputusan berdasarkan suara terbanyak, sedangkan *soft voting* mempertimbangkan rata-rata probabilitas prediksi. Data yang digunakan pada penelitian ini merupakan data sekunder dari RSUD Dr. Saiful Anwar, Kota Malang. Proporsi pasien rawat inap yang pulang dalam kondisi meninggal lebih kecil dibanding kondisi tidak meninggal. Kondisi data tidak seimbang ini menyebabkan model cenderung bias terhadap kelas mayoritas. Untuk mengatasi hal tersebut, *synthetic minority over-sampling technique* (SMOTE) diterapkan guna menyeimbangkan distribusi kelas. Selain itu, *random forest* dipilih karena kemampuannya dalam menangani ketidakimbangan data melalui pembobotan pada pohon-pohon keputusan, sehingga mengurangi bias terhadap kelas mayoritas. Evaluasi performa model dilakukan menggunakan metrik akurasi, presisi, dan *recall*. Hasil evaluasi menunjukkan bahwa *random forest* memberikan kinerja terbaik dengan akurasi 77%, presisi 36%, dan *recall* 60%, mengungguli *hard voting* dan *soft voting*. Penggunaan *random forest* dan SMOTE terbukti meningkatkan prediksi pada kelas minoritas, yang sangat penting dalam mendeteksi pasien berisiko kematian tinggi. Pendekatan ini dapat membantu dalam deteksi dini dan pengelolaan yang lebih baik terhadap pasien gagal ginjal kronis, sehingga berpotensi menurunkan angka kematian akibat penyakit ini.

Kata kunci: *Ensemble Machine Learning, Gagal Ginjal Kronis, Random Forest, Voting Classifier*

PREDICTION OF DEATH RISK IN CHRONIC KIDNEY FAILURE PATIENTS USING *VOTING CLASSIFIER* AND *RANDOM FOREST* ON IMBALANCED DATA

Abstract

Chronic kidney disease (CKD) is a life-threatening condition that can lead to fatal outcomes if not diagnosed and treated promptly. This study aims to forecast mortality risk in CKD patients using ensemble learning techniques, including random forest and voting classifier (*hard voting* and *soft voting*). The voting classifier combines predictions from various single classification models, with *hard voting* selecting outcomes based on majority decisions, while *soft voting* averages prediction probabilities. The data used in this study is secondary data from RSUD Dr. Saiful Anwar, Malang City. The proportion of hospitalized patients who were discharged in a deceased condition is smaller than those who were discharged alive. This imbalance in the data causes the model to be biased toward the majority class. However, models tend to favor the majority class when dealing with imbalanced data. To mitigate this, the synthetic minority over-sampling technique (SMOTE) was applied to balance the class distribution. Random forest was also selected for its ability to manage data imbalance through weighted decision trees, reducing bias toward the majority class. Model performance was evaluated using metrics such as accuracy, precision, and recall. Results indicated that random forest outperformed hard voting and soft voting, achieving 77% accuracy, 36% precision, and 60% recall. The combination of random forest and SMOTE significantly enhanced the prediction of minority class outcomes, which is essential for identifying high-risk patients. This method has the potential to support early detection and improved management of CKD patients, thus reducing mortality rates associated with the disease.

Keywords: *Ensemble Machine Learning, Chronic Kidney Disease, Random Forest, Voting Classifier*

1. PENDAHULUAN

Salah satu pendekatan dalam *machine learning* pada era big data adalah *ensemble learning*, yang bertujuan meningkatkan akurasi prediksi dengan menggabungkan beberapa model klasifikasi (Mienye and Sun, 2022). Salah satu metode *ensemble* populer adalah *voting classifier*, yang menggabungkan keputusan dari berbagai model klasifikasi. Metode ini terdiri dari dua jenis, *hard voting* dan *soft voting*. Pada *hard voting*, keputusan akhir diambil berdasarkan suara terbanyak dari model-model yang digunakan, sementara pada *soft voting*, keputusan diambil dengan mempertimbangkan rata-rata probabilitas prediksi setiap model (Jongbo et al., 2020).

Namun, penerapan *voting classifier* pada data tidak seimbang dapat memicu bias, karena model cenderung lebih akurat dalam memprediksi kelas mayoritas, yang mengabaikan kelas minoritas (de Oliveira et al., 2022). Oleh karena itu, untuk menangani data tidak seimbang, berbagai metode telah dikembangkan, termasuk algoritma *ensemble* lain seperti *random forest*, yang efektif dalam menangani ketimpangan kelas melalui pembobotan di pohon-pohon keputusan (Liu et al., 2022). Penelitian di Thailand, misalnya, berhasil menerapkan *random forest* untuk klasifikasi gagal ginjal kronis, dengan akurasi mencapai 100% (Chumuang et al., 2020).

