

PREDIKSI RISIKO PENYAKIT JANTUNG PADA PASIEN HEMODIALISA MENGGUNAKAN OPTIMASI ALGORITMA RANDOM FOREST DAN SUPPORT VECTOR MACHINE DI RSU ARUN

Khananda Raihansyah^{1*}, Nurdin², Muhammad Sayuti³

^{1,2,3}Magister Teknologi Informasi, Universitas Malikussaleh; Kampus Utama Bukit Indah, Muara Satu, Kota Lhokseumawe, Aceh 24353; Telp/Fax: (0645) 41373

Keywords:

Hemodialisa; Komplikasi Jantung; *Machine Learning*; *Random Forest*; *Support Vector Machine*.

Correspondent Email:

khananda.257110201004@mhs.unimal.ac.id

Abstrak. Penyakit jantung merupakan komplikasi yang sering terjadi dan menjadi penyebab utama morbiditas pada pasien yang menjalani terapi hemodialisa. Penelitian ini bertujuan untuk memprediksi risiko penyakit jantung pada pasien hemodialisa di RSU Arun dengan memanfaatkan algoritma *Machine Learning*, yaitu *Random Forest* dan *Support Vector Machine* (SVM). Total data yang digunakan adalah 160 rekam medis pasien dengan 12 parameter klinis awal. Tahapan penelitian mencakup *data cleansing*, *feature engineering* berupa penambahan fitur *Drop Tensi* dan Rasio Ureum/Kreatinin, *Exploratory Data Analysis* (EDA), serta *hyperparameter tuning* menggunakan *GridSearchCV*. Hasil penelitian menunjukkan bahwa dataset memiliki distribusi kelas target yang sangat seimbang, yaitu 80 pasien stabil dan 80 pasien berisiko komplikasi. Berdasarkan komparasi performa, kedua algoritma menghasilkan tingkat akurasi yang sama yaitu 96.88%. Namun, evaluasi berbasis kurva ROC menunjukkan bahwa model *Random Forest* memberikan performa terbaik sebagai model prediktif dengan skor AUC tertinggi yaitu 0.9960, dibandingkan dengan SVM (0.9921). Analisis *feature importance* mengungkapkan bahwa *Interdialytic Weight Gain* (IDWG) dan kadar Hemoglobin adalah dua prediktor paling signifikan dalam menentukan risiko komplikasi tersebut.



Copyright © 2026 The Author(s), Published by Jurnal Informatika dan Teknik Elektro Terapan. This is an open-access article distributed under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0).

Abstract. Heart disease is a frequent complication and a major cause of morbidity in patients undergoing hemodialysis therapy. This study aims to predict the risk of heart disease in hemodialysis patients at RSU Arun by utilizing *Machine Learning* algorithms, specifically *Random Forest* and *Support Vector Machine* (SVM). The total data used consists of 160 patient medical records with 12 initial clinical parameters. The research stages included *data cleansing*, *feature engineering* by adding *Blood Pressure Drop* (*Drop Tensi*) and *Urea-Creatinine Ratio* features, *Exploratory Data Analysis* (EDA), and *hyperparameter tuning* using *GridSearchCV*. The results showed that the dataset has a highly balanced target class distribution, comprising 80 stable patients and 80 patients at risk of complications. Based on performance comparison, both algorithms produced an identical accuracy rate of 96.88%. However, ROC curve-based evaluation demonstrated that the *Random Forest* model provided the best performance as a predictive model with the highest AUC score of 0.9960, compared to SVM (0.9921). *Feature importance* analysis revealed that *Interdialytic Weight Gain* (IDWG) and Hemoglobin levels are the two most significant predictors in determining the risk of these complications.

