

HARD-VOTING DAN SOFT-VOTING CLASSIFIER: MODEL KLASIFIKASI RISIKO KEMATIAN PADA PASIEN GAGAL GINJAL KRONIK

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

¹Departemen Statistika, Universitas Brawijaya [Email: luthfatul@ub.ac.id]

²Departemen Statistika, Universitas Brawijaya [Email: ani_budi@ub.ac.id]

³Departemen Statistika, Universitas Brawijaya [Email: rossandasg@gmail.com]

⁴Departemen Statistika, Universitas Brawijaya [Email: naurahrabbani@student.ub.ac.id]

⁵Departemen Statistika, Universitas Brawijaya [Email: nabilaayunda003@student.ub.ac.id]

[§]Corresponding Author

ABSTRACT

Chronic kidney failure is a serious disease that can lead to death if not detected and treated early. This study aims to predict the risk of death in hospitalized chronic kidney failure patients using ensemble machine learning methods, specifically hard-voting and soft-voting. The voting classifier is used to combine predictions from several classification models, where hard-voting makes decisions based on the majority vote, and soft-voting considers the average prediction probability. However, with imbalanced data, classification models tend to be biased toward the majority class. To address this, the synthetic minority oversampling technique (SMOTE) is applied to balance the class distribution. The model's performance is evaluated using accuracy, precision, and specificity metrics. The results of the study show that the hard-voting classifier provided the best performance with an accuracy of 85,156%, precision of 86,726%, and specificity of 89,908%, outperforming the soft-voting classifier. The use of SMOTE proved to improve prediction for the minority class, which is crucial in detecting high-risk patients who may die during hospitalization. This approach is expected to aid in the early detection and better management of hospitalized chronic kidney failure patients, potentially reducing mortality rates from this disease.

Keywords: *chronic kidney failure, ensemble machine learning, hard-voting, soft-voting*

1. PENDAHULUAN

Gagal ginjal kronik merupakan kondisi medis serius yang dapat menyebabkan kematian jika tidak ditangani dengan baik. Berdasarkan data rekam medis pasien di wilayah Malang Raya, jumlah pasien gagal ginjal kronik telah mencapai 2500 orang dan jumlah ini diperkirakan akan terus meningkat seiring berjalannya waktu (Republika, 2020). Tingginya angka kematian pada pasien gagal ginjal kronik disebabkan oleh beberapa faktor, seperti tingginya kasus diabetes, hipertensi, dan anemia (Kemenkes, 2018). Kondisi ini membuat pentingnya memprediksi risiko kematian pada pasien rawat inap penderita gagal ginjal kronik. Hal ini bertujuan agar penanganan dapat diberikan secara lebih efektif dan tepat waktu kepada pasien oleh tenaga medis.

Tingginya angka kematian pada pasien gagal

ginjal kronik memperlihatkan perlunya pendekatan prediktif yang lebih canggih untuk membantu dalam pengambilan keputusan klinis yang tepat waktu. Salah satu metode yang efektif untuk memprediksi risiko kematian pada pasien gagal ginjal kronik adalah pendekatan *ensemble machine learning*. Metode *ensemble machine learning* ini digunakan karena menggabungkan beberapa model klasifikasi untuk menghasilkan prediksi yang lebih akurat dibandingkan model klasifikasi tunggal (Han, dkk., 2012). Namun, kerap kali ditemui permasalahan data tidak seimbang jika banyaknya salah satu kategori pada variabel respon lebih sedikit dibandingkan dengan kategori lainnya (Thabtah, dkk., 2020; Ramyachitra & Manikandan, 2014). Penanganan permasalahan ini dapat dilakukan dengan metode *synthetic minority oversampling technique*

(SMOTE). *Oversampling* dilakukan dengan mensintesis kelas minoritas. Sampel kelas minoritas diambil dari data kemudian disisipkan ke kelas minoritas yang menjadi tetangga terdekat (Chawla, dkk., 2002).

