

Analisis prediksi mortalitas pada pasien gagal jantung menggunakan perbandingan algoritma support vector machine dan k-nearest neighbors

Siti Nur Maghfiroh

program studi Teknik Informatika, Universitas Islam Negeri Maulana Malik Ibrahim Malang,
e-mail: 220605110036@student.uin-malang.ac.id

Kata Kunci:

gagal jantung, prediksi mortalitas, Support Vector Machine, K-Nearest Neighbors, machine learning

Keywords:

heart failure, mortality prediction, Support Vector Machine, K-Nearest Neighbors, machine learning

ABSTRAK

Gagal jantung merupakan salah satu penyebab utama kematian di dunia sehingga diperlukan metode prediksi yang akurat untuk mendukung deteksi dini dan pengambilan keputusan medis. Penelitian ini bertujuan membandingkan performa algoritma Support Vector Machine (SVM) dan K-Nearest Neighbors (KNN) dalam memprediksi mortalitas pasien gagal jantung. Dataset yang digunakan adalah Heart Failure Clinical Records Dataset yang terdiri dari 299 data pasien dengan 13 fitur klinis, termasuk usia, fraksi ejeksi jantung, kadar kreatinin, tekanan darah tinggi, anemia, dan status merokok. Proses penelitian meliputi pra-pemrosesan data, standardisasi fitur, pelatihan model, serta evaluasi menggunakan akurasi, presisi, recall, F1-score, dan balanced accuracy. Hasil menunjukkan bahwa SVM unggul dengan akurasi 0,80, precision 0,84, recall 0,70, dan F1-score 0,72, sedangkan KNN hanya mencapai akurasi 0,68 dan F1-score 0,52. Temuan ini menegaskan bahwa SVM lebih andal dalam mendeteksi risiko mortalitas pada pasien gagal jantung, terutama pada kondisi data yang tidak seimbang. Penelitian ini diharapkan dapat menjadi rujukan untuk pengembangan sistem pendukung keputusan medis berbasis machine learning, sehingga tenaga kesehatan dapat melakukan intervensi lebih dini dan tepat sasaran.

ABSTRACT

Heart failure is one of the leading causes of mortality worldwide, requiring accurate prediction methods to support early detection and medical decision-making. This study compares the performance of Support Vector Machine (SVM) and K-Nearest Neighbors (KNN) algorithms in predicting mortality among heart failure patients. The dataset used is the Heart Failure Clinical Records Dataset, consisting of 299 patient records with 13 clinical features, including age, ejection fraction, creatinine level, hypertension, anemia, and smoking status. The research process involved data preprocessing, feature standardization, model training, and evaluation using accuracy, precision, recall, F1-score, and balanced accuracy. The results indicate that SVM achieved superior performance with 0.80 accuracy, 0.84 precision, 0.70 recall, and 0.72 F1-score, while KNN reached only 0.68 accuracy and 0.52 F1-score. These findings demonstrate that SVM is more reliable in detecting mortality risk in heart failure patients, especially under imbalanced data conditions. This research provides valuable insights for the development of machine learning-based medical decision support systems, enabling healthcare professionals to perform earlier and more targeted interventions.

Pendahuluan

Gagal jantung merupakan salah satu penyebab utama kematian di seluruh dunia dan menjadi beban signifikan bagi sistem pelayanan kesehatan. Menurut World Health Organization (WHO), jumlah penderita penyakit kardiovaskular meningkat setiap tahun,



This is an open access article under the [CC BY-NC-SA license](#).

Copyright © 2023 by Author. Published by Universitas Islam Negeri Maulana Malik Ibrahim Malang.