Selain pendekatan model, penyeimbangan data melalui teknik pengolahan seperti *synthetic minority over-sampling technique* (SMOTE) juga digunakan untuk menangani data tidak seimbang. SMOTE menghasilkan sampel sintesis bagi kelas minoritas, yang memungkinkan model untuk belajar dari data yang lebih seimbang (Basha et al., 2022). Penelitian di Brazil menunjukkan bahwa kombinasi SMOTE dan *random forest* menghasilkan performa yang lebih baik dalam klasifikasi pasien gagal ginjal kronis dibandingkan tanpa SMOTE (da Silveira et al., 2022).

Dalam bidang kesehatan, terutama pada penyakit gagal ginjal kronis, penerapan *machine learning* sangat penting (Evans et al., 2022). Gagal ginjal kronis menyebabkan penurunan fungsi ginjal secara bertahap dan berdampak serius pada keseimbangan cairan tubuh (Pasaribu et al., 2021). Di Indonesia, prevalensi gagal ginjal kronis dipengaruhi oleh faktor risiko seperti hipertensi (25,8%), obesitas (15,4%), dan diabetes mellitus (2,3%) (Hustrini et al., 2022). Pada tahap akhir, pasien memerlukan perawatan yang mahal seperti dialisis atau transplantasi ginjal. Oleh karena itu, deteksi dini menjadi kunci untuk memperlambat perkembangan penyakit ini dan mengurangi beban biaya perawatan (Lubetzky et al., 2021).

Berbeda dengan penelitian lain sebelumnya, penelitian ini membandingkan model-model *ensemble machine learning* menggunakan algoritma *random forest*, *voting classifier* yaitu *hard voting* dan *soft voting* disertai penanganan data tidak seimbang melalui teknik SMOTE untuk memprediksi

risiko kematian pada pasien gagal ginjal kronis. Pendekatan ini mampu meningkatkan akurasi prediksi dan mengurangi bias terhadap kelas mayoritas, sehingga dapat berkontribusi dalam menurunkan angka kematian akibat penyakit ini.

2. TINJAUAN PUSTAKA

2.1. Pre-processing Data

Tahapan awal sebelum klasifikasi adalah data *pre-processing*, yang mencakup *data cleaning* dan *label encoding*. *Data cleaning* membersihkan data dengan mendeteksi *missing value*, *outlier*, dan menyelesaikan inkonsistensi, karena data yang tidak bersih dapat mengganggu kinerja algoritma (Reis Pinheiro and Patetta, 2021). *Label encoding* dilakukan dengan mengubah nilai string pada variabel menjadi numerik (0 atau 1) agar bisa diproses oleh algoritma.

Setelah *pre-processing*, dilakukan eksplorasi data untuk memahami pola, mendeteksi outliers, dan anomali. Eksplorasi ini dilakukan secara numerik (ringkasan statistik) atau visual (teknik visualisasi). Tahap ini digunakan untuk pertimbangan memilih metode analisis yang tepat.

2.2. Synthetic Minority Over-sampling Technique

Untuk membantu menyeimbangkan data tidak seimbang maka dilakukan *over-sampling* dengan menggunakan *synthetic minority over-sampling technique* (SMOTE). Teknik SMOTE melakukan *over-sampling* dengan mensintesis data kelas minoritas. Proses ini dilakukan dengan mengambil sampel dari data kelas minoritas, kemudian menciptakan sampel sintesis dengan cara interpolasi di antara sampel-sampel terdekat dari kelas minoritas disimbolkan dengan x_a yang ditunjukkan pada persamaan (1) (Gnip et al., 2021).

$$x_a = x_i + \text{random}(0,1) \times (x_i - x_k) \quad (1)$$

Dimana x_k adalah sampel kelas minoritas yang dipilih secara acak dari *k-nearest neighbor* terhadap sampel x_i yang dihitung berdasarkan jarak *Euclidean*

2.3. Voting Classifier

Voting Classifier menerapkan teknik *ensemble* yang menggabungkan beberapa model lemah untuk menghasilkan model kuat (Sherbiny et al., 2023). Untuk membangun model *voting classifier* maka digunakan beberapa metode klasifikasi sebagai berikut.