Algoritma *voting-classifier* merupakan pengklasifikasi yang menggabungkan model *machine learning* baik yang sama maupun yang berbeda secara konsep untuk melakukan prediksi (Manconi, dkk., 2022). Prediksi ini dilakukan dengan melalui pemungutan suara mayoritas. *Voting-classifier* dibedakan menjadi *hard-voting* dan *soft-voting*. *Hard-voting* melakukan prediksi berdasarkan kelas yang paling banyak muncul dari prediksi kelas yang dihasilkan oleh model tunggal. Sedangkan *soft-voting* melakukan prediksi berdasarkan nilai probabilitas pada setiap prediksi kelas yang dihasilkan oleh model klasifikasi tunggal (Oliviera, dkk., 2022). Penelitian ini menggunakan *hard-voting* dan *soft-voting classifier* dengan memanfaatkan kombinasi dari berbagai algoritma, yakni *logistic regression*, *k-nearest neighbor* (KNN), dan *support vector machine* (SVM), sehingga dapat memberikan hasil prediksi yang lebih baik.

Logistic regression merupakan model regresi yang memiliki dua kemungkinan hasil pada variabel respons yaitu “sukses” dan “gagal” (Hosmer & Lemeshow, 2000). KNN mengklasifikasikan objek data yang tidak diketahui labelnya berdasarkan kemiripan dengan tetangga terdekat (Alfeilat, dkk., 2009). Sedangkan SVM merupakan metode klasifikasi yang memisahkan data berdasarkan fungsi *hyperplane* linear yang optimal dalam dimensi baru (Han, dkk., 2012).

Penerapan *voting-classifier* pada prediksi diabetes telah dilakukan sebelumnya oleh de Oliveira (2022). Selain di bidang kesehatan, *soft voting* dan *hard voting* juga telah diterapkan pada deteksi ancaman keamanan jaringan (*cyber-attack*) oleh Jabbar (2024). Sedangkan pada kasus klasifikasi gagal ginjal kronik, telah diimplementasikan berbagai algoritma klasifikasi seperti *naive bayes classifier*, KNN, SVM maupun *decision tree* oleh Madani, dkk. (2024) dan Wulandari, dkk. (2024).

Penelitian ini bertujuan untuk mengembangkan model prediktif berbasis *ensemble machine learning* untuk memprediksi risiko kematian pada pasien gagal ginjal kronik. Model ini diharapkan dapat membantu tenaga medis dalam memberikan perawatan yang lebih cepat dan tepat, sehingga dapat menurunkan angka kematian pasien gagal ginjal kronik. Selain

itu, model ini juga diharapkan memberikan kontribusi signifikan terhadap pengembangan strategi penanganan pasien gagal ginjal kronik di Indonesia, terutama dalam mendukung pengambilan keputusan medis yang lebih tepat dan didasarkan pada data yang akurat. Dengan adanya model prediktif yang akurat, kualitas hidup pasien dapat ditingkatkan melalui deteksi dini dan penanganan yang lebih optimal.

2. METODE PENELITIAN

Data yang digunakan pada penelitian merupakan data sekunder (sebanyak 638 orang) pasien rawat inap di RSUD Dr. Saiful Anwar (RSSA) Kota Malang, Jawa Timur penderita gagal ginjal kronik. Data tersebut didasarkan pada rekam medis pasien pada periode rawat inap bulan Desember 2022-2023. Pada penelitian digunakan satu variabel respons yaitu kondisi pulang dan tujuh variabel prediktor yang meliputi jenis kelamin, umur, diagnosis masuk, diagnosis utama, hemodialisis, komplikasi anemia, dan komplikasi diabetes. Definisi operasional variabel disajikan pada Tabel 1.

Tabel 1. Definisi Operasional Variabel

No	Nama Variabel	Definisi Operasional
1	Kondisi Pulang	Keadaan pasien setelah dirawat (meninggal atau tidak meninggal)
2	Jenis Kelamin	Jenis kelamin pasien
3	Umur	Usia pasien
4	Diagnosis Masuk	Diagnosis awal pasien saat masuk rumah sakit
5	Diagnosis Utama	Diagnosis 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 *preprocessing* pada data meliputi *data cleaning* dan penentuan kategori variabel.
2. Melakukan eksplorasi data pada data hasil langkah (1).
3. Membagi data menjadi dua bagian yaitu data

training (latih) dan data *testing* (uji) dengan proporsi 80% data *training* dan 20% data *testing*. Proporsi ini dipilih berdasarkan Prinsip Pareto agar tersedia cukup data (80%) sebagai data latih sehingga model dapat belajar dari pola data secara mendalam serta sisa data uji (20%) yang tersedia cukup untuk mengevaluasi performa model.