dengan tingkat mortalitas yang tinggi terutama pada kasus gagal jantung yang tidak terdeteksi sejak dini. Dalam era digital saat ini, kemajuan teknologi informasi dan analisis data memungkinkan dilakukannya prediksi kondisi medis secara lebih cepat dan akurat. Oleh karena itu, pemanfaatan teknik pembelajaran mesin (*machine learning*) menjadi pendekatan yang menjanjikan dalam mendukung diagnosis dan pengambilan keputusan klinis, khususnya dalam deteksi dini risiko gagal jantung. Meskipun terdapat berbagai algoritma *machine learning* yang dapat digunakan untuk klasifikasi kondisi medis, efektivitas masing-masing metode sangat bergantung pada karakteristik data dan parameter model yang digunakan. Dua algoritma yang banyak digunakan untuk klasifikasi medis adalah *Support Vector Machine (SVM)* dan *K-Nearest Neighbors (KNN)* (Maulidan et al., 2023). Namun, dalam prakteknya, belum terdapat kesepakatan algoritma mana yang memberikan kinerja terbaik untuk kasus prediksi gagal jantung. Oleh karena itu, diperlukan studi komparatif yang sistematis untuk mengevaluasi performa kedua algoritma tersebut dalam konteks prediksi gagal jantung berbasis data medis.

Sebagian besar penelitian sebelumnya lebih banyak memfokuskan pada penggunaan satu algoritma saja atau membandingkan secara umum tanpa memperhatikan aspek optimasi dan tuning parameter secara menyeluruh. Selain itu, masih terbatas penelitian yang membandingkan *SVM* dan *KNN* secara langsung pada dataset gagal jantung yang sama dengan metrik evaluasi yang lengkap seperti akurasi, presisi, recall, dan F1-score. Kurangnya pendekatan evaluasi yang komprehensif dan analisis parameter model menjadi celah yang ingin dijawab melalui penelitian ini. Penelitian ini bertujuan untuk mengoptimalkan proses prediksi gagal jantung dengan membandingkan performa dua algoritma klasifikasi, yaitu *Support Vector Machine* dan *K-Nearest Neighbors*. Evaluasi dilakukan dengan mengukur kinerja kedua algoritma berdasarkan sejumlah metrik evaluasi untuk menentukan metode yang paling efektif dan andal dalam konteks data medis gagal jantung (Adi & Wintarti, 2022).

Penelitian ini memberikan kontribusi ilmiah yang signifikan dalam bidang prediksi kondisi medis, khususnya gagal jantung, melalui pendekatan *machine learning*. Pertama, penelitian ini menyajikan evaluasi komprehensif terhadap performa dua algoritma populer, yaitu *Support Vector Machine (SVM)* dan *K-Nearest Neighbors (KNN)*, dalam mengklasifikasikan risiko gagal jantung berdasarkan data medis. Selain itu, penelitian ini juga menganalisis pengaruh parameter utama pada masing-masing algoritma terhadap akurasi dan stabilitas model, yang dapat menjadi acuan dalam proses tuning model di masa mendatang. Lebih lanjut, hasil penelitian ini memberikan wawasan praktis yang dapat dimanfaatkan dalam pengembangan sistem pendukung keputusan medis berbasis data, sehingga dapat membantu tenaga kesehatan dalam melakukan deteksi dini dan intervensi yang lebih tepat terhadap pasien dengan potensi gagal jantung.

Tinjauan Pustaka

Dalam beberapa tahun terakhir, pemanfaatan algoritma *machine learning* dalam bidang kesehatan, khususnya untuk prediksi penyakit kardiovaskular seperti gagal jantung, telah mengalami peningkatan signifikan. Salah satu algoritma yang banyak digunakan adalah *Support Vector Machine (SVM)* karena kemampuannya dalam

menangani data berdimensi tinggi dan klasifikasi non-linear. Rahman et al. (2023) mengembangkan model prediksi untuk readmisi darurat pada pasien gagal jantung menggunakan data rekam medis elektronik, dan hasilnya menunjukkan bahwa model SVM memiliki kemampuan diskriminatif yang baik dalam mengidentifikasi pasien berisiko tinggi. Di sisi lain, K-Nearest Neighbors (KNN) menjadi pilihan karena sifatnya yang sederhana namun efektif. (Souza & Lima, 2025).mengimplementasikan KNN pada dataset UCI Heart Disease dan menunjukkan akurasi hingga 83,7%, menggunakan seleksi fitur berbasis korelasi untuk meningkatkan performa model [Al-Mashhadani et al., 2022]. Penelitian serupa oleh (Assegie, 2021) juga mendukung efektivitas KNN, dengan hasil akurasi prediksi sebesar 97,07% ketika diterapkan pada dataset gagal jantung yang telah diolah melalui analisis korelasi fitur.