1. PENDAHULUAN

Penyakit kardiovaskular atau penyakit jantung merupakan salah satu komplikasi paling fatal yang sering dialami oleh pasien penderita gagal ginjal kronis (Chronic Kidney Disease/CKD) yang rutin menjalani terapi hemodialisa. Proses hemodialisa secara terus-menerus sering kali memicu perubahan hemodinamik yang ekstrem pada tubuh pasien. Fluktuasi tekanan darah sebelum dan sesudah proses cuci darah, penarikan cairan tubuh yang berlebihan, serta ketidakseimbangan elektrolit menjadi faktor pemicu utama terjadinya gangguan kardiovaskular. Pemantauan terhadap parameter klinis pasien secara manual sering kali memiliki keterbatasan dalam mendeteksi risiko komplikasi sejak dini, sehingga penanganan medis kadang terlambat diberikan [1]. Perkembangan teknologi informasi, khususnya di bidang *Machine Learning* dan *Data Science*, telah membuka peluang besar bagi dunia medis untuk mengembangkan sistem prediksi risiko penyakit berbasis data historis rekam medis pasien [2]. Pemanfaatan algoritma *Machine Learning* memungkinkan sistem untuk mengenali pola-pola tersembunyi dari parameter klinis pasien yang sangat kompleks [3]. Beberapa algoritma klasifikasi yang terbukti tangguh dalam menangani data medis antara lain Adalah *Random Forest* dan *Support Vector Machine* (SVM) [4].

Berbagai penelitian sebelumnya telah berupaya mengembangkan model prediksi komplikasi pada pasien hemodialisa. Namun, masih terdapat kesenjangan (*gap analysis*) dalam literatur saat ini, di mana sebagian besar model dibangun menggunakan dataset global dan jarang dikalibrasi menggunakan karakteristik populasi lokal dengan penambahan rekayasa fitur (*feature engineering*) klinis spesifik seperti selisih tekanan darah (*Drop Tensi*) dan rasio ureum/kreatinin secara bersamaan. Penelitian ini dilakukan di RSUD Arun untuk mengisi kesenjangan tersebut dengan membangun model prediksi risiko penyakit jantung yang disesuaikan dengan data klinis pasien lokal.

Tujuan utama dari penelitian ini adalah untuk mengimplementasikan, mengoptimasi, dan membandingkan kinerja dari algoritma *Random Forest* dan *Support Vector Machine* dalam memprediksi status risiko pasien hemodialisa (stabil atau berisiko komplikasi) di

RSU Arun. Secara spesifik, penelitian ini berupaya memecahkan masalah identifikasi fitur klinis mana yang paling berpengaruh terhadap risiko komplikasi, serta mencari parameter algoritma terbaik menggunakan metode *GridSearchCV* untuk menghasilkan nilai *Area Under Curve* (AUC) tertinggi. Hasil dari penelitian ini diharapkan dapat menjadi sistem pendukung keputusan klinis (Clinical Decision Support System) bagi tenaga medis di RSUD Arun dalam memprioritaskan penanganan pasien hemodialisa yang memiliki risiko tinggi terkena serangan jantung.

2. TINJAUAN PUSTAKA

Hemodialisa adalah terapi pengganti fungsi ginjal yang menggunakan mesin khusus untuk menyaring sisa metabolisme dan cairan berlebih dari dalam darah [5]. Dalam praktiknya, pemantauan beberapa indikator klinis sangat krusial:

1. IDWG (Interdialytic Weight Gain): Merupakan kenaikan berat badan pasien di antara dua sesi hemodialisa yang berurutan. IDWG yang tinggi menandakan penumpukan cairan yang berlebihan, yang secara langsung membebani kerja jantung [6].
2. Hemoglobin: Kadar protein dalam sel darah merah yang mengikat oksigen. Anemia (kadar hemoglobin rendah) sangat umum terjadi pada pasien hemodialisa dan dapat menyebabkan hipertrofi ventrikel kiri pada jantung [7].
3. Ureum dan Kreatinin: Parameter utama untuk menilai fungsi ginjal. Tingginya kadar ureum dapat menyebabkan uremia yang berdampak buruk pada organ lain, termasuk jantung [8].
4. Tensi Pre dan Post HD: Tekanan darah sebelum dan sesudah hemodialisa sangat memengaruhi perfusi organ. Penurunan tekanan darah secara drastis (*Drop Tensi*) selama proses penarikan cairan sangat berbahaya dan dapat memicu iskemia miokard [9].