4. Melakukan penanganan *imbalanced data* menggunakan metode SMOTE.
5. Melakukan *tuning hyperparameter* pada model klasifikasi tunggal *logistic regression*, KNN, dan SVM.
6. Membentuk model klasifikasi tunggal *logistic regression*, KNN, dan SVM.
7. Membentuk model berdasarkan *hard-voting classifier*.
8. Membentuk model berdasarkan *soft-voting classifier*.
9. Melakukan evaluasi model pada data *testing*.
10. Membandingkan hasil evaluasi model *hard-voting* dan *soft-voting classifier*.
11. Memilih model terbaik berdasarkan ukuran nilai akurasi, presisi dan *specificity*
12. Melakukan interpretasi model terbaik.

3. HASIL DAN PEMBAHASAN

Pada langkah awal penelitian dilakukan *preprocessing* pada data yang meliputi data *cleaning*, dan penentuan kategori pada variabel kondisi pulang, jenis kelamin, diagnosis utama, dan hemodialisis.

a. Eksplorasi Data

Eksplorasi pada data kondisi pasien gagal ginjal kronik disajikan melalui dua cara yaitu secara numerik dan visual. Eksplorasi data secara numerik dilakukan pada variabel dengan nilai numerik yaitu variabel umur dan lama rawat dengan menghitung statistika deskriptif yang dirangkum pada Tabel 2.


Tabel 2. Statistika Deskriptif

Variabel	Nilai Minimum	Nilai Maksimum	Rata-Rata
Umur (tahun)	7	95	52,2
Lama Rawat (hari)	1	27	5

Berdasarkan Tabel 2, rata-rata pasien gagal ginjal kronik berusia 52,2 tahun dengan rentang usia antara 7 tahun hingga 95 tahun. Rentang usia yang besar menandakan bahwa pasien gagal

ginjal kronik berasal dari berbagai kelompok usia. Sedangkan lama perawatan yang diterima oleh pasien gagal ginjal kronik bervariasi mulai dari 1 hari hingga yang paling lama adalah 27 hari dengan rata-rata lama perawatan adalah 5 hari.


Persentase Pasien Pulang Meninggal dan Tidak



Gambar 1. Persentase Pasien Pulang Meninggal dan Tidak


Gambaran umum mengenai kondisi pasien rawat inap yang menderita gagal ginjal kronik ditunjukkan oleh Gambar 1. Berdasarkan Gambar 1 diketahui sebanyak 81,7% pasien gagal ginjal kronik pulang dalam kondisi tidak meninggal. Sedangkan sisanya sebanyak 18,3% 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.

Persentase Pasien Pria dan Wanita



Gambar 2. Persentase Pasien Pria dan Wanita

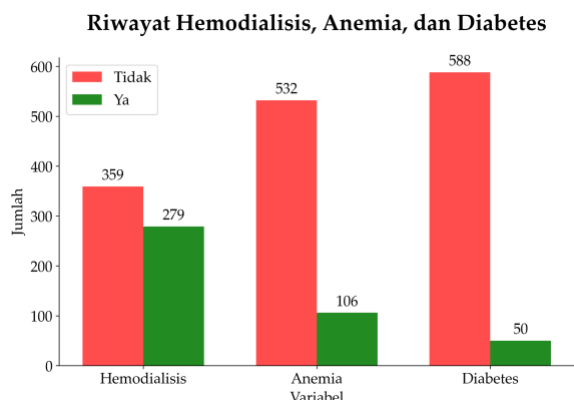
Persentase Diagnosis Utama Pasien



Gambar 3. Persentase Diagnosis Utama Pasien

Berdasarkan Gambar 2, diketahui sebanyak 50,8% pasien gagal ginjal kronik berjenis kelamin pria, sedangkan sisanya yaitu 49,2% berjenis kelamin wanita. Dari 638 pasien yang dirawat, sebanyak 89,3% atau 570 pasien

didiagnosis gagal ginjal kronik *stage 5* atau *stage* akhir, sebanyak 60 pasien juga didiagnosis gagal ginjal kronik akan tetapi tidak diketahui *stage* berapa kondisi gagal ginjal kronik pasien tersebut, dan sisanya sebanyak 8 pasien didiagnosis penyakit lainnya.