Kelemahan Studi Sebelumnya

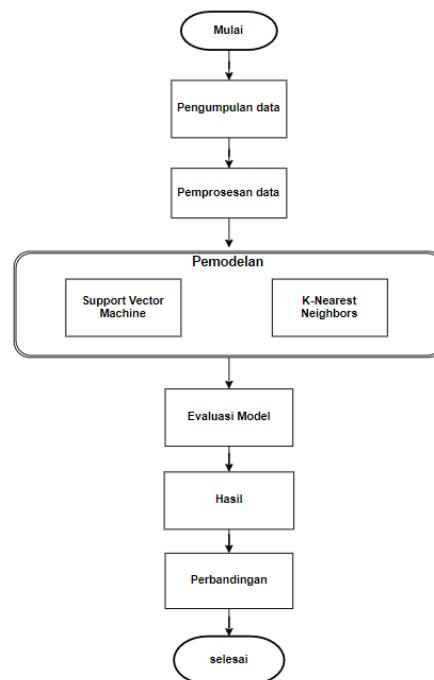
Algoritma Support Vector Machine (SVM) dan K-Nearest Neighbors (KNN) telah banyak diterapkan dalam prediksi gagal jantung, sejumlah keterbatasan masih ditemukan dalam studi-studi sebelumnya, ertama, sebagian besar penelitian hanya mengevaluasi performa satu algoritma secara terpisah tanpa melakukan perbandingan langsung yang terkontrol pada dataset yang sama. Hal ini menyulitkan untuk menarik kesimpulan objektif mengenai kelebihan dan kekurangan masing-masing metode dalam konteks klinis yang seragam. Sebagai contoh, studi oleh Rahman et al. (2023) menerapkan SVM untuk memprediksi readmisi darurat pada pasien gagal jantung, namun tidak membandingkannya secara langsung dengan algoritma lain seperti KNN, Kedua, banyak studi tidak melakukan proses *hyperparameter tuning* secara sistematis, padahal pemilihan parameter sangat memengaruhi performa akhir model, khususnya pada KNN (nilai k) dan SVM (jenis kernel dan parameter C). Sebagai ilustrasi, penelitian oleh (Assegie, 2021) menggunakan KNN untuk prediksi gagal jantung, namun tidak menyebutkan adanya optimasi parameter yang dilakukan. Ketiga, metrik evaluasi yang digunakan sering kali terbatas pada akurasi saja, tanpa memperhitungkan metrik lain seperti precision, recall, F1-score, atau ROC-AUC yang lebih representatif dalam konteks diagnosis medis. Hal ini dapat memberikan gambaran yang kurang lengkap mengenai performa model, terutama dalam mendeteksi pasien berisiko tinggi. Studi oleh (Iacobescu et al., 2024) menekankan pentingnya penggunaan metrik evaluasi yang beragam untuk mendapatkan pemahaman yang lebih komprehensif tentang kinerja model prediktif

Selain itu, sangat sedikit penelitian yang melakukan *hyperparameter tuning* secara sistematis. Padahal, pemilihan parameter sangat mempengaruhi hasil akhir dari model, terutama untuk algoritma seperti KNN (nilai k) dan SVM (kernel, C , dan γ). Ketidakhadiran proses optimasi ini dapat menurunkan akurasi prediksi dan menghasilkan interpretasi yang kurang andal. Dengan mempertimbangkan semua keterbatasan ini, diperlukan studi yang tidak hanya membandingkan dua algoritma secara langsung, tetapi juga melakukan evaluasi dan optimasi model secara menyeluruh untuk meningkatkan akurasi serta keandalan prediksi gagal jantung.