1) Logistic Regression

Metode *logistic regression* memprediksi peluang suatu kelas berdasarkan kumpulan variabel prediktor, dengan variabel respon sebanyak dua

kemungkinan yaitu “sukses” atau “gagal” yang dinotasikan sebagai “0” dan “1” (Pal, 2023). Model ini menghitung peluang kelasnya berdasarkan fungsi *log-odds* atau *logit* pada persamaan (2).

$$g(x) = \ln \left[\frac{\pi(x)}{1 - \pi(x)} \right] = \beta_0 + \beta_1 + \dots + \beta_p x_p \quad (2)$$

Dan fungsi *logistic sigmoid* untuk menghitung kelas positif pada persamaan (3).

$$\pi(x) = \frac{e^{\beta_0 + \beta_1 + \dots + \beta_p x_p}}{1 + e^{\beta_0 + \beta_1 + \dots + \beta_p x_p}} \quad (3)$$

Dimana p adalah banyaknya variabel prediktor

2) K-Nearest Neighbor

K-Nearest Neighbor bekerja dengan cara mengklasifikasikan objek data yang tidak diketahui labelnya berdasarkan kemiripan dengan tetangga terdekat (Tope-Oke et al., 2024). Kemiripan diukur berdasarkan jarak tertentu seperti jarak *euclidean* yang ditunjukkan pada persamaan (4).

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4)$$

Dengan x_i adalah objek data x pada variabel ke- i dan y_i adalah objek data y pada variabel ke- i

3) Support Vector Machine.

SVM adalah metode fleksibel pada data non-linier maupun linier yang melakukan klasifikasi dengan menggunakan pemisah berupa *hyperplane*, yaitu garis pemisah linier dibentuk menggunakan margin yang optimal (Sharma and Kaur, 2022). *Hyperplane* optimal ditunjukkan pada persamaan (5).

$$g(x) = \beta_0 + \sum_{i \in S} \alpha_i K(x_i, x) \quad (5)$$

Dimana β_0 adalah bias dan S adalah himpunan observasi data.

Ketiga metode ini dipilih berdasarkan kemampuan klasifikasinya model tunggalnya. Dengan *voting classifier*, kekuatan tiap algoritma dapat digabung untuk meningkatkan akurasi, terutama pada dataset tidak seimbang (Sherbiny et al., 2023).

Teknik penggabungan prediksi ini dibagi menjadi dua, yaitu *soft voting* melakukan prediksi dengan menghitung probabilitas setiap kelas pada model tunggal (de Oliveira et al., 2022). Persamaan dari *soft voting* ditunjukkan pada persamaan (6).

$$Y = \operatorname{argmax}_k \frac{1}{m} \sum_{j=1}^m P_j(k) \quad (6)$$

Dengan $P_m(k)$ menyatakan probabilitas prediksi pengklasifikasian ke- m untuk sejumlah kelas ke- k dan k adalah jumlah kelas.

Sedangkan *hard voting* dihitung berdasarkan oleh suara mayoritas model (de Oliveira et al., 2022). Persamaan dari *hard voting* ditunjukkan pada persamaan (7).

$$Y = \operatorname{mode} \{C1(x), C2(x), \dots, Cm(x)\} \quad (7)$$

Dengan $Cm(x)$ adalah prediksi pada kelas ke- m dan m adalah jumlah pengklasifikasi yang terlibat dalam *voting*.

2.4. Random Forest

Random forest adalah metode yang didasarkan oleh *decision tree* dengan menerapkan *ensemble* dalam menghasilkan keputusan tunggal (Mendapara, 2024). Metode ini mengatasi data tidak seimbang dengan melakukan pembobotan pada setiap kelasnya, dimana pada data minoritas model memberikan bobot yang lebih besar dibanding data mayoritas (Chumuang et al., 2020). Langkah awal dalam melakukan klasifikasi pada *random forest* dimulai dengan membangun sekumpulan pohon melalui teknik *bootstrap* pada data pelatihan. Kemudian ditentukan sebanyak m prediktor dari p prediktor secara acak. Selanjutnya akan dibentuk pohon klasifikasi ke- i . Langkah awal pembentukan pohon dihitung menggunakan persamaan *entropy* ditunjukkan pada persamaan (8).

$$\operatorname{entropy}(S) = \sum_{i=1}^k -p_i \log_2 p_i \quad (8)$$

Dengan S adalah himpunan data dan p_i adalah probabilitas frekuensi kelas ke- i . Nilai *entropy* yang telah didapatkan kemudian digunakan untuk menghitung nilai *information gain*, dengan menggunakan persamaan (9).

$$\operatorname{gain}(A) = \operatorname{entropy}(S) - \sum_{j=1}^c \frac{|S_j|}{S} \times \operatorname{entropy}(S_j) \quad (9)$$

Dengan A variabel prediktor, c menunjukkan banyak partisi, dan S_j menunjukkan banyak sampel untuk partisi ke- j .