Gambar 4. Riwayat Hemodialisis, Anemia, dan Diabetes

Berdasarkan Gambar 3, dari 638 pasien rawat inap penderita gagal ginjal kronik, terdapat 359 pasien yang tidak memiliki riwayat tindakan hemodialisis dan terdapat 279 pasien yang memiliki riwayat tindakan hemodialisis. Pasien gagal ginjal kronik yang memiliki riwayat komplikasi penyakit anemia adalah 106 pasien, sedangkan yang memiliki riwayat komplikasi penyakit diabetes adalah 50 pasien.

b. Synthetic Minority Oversampling Technique (SMOTE)

Sebelum melakukan proses analisis lebih lanjut, data yang digunakan perlu dibagi menjadi data *training* (latih) dan data *testing* (uji) dengan proporsi 80% data *training* dan 20% data *testing*. Data *training* digunakan untuk melatih model klasifikasi, sedangkan data *testing* digunakan untuk prediksi guna memperoleh informasi mengenai performa model yang telah terbentuk. Banyaknya kategori/kelas pada data *training* maupun data *testing* disajikan pada Tabel 3.

Tabel 3. Pembagian Data

	Label		Total
	Positive (1)	Negative (0)	
Data Training	97	413	510
Data Testing	20	108	128

Berdasarkan Tabel 3, dapat diketahui bahwa data dengan label positif dan negatif pada data *training* dalam kondisi yang tidak seimbang atau *imbalanced*. *Imbalanced* data yang tidak

ditangani dapat memengaruhi hasil klasifikasi yang kemudian akan memengaruhi performa model yang terbentuk. Penyeimbangan label kelas pada data dilakukan menggunakan metode SMOTE. Metode SMOTE akan mereplikasi data pada kelas minoritas sehingga banyaknya sama dengan kelas mayoritas. Proporsi data setelah melalui proses SMOTE disajikan pada Tabel 4.

Tabel 4. Hasil SMOTE

	Label/Kategori	
	Positive (1)	Negative (0)
Sebelum SMOTE	97	413
Setelah SMOTE	413	413

Setelah melewati proses SMOTE, proporsi label pada data *training* telah seimbang seperti yang tersaji pada Tabel 4.

c. Voting Classifier

Pada model *voting classifier* digunakan tiga model tunggal yang berbeda yaitu *logistic regression*, KNN, dan SVM. Masing-masing model tunggal menggunakan parameter yang berbeda. Parameter yang digunakan dalam pembentukan model klasifikasi tunggal disajikan pada Tabel 5.

Tabel 5. Parameter Model Klasifikasi Tunggal

Model	Parameter	Definisi	Value
Logistic Regression	<i>C</i>	Nilai yang mengontrol kekuatan regulasi	0.001
	<i>penalty</i>	Jenis regularisasi yang digunakan	l1
	<i>solver</i>	Algoritma optimasi yang digunakan	liblinear
KNN	<i>n_neighbors</i>	Banyaknya tetangga terdekat <i>k</i> Menentukan bagaimana bobot tetangga terdekat diperhitungkan	3
	<i>metric</i>	Metrik jarak yang digunakan	<i>euclidean</i>
SVM	<i>C</i>	Nilai yang mengontrol kekuatan regularisasi	0.1
	<i>gamma</i>	Nilai yang mengontrol seberapa jauh pengaruh satu titik data pelatihan	<i>scale</i>
	<i>kernel</i>	Jenis kernel yang digunakan	<i>linear</i>

Nilai parameter-parameter dari setiap metode tersebut kemudian dievaluasi menggunakan metode *hyperparameter tuning* untuk menentukan kombinasi parameter mana yang memberikan akurasi paling tinggi. Hasil *hyperparameter tuning* disajikan pada Tabel 6.

Tabel 6. *Hyperparameter Tuning*

Model Klasifikasi Tunggal	<i>Tuning Accuracy</i>
<i>Logistic Regression</i>	0,851
KNN	0,867
SVM	0,851

Perbandingan hasil evaluasi akurasi, presisi, dan *specificity* berdasarkan model klasifikasi tunggal *logistic regression*, KNN, dan SVM dirangkum pada Tabel 7.