Posisi dan Kunikan Penelitian

Penelitian ini bertujuan untuk mengisi kekosongan dari studi-studi sebelumnya dengan beberapa kontribusi utama. Pertama, penelitian ini melakukan perbandingan langsung dan terkontrol antara algoritma SVM dan KNN dalam konteks prediksi gagal jantung menggunakan dataset yang sama, memungkinkan evaluasi yang adil dan mendalam terhadap masing-masing metode. Kedua, penelitian ini menerapkan proses optimasi parameter (hyperparameter tuning) untuk kedua algoritma guna memperoleh performa maksimal, yang belum banyak dilakukan secara eksplisit dalam penelitian terdahulu. Ketiga, evaluasi kinerja dilakukan dengan menggunakan berbagai metrik seperti akurasi, precision, recall, dan F1-score, sehingga hasil analisis lebih komprehensif dan relevan dalam konteks medis. Terakhir, penelitian ini juga mempertimbangkan aspek ketidakseimbangan data dan dampaknya terhadap performa model, memberikan pendekatan yang lebih realistik terhadap penerapan di dunia nyata. Dengan demikian, penelitian ini tidak hanya memperluas pemahaman akademik mengenai penerapan SVM dan KNN dalam klasifikasi medis, tetapi juga menawarkan panduan praktis untuk pengembangan sistem pendukung keputusan klinis yang andal dan berbasis data.

Pembahasan



Gambar 1

Gambar 1 menunjukkan alur penelitian prediksi mortalitas pada pasien gagal jantung yang dimulai dari pengumpulan dan pemrosesan data klinis. Selanjutnya, data diproses menggunakan dua algoritma klasifikasi, yaitu Support Vector Machine (SVM) dan K-Nearest Neighbors (KNN). Setelah pemodelan, dilakukan evaluasi kinerja masing-masing model menggunakan metrik evaluasi, kemudian hasilnya dianalisis dan

dibandingkan untuk menentukan algoritma yang paling efektif. Proses penelitian diakhiri pada tahap kesimpulan.

Sumber Data atau Dataset

Dataset yang digunakan dalam penelitian ini adalah Heart Failure Clinical Records Dataset yang terdiri dari 299 data pasien penderita gagal jantung. Dataset ini bersumber dari studi publikasi oleh Davide Chicco dan Giuseppe Jurman (2020), dan tersedia secara terbuka melalui [UCI Machine Learning Repository dan Kaggle]. Setiap entri merepresentasikan riwayat klinis pasien, termasuk hasil laboratorium dan catatan medis lainnya. Dataset ini memiliki 13 fitur klinis, di antaranya: usia (*age*), kadar kreatinin serum (*serum creatinine*), fraksi ejeksi jantung (*ejection fraction*), jumlah trombosit (*platelets*), tekanan darah tinggi, status anemia, status merokok, dan hasil akhir pasien death event sebagai label target. Fitur target death event bernilai 1 jika pasien meninggal selama periode observasi, dan 0 jika masih hidup. Secara statistik, rata-rata usia pasien adalah 60,8 tahun, dengan usia tertua mencapai 95 tahun dan termuda 40 tahun. Nilai rata-rata *ejection fraction* berada di angka 38,1%, yang mencerminkan kinerja jantung yang relatif rendah (normalnya di atas 55%). Dataset menunjukkan adanya ketidakseimbangan kelas, di mana 67,9% pasien tidak meninggal dan 32,1% mengalami kematian. Ketidakseimbangan ini menjadi tantangan tersendiri dalam pelatihan model karena risiko bias terhadap kelas mayoritas

Sumber Data atau Dataset

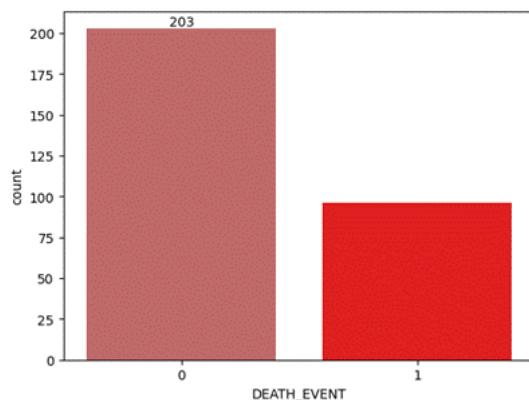
Dataset yang digunakan dalam penelitian ini memuat informasi klinis pasien gagal jantung yang terdiri dari berbagai variabel, seperti usia, status anemia, kadar enzim creatinine phosphokinase (CPK), kondisi diabetes, ejection fraction (persentase darah yang dipompa keluar oleh jantung setiap detak), tekanan darah tinggi, jumlah trombosit, kadar kreatinin dan natrium dalam darah. Selain itu, terdapat data demografis seperti jenis kelamin dan status merokok, serta durasi pemantauan pasien (dalam hari). Label target dalam dataset adalah variabel death event, yang menunjukkan apakah pasien meninggal (1) atau bertahan hidup (0) selama masa observasi. Data ini dianalisis untuk mengevaluasi hubungan antara faktor-faktor tersebut dengan risiko kematian akibat gagal jantung dan digunakan dalam pengembangan model klasifikasi prediktif berbasis algoritma machine learning (Dwi Fasnuari et al., 2022).