Algoritma Machine Learning yang digunakan didalam penelitian ini Adalah:

1. *Random Forest*: Adalah metode *ensemble learning* yang membangun banyak *Decision Tree* pada saat pelatihan dan mengeluarkan kelas yang merupakan modus dari kelas masing-masing pohon individu [10]. Metode

ini sangat kuat mengatasi *overfitting* dan handal dalam menangani data medis yang non-linear [11].

2. *Support Vector Machine* (SVM): Algoritma yang bekerja dengan mencari *hyperplane* atau garis pemisah optimal antar kelas data dalam ruang berdimensi tinggi [12]. SVM menggunakan berbagai jenis kernel (seperti *linear*, *polynomial*, dan *RBF*) untuk menangani data yang tidak dapat dipisahkan secara linear [13].
3. *Hyperparameter Tuning: GridSearchCV* adalah metode optimasi untuk mencari kombinasi *hyperparameter* terbaik dari sebuah model *Machine Learning* dengan melakukan pencarian secara menyeluruh (*exhaustive search*) pada *grid* nilai parameter yang telah ditentukan sebelumnya [14]. Proses ini dipadukan dengan teknik *Cross-Validation* (CV) untuk memastikan model dievaluasi secara obyektif dan menghindari *overfitting* [14].

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimental dan kuantitatif yang berfokus pada penerapan teknik *Data Science* terstruktur. Dataset yang digunakan merupakan rekam medis pasien hemodialisa dari RSUD Arun. Penelitian ini dilaksanakan menggunakan bahasa pemrograman Python beserta pustaka standar seperti Pandas, NumPy, Scikit-Learn, Matplotlib, dan Seaborn. Berikut adalah tahapan metode penelitian yang digunakan:

3.1. Pengumpulan dan Pembersihan Data (Data Cleansing)

Dataset awal yang dimuat dari file *Data_Hd_Arun.csv* memiliki ukuran sebanyak 160 baris dan 12 kolom. Pada tahap *Data Cleansing*, dilakukan pengecekan terhadap nilai kosong (*missing values*). Hasil analisis awal menunjukkan bahwa seluruh kolom (*age*, *sex*, *Tensi Pre HD*, *Tensi Post HD*, *IDWG*, *Hemoglobin*, *Ureum*, *Kreatinin*, *Riwayat Diabetes*, *Riwayat Hipertensi*, *Lama Bulan HD*, *target*) tidak memiliki data yang kosong (0 *missing values*). Selanjutnya, sistem melakukan pengecekan data duplikat. Jika ditemukan adanya baris data ganda, maka baris tersebut akan dihapus menggunakan fungsi *drop_duplicates()*. Total data bersih yang siap digunakan setelah proses ini adalah tetap 160

baris dan 12 kolom.

3.2. Rekayasa Fitur (Feature Engineering)

Untuk memperkaya informasi yang dapat dipelajari oleh model, dilakukan proses rekayasa fitur khusus untuk pasien hemodialisa. Dua fitur klinis baru ditambahkan ke dalam dataset:

4. *Drop_Tensi*: Fitur ini merepresentasikan anjloknya tensi pasien setelah cuci darah. Fitur ini dihitung dengan formula mengurangi nilai *Tensi_Pre_HD* dengan *Tensi_Post_HD*.
5. *Rasio_Ur_Cr*: Fitur ini digunakan untuk menilai efektivitas saringan mesin hemodialisa. Perhitungannya dilakukan dengan membagi nilai *Ureum* dengan *Kreatinin*, yang kemudian dibulatkan hingga dua angka desimal.

3.3. Exploratory Data Analysis (EDA)

Tahap ini bertujuan untuk menganalisis karakteristik statistik dan visualisasi distribusi data pasien. Distribusi kelas target divisualisasikan menggunakan diagram batang (*countplot*) untuk melihat keseimbangan antara pasien stabil dan pasien berisiko komplikasi. Selain itu, histogram distribusi kenaikan berat badan (*IDWG*) antara pasien berisiko dan stabil divisualisasikan untuk melihat pola kepadatan (*density*) data. Terakhir, *Heatmap* korelasi Spearman/Pearson dihasilkan untuk melihat kekuatan hubungan matematis antar seluruh parameter klinis pasien.