Tabel 7. Perbandingan Hasil Klasifikasi

Model Klasifikasi Tunggal	Akurasi	Presisi	<i>Specificity</i>
<i>Logistic Regression</i>	0,85	0	0,85
KNN	0,72	0,19	0,61
SVM	0,62	0,19	0,88

Nilai evaluasi dari model klasifikasi tunggal pada Tabel 7 menunjukkan keakuratan yang tinggi pada hasil klasifikasi. Oleh karena itu, digunakan metode *ensemble machine learning* dengan *voting classifier* yaitu *soft voting* dan *hard voting* yang menggabungkan beberapa model klasifikasi tunggal untuk dapat memperoleh hasil klasifikasi yang lebih akurat.

i. Soft Voting

Matriks konfusi hasil klasifikasi kondisi pulang dari pasien rawat inap penderita gagal ginjal kronik yang terbentuk berdasarkan hasil evaluasi model *soft-voting* disajikan pada Tabel 8.

Tabel 8. Matriks Konfusi *Soft-Voting Classifier*

Aktual	Prediksi	
	<i>Positive (1)</i>	<i>Negative (0)</i>
<i>Positive (1)</i>	88	21
<i>Negative (0)</i>	13	6

Matriks konfusi pada Tabel 8 dapat digunakan untuk menghitung nilai evaluasi lain seperti akurasi, presisi, dan *specificity* sebagai berikut.

1. Akurasi

Nilai akurasi dihitung menggunakan rumus berikut:

$$\begin{aligned}
 \text{akurasi} &= \frac{TP + FN}{TP + FN + FP + TN} \\
 &= \frac{88 + 21}{88 + 21 + 13 + 6} \\
 &= \frac{109}{128} \approx 0,85156
 \end{aligned}$$

Berdasarkan nilai akurasi yang diperoleh, keakuratan model dalam mengklasifikasikan data adalah 85,156%. Hal ini memiliki arti bahwa performa model cukup dalam mengklasifikasikan data.

2. Presisi

Nilai presisi dihitung menggunakan rumus berikut:

$$\begin{aligned}
 \text{presisi} &= \frac{TP}{TP + FP} \\
 &= \frac{88}{88 + 13} = \frac{88}{101} \approx 0,87129
 \end{aligned}$$

Berdasarkan nilai presisi yang diperoleh, dapat diketahui bahwa ketepatan model dalam melakukan klasifikasi adalah sebesar 87,129%. Nilai presisi juga dapat diartikan sebagai kemampuan model dalam memprediksi label positif yang benar-benar positif adalah sebesar 87,129%.

3. *Specificity*

Nilai *specificity* dapat dihitung menggunakan rumus berikut:

$$\begin{aligned}
 \text{specificity} &= \frac{TN}{TN + FP} \\
 &= \frac{88}{88 + 21} = \frac{88}{109} \approx 0,80734
 \end{aligned}$$

Berdasarkan nilai *specificity* yang diperoleh, kemampuan model dalam menemukan kembali informasi adalah 80,734% atau model mampu mendeteksi seluruh label positif sebesar 80,734%.

ii. Hard Voting

Matriks konfusi kondisi pasien gagal ginjal kronik yang dihasilkan oleh model *hard voting* tersaji pada Tabel 9.

Tabel 9. Matriks Konfusi *Hard Voting*

Actual	Prediction	
	Positive (1)	Negative (0)
Positive (1)	98	11
Negative (0)	15	4

Matriks konfusi pada Tabel 9, dapat dihitung nilai evaluasi lain seperti akurasi, presisi, dan *specificity*. Berikut merupakan hasil nilai evaluasi akurasi, presisi, dan *recall* yang dihasilkan model *hard voting*.

1. Akurasi

Nilai akurasi dihitung menggunakan rumus berikut:

$$\begin{aligned} \text{akurasi} &= \frac{TP + FN}{TP + FN + FP + TN} \\ &= \frac{98+11}{98+11+15+4} = \frac{109}{128} \approx 0,85156 \end{aligned}$$

Berdasarkan nilai akurasi yang diperoleh, keakuratan model *hard voting* dalam mengklasifikasikan data adalah sebesar 85,156%. Hal ini memiliki arti bahwa performa model *hard-voting* cukup dalam mengklasifikasikan data.