	count	mean	std	min	25%	50%	75%	max
<i>age</i>	299.0	60.833893	11.894809	40.0	51.0	60.0	70.0	95.0
<i>anaemia</i>	299.0	0.431438	0.496107	0.0	0.0	0.0	1.0	1.0
<i>creatinine_phosphokinase</i>	299.0	581.839465	970.287881	23.0	116.5	250.0	582.0	7861.0
<i>diabetes</i>	299.0	0.418000	0.494067	0.0	0.0	0.0	1.0	1.0
<i>ejection_fraction</i>	299.0	38.083612	11.834841	14.0	30.0	38.0	45.0	80.0
<i>high_blood_pressure</i>	299.0	0.351171	0.478136	0.0	0.0	0.0	1.0	1.0
<i>platelets</i>	299.0	263358.029264	97804.236869	25100.0	212500.0	262000.0	303500.0	850000.0
<i>serum_creatinine</i>	299.0	1.393880	1.034510	0.5	0.9	1.1	1.4	9.4
<i>serum_sodium</i>	299.0	136.625418	4.412477	113.0	134.0	137.0	140.0	148.0
<i>sex</i>	299.0	0.648829	0.478136	0.0	0.0	1.0	1.0	1.0
<i>smoking</i>	299.0	0.321070	0.467670	0.0	0.0	0.0	1.0	1.0
<i>time</i>	299.0	130.260870	77.614208	4.0	73.0	115.0	203.0	285.0
<i>DEATH_EVENT</i>	299.0	0.321070	0.467670	0.0	0.0	0.0	1.0	1.0

Gambar 2

Pra-Pemrosesan Data

Setelah data klinis pasien gagal jantung dikumpulkan, langkah selanjutnya dalam metode penelitian adalah pra-pemrosesan data yang bertujuan untuk memastikan



bahwa data siap digunakan dalam proses analisis. Berdasarkan pengecekan awal pada dataset, tidak ditemukan adanya nilai yang hilang, sehingga proses dapat langsung dilanjutkan ke tahapan pemisahan variabel fitur dan target. Variabel death event dipisahkan sebagai variabel target, sementara seluruh fitur numerik lainnya digunakan sebagai input model. Karena fitur-fitur dalam dataset memiliki skala yang berbeda-beda, maka dilakukan proses standarisasi agar setiap fitur berada dalam skala yang setara, sehingga tidak ada fitur yang mendominasi proses pembelajaran model. Tahap ini penting untuk meningkatkan kinerja algoritma yang sensitif terhadap skala data, seperti Support Vector Machine (SVM) dan K-Nearest Neighbors (KNN).

Gambar 3 di atas Menunjukkan distribusi variabel target death event dalam dataset gagal jantung, di mana sebanyak 203 pasien tercatat bertahan hidup (death event= 0) dan 96 pasien tercatat meninggal dunia (death event = 1) selama masa observasi. Distribusi ini mencerminkan adanya ketidakseimbangan kelas (data imbalance), karena jumlah pasien yang meninggal jauh lebih sedikit dibandingkan yang bertahan hidup. Kondisi seperti ini penting diperhatikan dalam proses pemodelan, karena dapat menyebabkan model klasifikasi menjadi bias terhadap kelas mayoritas dan mengabaikan kelas minoritas yang justru lebih kritis secara medis. Oleh karena itu, strategi penanganan seperti stratifikasi data, oversampling, atau pemilihan metrik evaluasi yang sensitif terhadap ketidakseimbangan, seperti F1-score dan balanced accuracy, perlu diterapkan untuk menghasilkan model prediktif yang akurat dan adil.