2.5. Evaluasi Model

Evaluasi model klasifikasi perlu dilakukan untuk dapat mengetahui performa model dalam

mengklasifikasikan objek data secara tepat dan akurat. Evaluasi model klasifikasi dilakukan dengan cara membandingkan nilai prediksi dan nilai aktual yang dihasilkan. Hasil perbandingan tersebut disajikan dalam bentuk matriks bernama matriks konfusi. Bentuk matriks konfusi disajikan pada Tabel 1.

Actual	Prediction	
	Positive (1)	Negative (0)
Positive (1)	True Positive (TP)	False Negative (FN)
Negative (0)	False Positive (FP)	True Negative (TN)

Berdasarkan nilai dari keempat komponen matriks konfusi tersebut, dapat dihitung nilai evaluasi lain seperti akurasi, presisi, dan *recall*. Nilai akurasi, presisi, dan *recall* memiliki rentang dari 0 hingga 1. Nilai mendekati 1 menandakan bahwa model klasifikasi sudah cukup baik dalam melakukan klasifikasi. Nilai akurasi, presisi, dan *recall* dapat dihitung menggunakan persamaan (10), (11), dan (12).

$$\text{Akurasi} = \frac{TP + FN}{TP + FN + FP + TN} \quad (10)$$

Akurasi mengukur ketepatan model klasifikasi secara keseluruhan dengan menghitung rasio prediksi yang benar, yaitu *true positive* dan *true negative*. Dengan mempertimbangkan kedua metrik tersebut, akurasi memberikan evaluasi menyeluruh terhadap performa model di semua kelas.

$$\text{Presisi} = \frac{TP}{TP + FP} \quad (11)$$

Presisi mengukur keakuratan prediksi *positive* dari model, dimana nilai presisi yang tinggi menunjukkan rendahnya *false positive* atau *type I error*.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (12)$$

Recall mengukur kemampuan model untuk mengidentifikasi data yang termasuk dalam kategori *positive* oleh model. Nilai *recall* yang tinggi menunjukkan rendahnya *false negative* atau *type II error* (Vujović, 2021).

3. METODE PENELITIAN

Data yang digunakan pada penelitian merupakan data sekunder yang bersumber dari RSUD Dr. Saiful Anwar (RSSA) Kota Malang, Jawa Timur. Data terdiri dari 52 kolom dan 640 baris. Pada penelitian digunakan satu variabel respon yaitu kondisi pulang pasien sejumlah 521 tidak meninggal dan 117 meninggal. Variabel prediktor meliputi jenis kelamin, umur, diagnosa masuk, diagnosa utama,

hemodialisis, komplikasi anemia, komplikasi diabetes. Definisi operasional variabel disajikan pada Tabel 2.

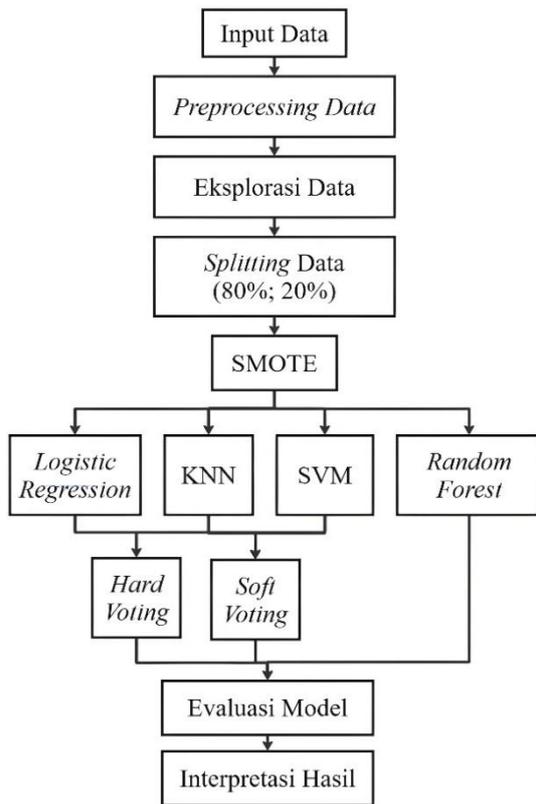
Tabel 2. Definisi Operasional Tabel

No	Nama Variabel	Definisi Operasional
1	Kondisi Pulang	Keadaan pasien penderita gagal ginjal kronik saat pulang setelah mendapatkan perawatan (meninggal atau tidak meninggal).
2	Jenis Kelamin	Jenis kelamin pasien yang dirawat
3	Umur	Usia pasien yang dirawat
4	Diagnosa Masuk	Diagnosa awal pasien saat masuk rumah sakit
5	Diagnosa Utama	Diagnosa pasien setelah melewati proses pemeriksaan
6	Hemodialisis	Riwayat tindakan hemodialisis pada pasien
7	Komplikasi Anemia	Riwayat adanya penyakit anemia pada pasien
8	Komplikasi Diabetes	Riwayat adanya penyakit diabetes pada pasien

Langkah-langkah yang dilakukan pada penelitian ini adalah sebagai berikut.