2. Presisi

Nilai presisi dihitung menggunakan rumus berikut:

$$\begin{aligned} \text{presisi} &= \frac{TP}{TP + FP} \\ &= \frac{98}{98 + 15} = \frac{98}{113} \approx 0,86726 \end{aligned}$$

Berdasarkan nilai presisi yang diperoleh, dapat diketahui bahwa ketepatan model dalam melakukan klasifikasi adalah sebesar 86,726%. Nilai presisi juga dapat diartikan sebagai kemampuan model dalam memprediksi label positif yang benar-benar positif adalah sebesar 86,726%.

3. *Specificity*

Nilai *specificity* dapat dihitung menggunakan rumus berikut:

$$\begin{aligned} \text{specificity} &= \frac{TN}{TP + FN} \\ &= \frac{4}{98 + 11} = \frac{4}{109} \approx 0,036697 \end{aligned}$$

Berdasarkan nilai *specificity* yang diperoleh, kemampuan model dalam menemukan kembali informasi adalah 89,908% atau model mampu mendeteksi seluruh label positif sebesar 89,908%.

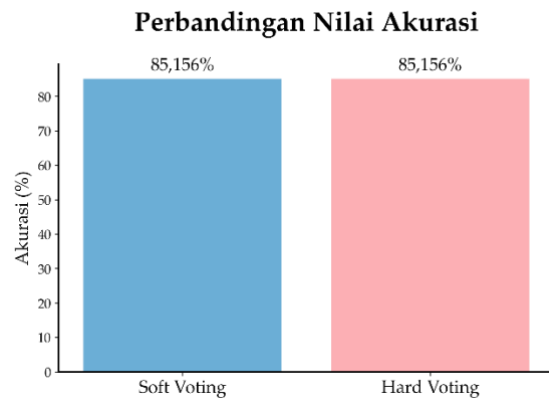
d. Evaluasi Model Klasifikasi

Performa model *hard-voting* dan *soft-voting* yang telah terbentuk dapat diketahui dengan cara melakukan evaluasi model. Model yang terbentuk selanjutnya dievaluasi menggunakan matriks konfusi. Matriks konfusi diperoleh dengan cara membandingkan nilai prediksi dan nilai aktual dari data *testing*. Melalui matriks konfusi, dapat diketahui nilai-nilai evaluasi lain seperti akurasi, presisi, dan *specificity*.


e. Pemilihan Model Terbaik

Perolehan masing-masing nilai evaluasi baik pada kedua model akan digunakan sebagai pertimbangan pemilihan model terbaik untuk kasus prediksi kondisi pasien rawat inap penderita gagal ginjal kronik.

Berdasarkan perbandingan kedua nilai akurasi yang dihasilkan oleh masing-masing model pada Gambar 5, dapat diketahui bahwa nilai akurasi yang dihasilkan tidak memiliki perbedaan yang signifikan. Model *soft-voting* dan *hard-voting* menghasilkan nilai akurasi yang sama yaitu sebesar 85,156%.




Gambar 5. Perbandingan Nilai Akurasi



Gambar 6. Perbandingan Nilai Presisi

Berdasarkan perbandingan kedua nilai presisi yang dihasilkan oleh masing-masing model seperti pada Gambar 6, dapat diketahui bahwa nilai presisi yang dihasilkan tidak memiliki perbedaan yang signifikan. Namun, model yang dihasilkan *soft-voting* sedikit lebih unggul daripada model yang dihasilkan *hard-voting*. Nilai presisi yang dihasilkan oleh model *soft-voting* adalah 87,129%, sementara yang dihasilkan oleh model *hard voting* adalah 86,726%. Kedua nilai presisi tersebut dapat dikatakan hampir sama pada kedua model.



Gambar 7. Perbandingan Nilai *Specificity*

Perbandingan nilai *specificity* yang disajikan pada Gambar 7 menunjukkan perolehan nilai *specificity* dari model *soft-voting* dan *hard-voting*. Berdasarkan kedua nilai evaluasi, model yang dihasilkan oleh *hard-voting* memberikan nilai evaluasi yang lebih tinggi dibandingkan dengan *soft-voting*.

Perolehan nilai akurasi yang sama dan *specificity* yang lebih tinggi dibandingkan dengan model *soft-voting* menandakan bahwa model *hard-voting* memiliki performa yang lebih baik. Hal ini juga berarti bahwa model *hard-voting* lebih baik digunakan pada klasifikasi kondisi pulang pasien rawat inap penderita gagal ginjal kronik karena memberikan hasil klasifikasi yang lebih tepat dan akurat, dibandingkan model *soft-voting*.