Model Algoritma

Support Vector Machine (SVM)

SVM bekerja dengan mencari sebuah *hyperplane* optimal yang dapat memisahkan dua kelas data dalam ruang fitur. Tujuan utama dari SVM adalah memaksimalkan margin, yaitu jarak antara *hyperplane* dan titik-titik data terdekat dari masing-masing kelas yang disebut sebagai *support vectors*. Metode klasifikasi yang dapat digunakan untuk memprediksi risiko kematian akibat gagal jantung, baik dalam hubungan data yang linier maupun non-linier(Nuraeni & Faisal, 2025). SVM bekerja dengan mencari *hyperplane* terbaik yang memisahkan dua kelas dalam hal ini pasien yang bertahan hidup dan yang

meninggal dengan margin maksimum. Dalam konteks ini, digunakan kernel Radial Basis Function (RBF) yang mampu menangani batas keputusan non-linier antar pasien berdasarkan fitur-fitur klinis seperti usia, kadar kreatinin, dan fraksi ejeksi jantung. Penggunaan SVM adalah untuk menentukan batas pemisah optimal berdasarkan data support vector, sehingga proses klasifikasi hanya bergantung pada titik data penting yang berada di dekat batas klasifikasi. Fungsi kernel yang digunakan memungkinkan pemetaan fitur ke ruang berdimensi lebih tinggi tanpa perlu mengetahui bentuk eksplisit transformasinya, sehingga menjadikannya efektif dalam menangani data kompleks pada klasifikasi medis (Rahmah, 2025).

K-Nearest Neighbors (KNN)

KNN menyimpan seluruh data dan membuat prediksi berdasarkan kemiripan (jarak) antara data uji dan data pelatihan. Dalam klasifikasi, KNN menentukan kelas suatu data baru dengan melihat k data tetangga terdekat (berdasarkan metrik jarak seperti Euclidean) (jabbar et al., 2013), dan memilih kelas mayoritas dari tetangga-tetangga tersebut sebagai hasil prediksi. Metode klasifikasi berbasis instance yang digunakan untuk memprediksi status kematian pasien gagal jantung berdasarkan kedekatan fitur klinis dengan pasien sebelumnya. KNN mengklasifikasikan pasien baru berdasarkan mayoritas kelas dari sejumlah tetangga terdekat dalam ruang fitur, tanpa proses pelatihan eksplisit. Pendekatan ini sangat bergantung pada perhitungan jarak antar data, biasanya menggunakan Euclidean Distance. Hal ini sejalan dengan temuan (Romadhon et al., 2023) yang menjelaskan bahwa kinerja KNN sangat dipengaruhi oleh parameter k yang digunakan serta kualitas data pelatihan, sehingga pemilihan nilai k optimal dapat meningkatkan akurasi klasifikasi. Berikut adalah rumus dari K-Nearest Neighbors yang lebih pendek dan lebih mungkin dianggap sebagai anomali. Berdasarkan panjang jalur ini, model memberikan skor anomali untuk setiap titik data, yang digunakan untuk menentukan apakah transaksi tersebut penipuan atau tidak. Threshold Skor Anomali atau skor anomali digunakan untuk menentukan batas (threshold) di mana transaksi yang memiliki skor lebih tinggi dari nilai tertentu dianggap sebagai penipuan. Threshold ini disesuaikan untuk mencapai keseimbangan yang optimal antara precision dan recall, memastikan bahwa model dapat mendekripsi sebanyak mungkin transaksi penipuan tanpa menghasilkan terlalu banyak false positives.

Evaluasi Hasil

Setelah pemodelan selesai, evaluasi dilakukan untuk mengukur kemampuan model dalam memprediksi risiko kematian akibat gagal jantung. Penilaian dilakukan menggunakan data uji terpisah dengan metrik seperti akurasi, precision, recall, dan F1-score, serta divisualisasikan melalui confusion matrix (Adi & Wintarti, 2022). Untuk memastikan model tidak overfitting dan dapat digeneralisasi dengan baik, data latih juga dibagi menjadi data pelatihan dan validasi. Hasil evaluasi ini digunakan untuk memilih model yang paling akurat dan stabil untuk prediksi klinis.