- 1) Melakukan *pre-processing* pada data meliputi *data cleaning*, dan *label encoding*.
- 2) Melakukan eksplorasi data.
- 3) Membagi data menjadi dua bagian yaitu data *training* dan data *testing* dengan proporsi 80% data *training* dan 20% data *testing*.
- 4) Melakukan penanganan *imbalanced data* menggunakan metode SMOTE menggunakan persamaan (1).
- 5) Membentuk model klasifikasi tunggal *logistic regression* menggunakan persamaan (2) dan (3), K-NN menggunakan persamaan (4) dan SVM menggunakan persamaan (5).
- 6) Membentuk model *soft voting* menggunakan rumus pada persamaan (6)
- 7) Membentuk model *hard voting* menggunakan rumus pada persamaan (7)
- 8) Membentuk model *random forest* menggunakan rumus pada persamaan (8) dan (9)
- 9) Melakukan evaluasi model pada data *testing* menggunakan rumus pada persamaan (10), (11) dan (12).
- 10) Membandingkan hasil evaluasi model *soft voting*, *hard voting*, dan *random forest*
- 11) Memilih model terbaik dan melakukan interpretasi

Untuk memperjelas gambaran langkah-langkah penelitian ini dapat dilihat pada Gambar 1.



Gambar 1. Langkah-Langkah Penelitian

Untuk mendapatkan hasil klasifikasi yang optimal pada model maka dibutuhkan pengaturan *hyperparameter*. Berikut ditunjukkan kombinasi *hyperparameter* tuning yang optimal untuk algoritma *logistic regression*, K-NN, SVM, dan *random forest* dengan definisi ditunjukkan pada Tabel 3.

Tabel 3. Parameter Model

Model	Parameter	Definisi
<i>Logistic Regression</i>	<i>C</i>	Nilai yang mengontrol kekuatan regulasi
	<i>penalty</i>	Jenis regularisasi yang digunakan
	<i>solver</i>	Algoritma optimasi yang digunakan
K-NN	<i>n_neighbors</i>	Banyaknya tetangga terdekat <i>k</i>
	<i>weights</i>	Menentukan bagaimana bobot tetangga terdekat diperhitungkan
	<i>metric</i>	Metrik jarak yang digunakan
SVM	<i>C</i>	Nilai yang mengontrol kekuatan regularisasi
	<i>gamma</i>	Nilai yang mengontrol seberapa jauh pengaruh satu titik data pelatihan
	<i>kernel</i>	Jenis kernel yang digunakan
<i>Random Forest</i>	<i>n_estimators</i>	Banyaknya <i>trees</i> yang akan dibuat
	<i>max_features</i>	Nilai yang mengontrol keragaman diantara <i>trees</i>

Dengan kombinasi pengaturan *hyperparameter* ditunjukkan pada Tabel 4.

Tabel 4. Kombinasi Parameter Model dan *Tuning Accuracy*

Model	Parameter	Nilai
<i>Logistic Regression</i>	<i>C</i>	0,001
	<i>penalty</i>	l1
	<i>solver</i>	<i>liblinear</i>
<i>Tuning Accuracy</i>	-	0,88
K-NN	<i>n_neighbors</i>	11
	<i>weights</i>	<i>uniform</i>
	<i>metric</i>	<i>euclidean</i>
<i>Tuning Accuracy</i>	-	0,83
SVM	<i>C</i>	0,1
	<i>gamma</i>	<i>scale</i>
	<i>kernel</i>	<i>linear</i>
<i>Tuning Accuracy</i>	-	0,88
<i>Random Forest</i>	<i>n_estimators</i>	600
	<i>max_features</i>	4
<i>Tuning Accuracy</i>	-	0,98

Hasil *tuning hyperparameter* pada Tabel 4 kemudian akan digunakan untuk membentuk model klasifikasi.

4. HASIL DAN PEMBAHASAN

4.1 Eksplorasi Data

Eksplorasi data pada data kondisi pasien gagal ginjal kronik disajikan pada Gambar 2.