3.4. Pembagian dan Penskalaan Data (Split & Scaling)

Data dipisahkan menjadi dua variabel utama: variabel *prediktor* (X) yang berisi seluruh fitur klinis, dan variabel *target* (y) yang berisi status kondisi pasien. Data kemudian dibagi menjadi data latih (*training data*) dan data uji (*testing data*) menggunakan metode *train_test_split* dengan rasio 80:20 dan *random_state=42*. Pembagian ini menghasilkan 128 data latih dan 32 data uji. Untuk menghindari bias akibat skala nilai parameter yang berbeda-beda (misalnya rentang tensi yang ratusan vs hemoglobin yang belasan), dilakukan normalisasi data menggunakan metode *StandardScaler*.

3.5. Pelatihan dan Optimasi Model (Modeling)

Dua algoritma diterapkan untuk memprediksi target:

1. *Random Forest*: Dilatih dan dioptimasi menggunakan *GridSearchCV*. Proses pencarian ditekankan untuk mengejar nilai *roc_auc* tertinggi menggunakan skema *5-fold cross-validation* (*cv=5*). *Grid* parameter yang diuji meliputi *max_depth* (5, 10, 15), *min_samples_leaf* (2, 5, 10), dan *n_estimators* (50, 100, 150).
2. *Support Vector Machine* (SVM): Diinisialisasi terlebih dahulu sebagai model baseline dengan kernel '*rbf*' dan *probability=True* untuk mendapatkan skor *AUC*. Selanjutnya, dilakukan optimasi SVM dengan *GridSearchCV* menggunakan metrik *scoring AUC*. Parameter *grid* yang diuji meliputi C (0.1, 1, 10, 100), kernel ('*rbf*', '*linear*', '*poly*'), dan gamma ('*scale*', '*auto*').

4. HASIL DAN PEMBAHASAN

Pada Bagian ini akan menguraikan secara komprehensif hasil temuan eksplorasi data, pelatihan model, serta evaluasi komparatif dari kinerja ketiga algoritma klasifikasi yang digunakan untuk memprediksi risiko penyakit jantung pasien hemodialisa di RSUD Arun.

4.1. Analisis Eksplorasi Data (EDA)

Berdasarkan statistik deskriptif dari 160 sampel pasien, didapatkan rata-rata usia pasien adalah 51.41 tahun, dengan usia termuda 17 tahun dan tertua 80 tahun. Rata-rata tensi darah sebelum hemodialisa (Tensi_Pre_HD) berada di angka 142.61 mmHg, sedangkan pasca hemodialisa (Tensi_Post_HD) menurun menjadi rata-rata 125.77 mmHg. Nilai rata-rata IDWG terpantau pada angka 3.51 kg, dan rata-rata kadar Hemoglobin berada di bawah ambang batas normal sehat yaitu 9.66 g/dL. Hal ini menunjukkan karakteristik klinis yang sangat umum ditemukan pada pasien cuci darah kronis. Pada visualisasi distribusi target, didapatkan hasil yang sangat ideal bagi pemodelan klasifikasi. Dari 160 data, kondisi pasien terdistribusi secara seimbang sempurna (*perfectly balanced*), di mana terdapat 80 pasien (50%) berada dalam kondisi Stabil/Aman (Target = 0), dan 80 pasien (50%) lainnya terklasifikasi sebagai Berisiko Komplikasi (Target = 1). Keseimbangan kelas ini

memastikan bahwa model *Machine Learning* yang dibangun tidak akan mengalami bias kelas minoritas. Visualisasi tambahan pada distribusi berat badan (IDWG) mengungkapkan bahwa pasien yang berisiko komplikasi cenderung mendominasi pada rentang nilai IDWG yang lebih tinggi dibandingkan pasien yang stabil.

Analisis *Heatmap* korelasi berhasil mengungkap hubungan linear antar fitur klinis. Fitur target (kondisi berisiko komplikasi) memiliki nilai korelasi positif yang kuat terhadap IDWG (0.46) dan Hemoglobin (0.73). Terdapat pula korelasi yang sangat kuat antara fitur rekayasa yang dibuat, seperti Drop_Tensi dengan Tensi_Pre_HD sebesar 0.76. Selain itu, korelasi nyaris sempurna (0.90) teridentifikasi antara Kreatinin dan Ureum, yang sesuai dengan logika medis bahwa keduanya merupakan biomarker fungsi penyaringan ginjal yang bergerak seiringan.