Pembahasan

Pada penelitian ini, dataset yang digunakan merupakan data klinis pasien gagal jantung yang dikumpulkan dari berbagai sumber medis. Dataset ini terdiri dari 13 atribut

yang mencerminkan kondisi klinis dan riwayat kesehatan pasien, seperti usia, kadar kreatinin serum, fraksi ejeksi jantung, kadar natrium, jumlah trombosit, serta riwayat

	count	mean	std	min	25%	50%	75%	max
age	299.0	5.703353e-16	1.001676	-1.754448	-0.828124	-0.070223	0.771889	2.877170
anaemia	299.0	1.009969e-16	1.001676	-0.871105	-0.871105	-0.871105	1.147968	1.147968
creatinine_phosphokinase	299.0	0.000000e+00	1.001676	-0.576918	-0.480393	-0.342574	0.000166	7.514640
diabetes	299.0	9.060014e-17	1.001676	-0.847579	-0.847579	-0.847579	1.179830	1.179830
ejection_fraction	299.0	-3.267546e-17	1.001676	-2.036387	-0.684180	-0.007077	0.585389	3.547716
high_blood_pressure	299.0	0.000000e+00	1.001676	-0.735688	-0.735688	1.359272	1.359272	
platelets	299.0	7.723291e-17	1.001676	-2.440155	-0.520870	-0.013908	0.411120	6.008180
serum_creatinine	299.0	1.425838e-16	1.001676	-0.865509	-0.478205	-0.284552	0.005926	7.752020
serum_sodium	299.0	-8.673849e-16	1.001676	-5.363208	-0.595999	0.085034	0.766064	2.582144
sex	299.0	-8.911489e-18	1.001676	-1.359272	-1.359272	0.735688	0.735688	
smoking	299.0	-1.188199e-17	1.001676	-0.687682	-0.687682	-0.687682	1.454161	1.454161
time	299.0	-1.901118e-16	1.001676	-1.629502	-0.739000	-0.196954	0.938759	1.997038

hipertensi, diabetes, dan anemia. Selain itu, juga terdapat informasi demografis seperti jenis kelamin dan status merokok. Total terdapat 299 data pasien, di mana masing-masing baris mewakili satu pasien dengan informasi lengkap serta status kematian selama masa observasi yang direpresentasikan oleh variabel death event.

Gambar 4

Pada gambar 4 menunjukkan hasil dari tahap preprocessing yang diawali dengan pengecekan nilai hilang, dan hasilnya menunjukkan bahwa dataset bersih dari missing value. Variabel target death event dipisahkan sebagai y, sementara fitur lainnya disimpan dalam X. Karena seluruh fitur bersifat numerik dan memiliki skala yang bervariasi, dilakukan standardisasi menggunakan StandardScaler untuk memastikan semua fitur berada dalam skala yang seragam sebelum digunakan dalam pemodelan.



Gambar 5

Gambar 5 menunjukkan hasil analisis korelasi pada dataset gagal jantung, variabel serum_creatinine dan age menunjukkan korelasi positif terhadap death event, yang mengindikasikan bahwa pasien dengan usia lebih tua dan kadar kreatinin yang lebih tinggi memiliki risiko kematian yang lebih tinggi. Sebaliknya, variabel ejection_fraction dan time memiliki korelasi negatif terhadap death event, menunjukkan bahwa pasien dengan fungsi pompa jantung yang lebih baik dan masa bertahan hidup yang lebih lama cenderung memiliki kemungkinan kematian yang lebih rendah. Variabel lain seperti

anaemia, diabetes, dan serum_sodium memiliki korelasi yang lemah terhadap death event, yang berarti kontribusinya dalam memprediksi risiko kematian tidak terlalu signifikan. Sementara itu, fitur seperti sex, smoking, dan high_blood_pressure hampir tidak menunjukkan hubungan berarti, sehingga perannya dalam prediksi lebih terbatas berdasarkan data ini.