Gambar 2. Presentase Pasien Pulang Meninggal dan Tidak Meninggal

Berdasarkan gambaran umum mengenai hasil perawatan bagi pasien gagal ginjal kronik ditunjukkan pada Gambar 2 diketahui sebanyak 81,7% atau 521 pasien gagal ginjal kronik pulang dalam kondisi tidak meninggal. Sedangkan sisanya sebanyak 18,3% atau 117 pasien pulang dalam keadaan meninggal setelah melewati proses perawatan. Banyaknya pasien yang pulang dalam kondisi tidak meninggal menandakan bahwa perawatan bagi pasien berjalan dengan baik.

4.2 Hasil Penerapan SMOTE

Sebelum analisis dilakukan, data perlu dibagi menjadi dua bagian, yakni 80% untuk latih (*training data*) dan 20% untuk uji (*testing data*). Data latih digunakan untuk melatih model klasifikasi, sedangkan data uji digunakan untuk mengevaluasi model melalui prediksi, sehingga dapat diperoleh informasi terkait performa model yang dihasilkan. Hasil penerapan teknik SMOTE dapat dilihat pada Tabel 5.

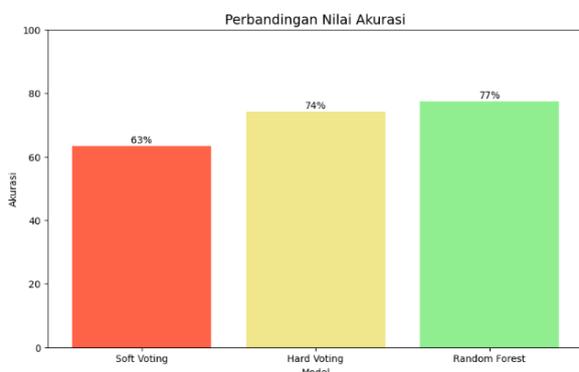
Tabel 5. Hasil SMOTE

	Label	
	<i>Positive (1)</i>	<i>Negative (0)</i>
Sebelum SMOTE	97	413
Setelah SMOTE	413	413

Setelah melewati proses SMOTE, proporsi label pada data *training* telah seimbang dan dapat digunakan untuk proses klasifikasi.

4.3 Evaluasi Model

Performa model *soft voting*, *hard voting*, dan *random forest* dievaluasi menggunakan metrik evaluasi seperti akurasi, presisi, dan *recall* yang dihitung berdasarkan matriks konfusi. Matriks konfusi ini diperoleh dengan membandingkan nilai prediksi dengan nilai aktual dari data *testing*.



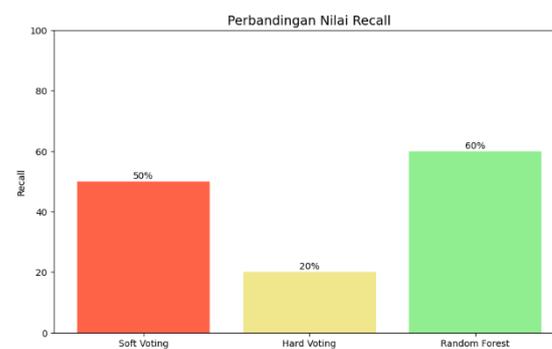
Gambar 3. Perbandingan Nilai Akurasi

Pada Gambar 3 menunjukkan perbandingan nilai akurasi yang dihasilkan oleh ketiga model. Nilai akurasi digunakan untuk menilai seberapa tepat model dalam memprediksi keseluruhan hasil klasifikasi. Akurasi yang tinggi menunjukkan bahwa model lebih akurat dalam melakukan prediksi. Berdasarkan Gambar 3, model yang dihasilkan oleh algoritma *random forest* memberikan nilai akurasi tertinggi, yaitu 77%, dibandingkan dengan algoritma *soft voting* dan *hard voting* yang masing-masing menghasilkan akurasi sebesar 63% dan 74%.



Gambar 4. Perbandingan Nilai Presisi

Berdasarkan perbandingan nilai presisi pada Gambar 4, diketahui bahwa nilai presisi tertinggi, yaitu 36%, dihasilkan oleh model yang dibentuk menggunakan algoritma *random forest*. Nilai presisi yang lebih tinggi pada model *random forest* menunjukkan bahwa ketepatan model dalam melakukan klasifikasi lebih baik dibandingkan dengan model *soft voting* dan *hard voting*.



Gambar 5. Perbandingan Nilai Recall

Berdasarkan perbandingan nilai *recall* pada Gambar 5, dapat dilihat nilai *recall* yang dihasilkan oleh ketiga model untuk mengukur kemampuan model dalam menemukan kembali data yang relevan. Gambar 5 menunjukkan bahwa nilai *recall* tertinggi dihasilkan oleh model *random forest*, yaitu 60%, diikuti oleh model *soft voting* sebesar 50%, dan model *hard voting* sebesar 20%.