4.2. Hasil Optimasi dan Evaluasi Model Random Forest

Algoritma *Random Forest* yang dioptimasi dengan *GridSearchCV* berhasil menemukan parameter terbaik untuk memprediksi data pasien hemodialisa, yaitu: *max_depth* sebesar 5, *min_samples_leaf* sebesar 2, dan jumlah pohon keputusan (*n_estimators*) sebanyak 50. Penerapan parameter optimal ini menghasilkan performa akurasi yang sama dengan *model baseline DT* yaitu 96.88% (0.9688). Berdasarkan *Confusion Matrix*, *RF Optimized* juga menebak tepat 14 pasien stabil dan 17 pasien berisiko, dengan 1 misklasifikasi pada pasien yang aslinya berisiko namun ditebak stabil. Nilai rata-rata makro untuk *precision*, *recall*, dan *f1-score* juga stabil di angka 0.97. Meskipun akurasi klasifikasi tampak serupa, keunggulan *Random Forest* terletak pada kemampuannya untuk mendistribusikan probabilitas prediksi secara lebih meyakinkan, yang nantinya diukur melalui nilai *AUC Score*.

4.3. Hasil Optimasi dan Evaluasi Model Support Vector Machine (SVM)


Pelatihan awal menggunakan *SVM Baseline* (dengan kernel RBF) berhasil mencetak akurasi sebesar 96.88% dengan nilai *AUC* 0.9960. Untuk memaksimalkan performa, dilakukan *tuning SVM* melalui *GridSearchCV* yang kemudian menemukan parameter terbaik berupa: parameter regularisasi C sebesar 0.1,

parameter *gamma* berjenis '*scale*', dan fungsi pemisah batas (*kernel*) berbentuk garis lurus atau '*linear*'. *Cross-Validation* (CV) terbaik selama proses *grid search* SVM mencapai skor 0.9988. Namun, saat dievaluasi pada data uji (*testing*), model SVM yang dioptimasi ini mencatatkan tingkat akurasi sebesar 0.9688 dengan struktur *Confusion Matrix* yang sama identik: 14 *True Negative*, 0 *False Positive*, 1 *False Negative*, dan 17 *True Positive*. Metrik *precision* untuk kelas 0 (0.93) dan kelas 1 (1.00) serta *recall* (1.00 untuk kelas 0, dan 0.94 untuk kelas 1) tidak berubah.

4.4. Komparasi Keseluruhan Model dan Analisis Kurva ROC

Tabel komparasi mengkonsolidasikan performa dari ketiga model yang dievaluasi. Berikut adalah rincian perbandingan metrik dari ketiga algoritma (dibulatkan menjadi 4 desimal standar jurnal):

Tingkat Akurasi, Presisi, Recall



Gambar 1. Komparasi Performa

(Sensitivitas), dan *F1-Score* menghasilkan angka yang seragam di antara ketiga algoritma tersebut. Hal ini mengindikasikan bahwa batas klasifikasi biner dari dataset ini cukup jelas sehingga ketiga model mencapai tingkat klasifikasi keras (*hard classification*) yang ekuivalen.


Namun, pengukuran sensitivitas probabilitas melalui analisis kurva ROC (*Receiver Operating Characteristic*) mengungkapkan adanya perbedaan kualitas keyakinan tebakan (*confidence*) dari masing-masing model. Plot

kurva ROC membandingkan *True Positive Rate* (TPR) terhadap *False Positive Rate* (FPR). Pada kurva tersebut terlihat bahwa *Random Forest (Optimized)* menduduki peringkat pertama dengan nilai AUC sebesar 0.9960. Sedangkan SVM (*Optimized*) di tempat kedua dengan AUC 0.9921. Model dengan AUC tertinggi, yaitu Random Forest Optimized, dideklarasikan sebagai algoritma yang paling baik dan direkomendasikan untuk digunakan dalam mendiagnosis risiko jantung pasien hemodialisa.