4. KESIMPULAN DAN SARAN

Berdasarkan hasil dan pembahasan, dapat disimpulkan bahwa model klasifikasi *soft-voting* dan *hard-voting* mampu memberikan hasil yang baik dalam memprediksi kondisi pulang pasien gagal ginjal kronik. Berdasarkan ketiga nilai evaluasi, diperoleh nilai presisi menunjukkan *soft-voting* lebih baik dari *hard-voting*. Namun, sebaliknya, nilai akurasi dan *specificity* justru menunjukkan model *hard-voting* lebih unggul

dibandingkan *soft-voting* dalam memprediksi kondisi pulang pasien rawat inap penderita gagal ginjal kronik. Model klasifikasi terbaik yang dihasilkan dari *hard-voting* mampu menunjukkan hasil prediksi persentase kondisi pasien rawat inap gagal ginjal kronik yang pulang meninggal sebesar 18,3%, sementara yang pulang tidak meninggal sebesar 81,7%.

Saran yang dapat diberikan untuk penelitian berikutnya adalah terdapat banyak metode *ensemble machine learning* seperti *random forest*, algoritma C4.5, dan berbagai metode lainnya dapat di kembangkan untuk menghasilkan keakuratan prediksi yang lebih tinggi.

DAFTAR PUSTAKA

- Alfeilat, H. A., Hassanat, A., Lasassmeh, O., Tarawneh, A., Alhasanat, M., Salman, H., & Prasath, V. (2009). K-nearest neighbor classification. *Data mining in agriculture*, 83-106.
- Chawla, N., Bowyer, K., Hall, L., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research* 16, 321-357.
- De Oliveira, G. P., Fonsêca, A., & Rodrigues, P. (2022). Diabetes diagnosis based on hard and soft voting classifiers combining statistical learning models. *Brazilian Journal of Biometrics*, 415-427.
- Han, J., Kamber, M., & Pei, J. (2012). *Data Mining Concepts and Techniques*. Morgan Kaufmann Publishers.
- Hosmer, D. & Lemeshow, S. (2000). *Applied Logistic Regression*. USA: John Wiley & Sons, Inc.
- Jabbar, H. G. (2024). Advanced Threat Detection Using Soft and Hard Voting Techniques in Ensemble Learning. *Journal of Robotics and Control*, 5(4), 1104-1116.
- Madani, P. M. S., Rohana, T., Baihaqi, K. A., & Fauzi, A. (2024). Perbandingan Kinerja Klasifikasi Penyakit Ginjal Menggunakan Algoritma Support Vector Machine (SVM) dan Decision Tree (DT). *Building of Informatics, Technology and Science (BITS)*, 6(1), 74-82.
- Manconi, A., Armano, G., Gnocchi, M., & Milanesi, L. (2022). A Soft-Voting Ensemble Classifier for Detecting Patients

Affected by COVID-19. *Applied Science*, 1-23.

Menteri Kesehatan RI. (2018). Air bagi kesehatan: upaya peningkatan promotive preventif bagi kesehatan ginjal di Indonesia. https://www.persi.or.id/images/2018/data/materi_menkes.pdf. Diakses pada 1 Maret 2024.

Ramyachitra, D., & Manikandan, P. (2014). Imbalanced Dataset Classification and Solutions: A Review. *International Journal of Computing and Business Research (IJCBR)*, 5(4).

Republika. (2020). Penderita Gagal Ginjal di Malang Raya Diprediksi Capai 2500. <https://republika.co.id/berita/q3n1dy284/penderita-gagal-ginjal-di-malangraya-diprediksi-capai-2500>. Diakses pada 4 Maret 2024.

Thabtah, F., Hammoud, S., Kamalov, F., & Gonsalvesv, A. (2020). Data Imbalance in Classification: Experimental Evaluation. *Information Science*, 429-441.

Wulandari, V., Sari, W.J., Alfian, Z., Legito, & Arifianto, T. (2024). Implementation of Naïve Bayes Classifier and K-Nearest Neighbor Algorithms for Chronic Kidney Disease Classification. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(2), 710-718.