Berdasarkan ketiga metrik evaluasi, model *random forest* menunjukkan performa terbaik dibandingkan model lainnya. Nilai evaluasi yang lebih tinggi ini menunjukkan bahwa model *random forest* lebih unggul dalam melakukan klasifikasi. Hasil penelitian ini sesuai dengan penelitian terdahulu yang dilakukan oleh Chumuang et al. (2020) yang menunjukkan bahwa *random forest* merupakan algoritma terbaik dibandingkan algoritma *machine learning* lainnya. Hal ini juga berarti bahwa, dibandingkan model lain, *random forest* lebih tepat digunakan untuk klasifikasi kondisi pasien gagal ginjal kronik, karena memberikan hasil yang lebih akurat dan presisi. Penggunaan *random forest* dan SMOTE terbukti dapat meningkatkan prediksi pada

kelas minoritas, yang sangat penting dalam mendeteksi pasien berisiko kematian tinggi. Metode ini dapat membantu dalam deteksi dini dan pengelolaan yang lebih baik terhadap pasien gagal ginjal kronis, sehingga berpotensi menurunkan angka kematian akibat penyakit ini.

5. KESIMPULAN

Penelitian ini berhasil menunjukkan bahwa metode *ensemble learning*, terutama *random forest* dengan penanganan data tidak seimbang melalui teknik SMOTE, mampu meningkatkan akurasi prediksi risiko kematian pada pasien gagal ginjal kronis. Berdasarkan hasil evaluasi, *random forest* memberikan performa terbaik dibandingkan dengan metode *hard voting* dan *soft voting*, dengan akurasi 77%, presisi 36%, dan *recall* 60%. Penerapan SMOTE terbukti efektif dalam menyeimbangkan distribusi kelas dan mengurangi bias terhadap kelas mayoritas, sehingga prediksi terhadap pasien berisiko tinggi menjadi lebih akurat. Pendekatan ini dapat membantu deteksi dini dan pengelolaan yang lebih baik terhadap pasien gagal ginjal kronis, yang pada akhirnya dapat berkontribusi dalam menurunkan angka kematian akibat penyakit ini. Penelitian ini menghasilkan nilai akurasi tertinggi sebesar 77% dari model *random forest*. Namun, jika dibandingkan dengan penelitian sebelumnya, akurasi dari model ini dapat lebih ditingkatkan dengan metode penyeimbang data lainnya seperti *adaptive synthetic sampling* (ADASYN) yang lebih sesuai untuk klasifikasi biner.