4.5. Analisis Parameter Klinis Paling Berpengaruh (*Feature Importance*)

Untuk memahami dasar keputusan klinis dari model terbaik, dilakukan ekstraksi nilai pengaruh fitur (*Feature Importance*) dari algoritma *Random Forest Optimized*. Hasil visualisasi grafik batang horizontal menunjukkan tingkat signifikansi masing-masing parameter klinis pasien dalam memprediksi status komplikasi.

Temuan ini secara eksplisit menegaskan bahwa berat badan interdialitik (IDWG), kondisi hemodinamik (tekanan darah sebelum



Gambar 2. Parameter Klinis Paling Berpengaruh

dan sesudah HD), serta kadar Hemoglobin memegang peranan klinis yang jauh lebih vital dibandingkan faktor demografis pasien seperti umur (*age*) maupun jenis kelamin (*sex*). Selain itu, riwayat penyakit komorbid seperti diabetes dan hipertensi ternyata menyumbangkan skor yang relatif kecil pada dataset ini. Temuan dari analisis ini menjadi landasan ilmiah medis yang kuat bahwa regulasi cairan pasien dan pengelolaan anemia mutlak diutamakan.

Sebagai langkah akhir dari penelitian eksperimental ini, probabilitas dari kelas 1 (Berisiko komplikasi) dihitung dalam satuan persentase. Seluruh hasil prediksi dari model *Random Forest* terbaik beserta angka keyakinan probabilitasnya diekspor ke dalam sebuah *file* CSV baru bernama *Data_Hd_Arun.csv*. File rekam medis baru ini selanjutnya dapat digunakan secara langsung oleh tim medis di RSUD Arun untuk melakukan triase (*triage*) prioritas penanganan.

5. KESIMPULAN

Berdasarkan hasil analisis komparatif dan pengujian algoritma *Machine Learning* untuk memprediksi risiko penyakit jantung pasien hemodialisa di RSUD Arun, dapat disimpulkan beberapa poin penting sebagai berikut:

- a. Tahap *Exploratory Data Analysis* (EDA) memastikan bahwa dataset pasien sangat proporsional dengan rasio 50:50 (80 stabil, 80 berisiko), yang sangat mendukung integritas pelatihan model prediksi tanpa perlu dilakukan proses *resampling*.
- b. Kedua model klasifikasi (*Random Forest* teroptimasi, dan *SVM* teroptimasi) berhasil membukukan nilai akurasi klasifikasi akhir yang identik, yaitu mencapai 96.88% saat dievaluasi menggunakan data uji (*testing*).
- c. Model *Random Forest* (Optimized) ditetapkan sebagai model terbaik dalam penelitian ini. Melalui *tuning parameter* ($n_estimators=50$, $max_depth=5$, $min_samples_leaf=2$), algoritma ini menjuarai komparasi melalui metrik *Area Under Curve* (AUC) tertinggi yang mencapai 0.9960.
- d. Berdasarkan ekstraksi nilai *Feature Importance*, temuan klinis terpenting menunjukkan bahwa parameter IDWG (0.2645), Hemoglobin (0.2609), Tensi *Post* HD (0.1518), dan Tensi *Pre* HD (0.1089). merupakan fitur prediktor utama dalam menentukan seberapa besar risiko komplikasi penyakit jantung pada pasien hemodialisa.

Sistem yang dibangun memiliki potensi keilmuan dan praktis yang sangat besar untuk diintegrasikan lebih lanjut menjadi *Clinical Decision Support System* yang cerdas pada instalasi rawat jalan rumah sakit setempat. Pengembangan di masa depan disarankan untuk menggabungkan variasi data longitudinal

(runtun waktu) demi mendeteksi tren perburukan klinis bulanan pasien.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada tim medis dan manajemen RSUD Arun khususnya pada perawat ruangan Hemodialisa yang telah mengizinkan dan menyediakan dukungan data demi terselenggaranya penelitian ini. Ucapan terima kasih juga ditujukan kepada orang tua, pakcik, dan teman-teman penulis yang terus mendukung atas pendapat penulis saat ingin melakukan penelitian ini.

DAFTAR PUSTAKA

- [1] J. P. L. Macêdo, C. Hassig, and O. K. F. L., "Cardiovascular complications in chronic kidney disease patients undergoing hemodialysis: A systematic review," *J. Cardiovasc. Med.*, vol. 45, no. 3, pp. 211–225, 2021.
- [2] J. Qin, L. Chen, Y. Liu, C. Liu, C. Feng, and B. Chen, "A machine learning methodology for diagnosing chronic kidney disease," *IEEE Access*, vol. 8, pp. 20991–21002, 2020.
- [3] D. B. F. M. Silva, A. M. Silva, and E. R. Silva, "Comparative analysis of classification algorithms for cardiovascular disease prediction," *Comput. Biol. Med.*, vol. 115, no. 5, pp. 427–435, 2019.
- [4] K. T. V. Nguyen, "Hemodialysis principles and fluid management," *Clin. Nephrol.*, vol. 22, no. 4, pp. 312–320, 2020.
- [5] S. Y. Lee, H. J. Kim, and Choi Y. C., "Predictive modeling of cardiovascular events in end-stage renal disease using artificial neural networks," *Artif. Intell. Med.*, vol. 104, no. 11, pp. 4679–4686, 2020.
- [6] S. Sezer, F. N. Özdemir, Z. Arat, Ö. Perim, M. Turan, and M. Haberal, "THE ASSOCIATION OF INTERDIALYTIC WEIGHT GAIN WITH NUTRITIONAL PARAMETERS AND MORTALITY RISK IN HEMODIALYSIS PATIENTS," *Ren. Fail.*, vol. 24, no. 1, pp. 37–48, 2002.
- [7] Z. Xu, Y. Yue, M. Xu, L. Qian, and L. Dou, "The role of cut-off values for creatinine, blood urea nitrogen, and uric acid in prognostic assessment of chronic heart failure: a retrospective cohort study," *BMC Cardiovasc. Disord.*, vol. 25, no. 1, 2025.
- [8] L. G. G. Dantas, M. De Seixas Rocha, J. A. M. Junior, E. L. Paschoalin, S. R. K. P. Paschoalin, and C. M. Sampaio Cruz, "Non-adherence to

- Haemodialysis, Interdialytic weight gain and cardiovascular mortality: a cohort study,” *BMC Nephrol.*, vol. 20, no. 1, 2019.
- [9] A. V. Zoccali, C. F. M. R. A. C., and P. R. M. F., “Urea and creatinine levels as predictors of cardiac failure in CKD,” *Nephrol. Dial. Transplant.*, vol. 35, no. 11, 2020.
- [10] S. S. Elfaretta, A. A. Arifiyanti, and A. S. Fitri, “KLASIFIKASI CALON PENDONOR DARAH POTENSIAL MENGGUNAKAN ALGORITMA DECISION TREE DI UTD PMI KOTA SURABAYA,” *JITET (Jurnal Inform. dan Tek. Elektro Ter.)*, vol. 12, no. 3, 2024.
- [11] C. Cortes and V. Vapnik, “Support-vector networks,” *Machine Learning, Physiol. Behav.*, vol. 20, no. 3, pp. 139–148, 2020.
- [12] S. Sriani and Y. Rizky, “Klasifikasi Kualitas Daun Tembakau Menggunakan Glcm (Gray Level Co-Occurrence Matrix) Dan Svm (Support Vector Machine),” *JITET (Jurnal Inform. dan Tek. Elektro Ter.)*, vol. 12, no. 3, pp. 3342–3349, 2024.
- [13] M. Hendrix, A. Abernethy, S. Sloane, P. Misuraca, P. W. and K. M. George, and Y. Pylayeva-Gupta, “Support vector machines in clinical predictive modeling,” *J. Biomed.*, vol. 110, no. 1, pp. 1–7, 2020.
- [14] T. I. Chang *et al.*, “Grid search optimization for hyperparameter tuning in machine learning algorithms,” *Nephrol. Dial. Transplant.*, vol. 182, no. 45, pp. 23–28, 2019.