DAFTAR PUSTAKA

- BASHA, S.J., MADALA, S.R., VIVEK, K., KUMAR, E.S., AMMANNAMMA, T., 2022. A Review on Imbalanced Data Classification Techniques. 2022 Int. Conf. Adv. Comput. Technol. Appl. ICACTA 2022 1–6. <https://doi.org/10.1109/ICACTA54488.2022.9753392>
- CHUMUANG, N., MEESANG, N., KETCHAM, M., YIMYAM, W., CHALERMDIT, J., WITTAYAKHOM, N., PRAMKEAW, P., 2020. An Efficiency Random Forest Algorithm for Classification of Patients with Kidney Dysfunction. Proc. - 2020 15th Int. Jt. Symp. Artif. Intell. Nat. Lang. Process. iSAI-NLP 2020 5–10. <https://doi.org/10.1109/iSAI-NLP51646.2020.9376785>
- DA SILVEIRA, A.C.M., SOBRINHO, Á., DA SILVA, L.D., COSTA, E. DE B., PINHEIRO, M.E., PERKUSICH, A., 2022. Exploring Early Prediction of Chronic Kidney Disease Using Machine Learning Algorithms for Small and Imbalanced Datasets. Appl. Sci. 12. <https://doi.org/10.3390/app12073673>
- DE OLIVEIRA, G.P., FONSÊCA, A., RODRIGUES, P.C., 2022. Diabetes diagnosis based on hard and soft voting classifiers combining statistical learning models. Brazilian J. Biometrics 40, 415–427. <https://doi.org/10.28951/bjb.v40i4.605>
- EVANS, M., LEWIS, R.D., MORGAN, A.R., WHYTE, M.B., HANIF, W., BAIN, S.C., DAVIES, S., DASHORA, U., YOUSEF, Z., PATEL, D.C., STRAIN, W.D., 2022. A Narrative Review of Chronic Kidney Disease in Clinical Practice: Current Challenges and Future Perspectives. Adv. Ther. 39, 33–43. <https://doi.org/10.1007/s12325-021-01927-z>
- GNIP, P., VOKOROKOS, L., DROTÁR, P., 2021. Selective oversampling approach for strongly imbalanced data. PeerJ Comput. Sci. 7, 1–22. <https://doi.org/10.7717/PEERJ-CS.604>
- HUSTRINI, N.M., SUSALIT, E., ROTMANS, J.I., 2022. Prevalence and risk factors for chronic kidney disease in Indonesia: An analysis of the National Basic Health Survey 2018. J. Glob. Health 12, 4074. <https://doi.org/10.7189/jogh.12.04074>
- JONGBO, O.A., ADETUNMBI, A.O., OGUNRINDE, R.B., BADEJI-AJISAFE, B., 2020. Development of an ensemble approach to chronic kidney disease diagnosis. Sci. African 8, e00456. <https://doi.org/10.1016/j.sciaf.2020.e00456>
- LIU, L., WU, X., LI, S., LI, Y., TAN, S., BAI, Y., 2022. Solving the class imbalance problem using ensemble algorithm: application of screening for aortic dissection. BMC Med. Inform. Decis. Mak. 22, 1–16.
- LUBETZKY, M., TANTISATTAMO, E., MOLNAR, M.Z., LENTINE, K.L., BASU, A., PARSONS, R.F., WOODSIDE, K.J., PAVLAKIS, M., BLOSSER, C.D., SINGH, N., CONCEPCION, B.P., ADEY, D., GUPTA, G., FARAVARDEH, A., KRAUS, E., ONG, S., RIELLA, L. V., FRIEDEWALD, J., WISEMAN, A., AALA, A., DADHANIA, D.M., ALHAMAD, T., 2021. The failing kidney allograft: A review and recommendations for the care and management of a complex group of patients. Am. J. Transplant. 21, 2937–2949. <https://doi.org/10.1111/ajt.16717>
- MENDAPARA, K., 2024. Development and evaluation of a chronic kidney disease risk prediction model using random forest. Front. Genet. 15, 1–11. <https://doi.org/10.3389/fgene.2024.1409755>
- MIENYE, I.D., SUN, Y., 2022. A Survey of Ensemble Learning: Concepts, Algorithms, Applications, and Prospects. IEEE Access 10, 99129–99149.

- <https://doi.org/10.1109/ACCESS.2022.3207287>
- PAL, S., 2023. Prediction for chronic kidney disease by categorical and non_categorical attributes using different machine learning algorithms. *Multimed. Tools Appl.* 82, 41253–41266. <https://doi.org/10.1007/s11042-023-15188-1>
- REIS PINHEIRO, C.A., PATETTA, M., 2021. *Introduction to Statistical and Machine Learning Methods for Data Science*. SAS Institute.
- SHARMA, P., KAUR, G., 2022. Optimization of Support Vector Machine Classifier Using Grey Wolf Optimization Algorithm for Chronic Kidney Disease Prediction. *Asian Pacific J. Heal. Sci.* 9, 227–231. <https://doi.org/10.21276/apjhs.2022.9.3.46>
- SHERBINY, M.M. EL, ABDELHALIM, E., EL-DIN MOSTAFA, H., EL-SEDDIK, M.M., 2023. Classification of chronic kidney disease based on machine learning techniques. *Indones. J. Electr. Eng. Comput. Sci.* 32, 945–955. <https://doi.org/10.11591/ijeecs.v32.i2.pp945-955>
- TOPE-OKE, A., BADEJI-AJISAFE, B., OGUNTIMILEHIN, A., INYANG, M.V., AWEH, O., ABIOLA, O., 2024. K- Nearest Neighbour-Based Chronic Kidney Disease Prediction System: A Case of Toxic Metals in Urine. *Int. Conf. Sci. Eng. Bus. Driv. Sustain. Dev. Goals, SEB4SDG 2024* 1–6. <https://doi.org/10.1109/SEB4SDG60871.2024.10630163>
- VUJOVIĆ, Ž., 2021. Classification Model Evaluation Metrics. *Int. J. Adv. Comput. Sci. Appl.* 12, 599–606. <https://doi.org/10.14569/IJACSA.2021.0120670>
- PASARIBU, Y.R., SEFTI S.J. ROMPAS, KUNDRE, R.M., 2021. Perbedaan Tekanan Darah Pada Pasien Ckd Sebelum Dan Setelah Hemodialisis Di Ruang Hemodialisars Swasta Di Sulawesi Utara. *J. Keperawatan Volume 9*.