Evaluasi Model Pada Data Uji

Evaluasi model pada data uji dilakukan untuk membandingkan efektivitas algoritma Support Vector Machine (SVM) dan K-Nearest Neighbors (KNN) dalam memprediksi risiko kematian akibat gagal jantung. Tujuan dari evaluasi ini adalah untuk mengetahui seberapa baik masing-masing model dapat mengklasifikasikan data baru yang belum pernah digunakan pada tahap pelatihan. Dengan menggunakan metrik evaluasi seperti akurasi, precision, recall, dan F1-score, diperoleh gambaran mengenai kelebihan dan kelemahan masing-masing algoritma.

Algoritma Support Vector Machine

	precision	recall	f1-score	support
0	0.78	0.98	0.87	41
1	0.89	0.42	0.57	19
accuracy			0.80	60
macro avg	0.84	0.70	0.72	60
weighted avg	0.82	0.80	0.78	60

Algoritma K-Nearest Neighbors

Accuracy (KNN): 0.6833333333333333

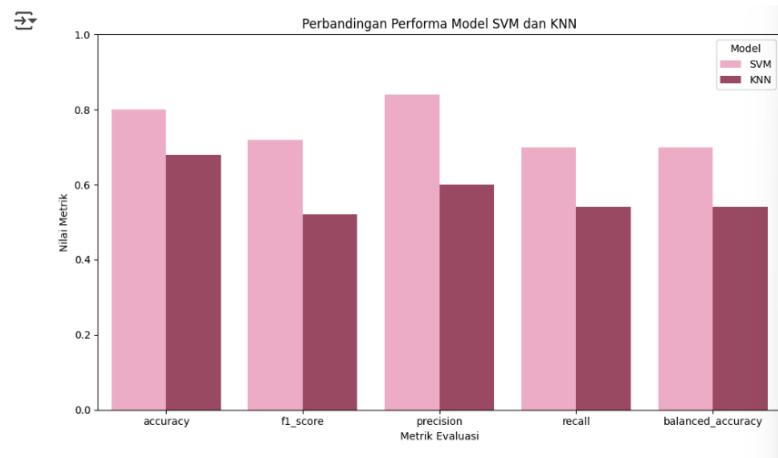
Classification Report (KNN):

	precision	recall	f1-score	support
0	0.70	0.93	0.80	41
1	0.50	0.16	0.24	19
accuracy			0.68	60
macro avg	0.60	0.54	0.52	60
weighted avg	0.64	0.68	0.62	60

Perbandingan Performa Model

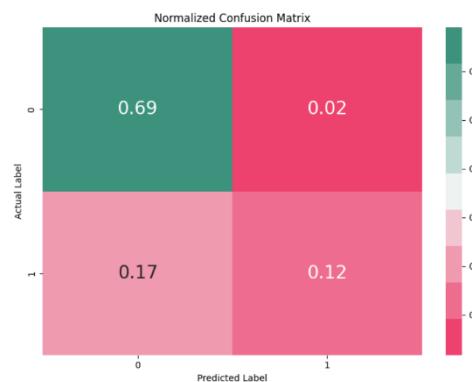
Perbandingan ini didasarkan pada lima metrik evaluasi utama: akurasi, precision, recall, F1-score, dan balanced accuracy, perbandingan ini adalah untuk mengidentifikasi algoritma yang paling tepat dan andal dalam mendukung deteksi dini serta pengambilan keputusan medis pada kasus gagal jantung. Berdasarkan Gambar 1 dan Gambar 2 yang menyajikan metrik evaluasi dari algoritma K-Nearest Neighbors (KNN) dan Support Vector Machine (SVM) dalam klasifikasi gagal jantung, dapat disimpulkan bahwa algoritma SVM memberikan performa yang lebih unggul secara menyeluruhan dibandingkan KNN. Model SVM mencapai nilai akurasi sebesar 0.80, precision 0.84, recall 0.70, dan F1-score 0.72. Angka-angka tersebut menunjukkan bahwa model ini tidak

hanya akurat, tetapi juga seimbang dalam mengenali pasien yang benar-benar berisiko (kelas 1), terutama pada kondisi data yang tidak seimbang. Sebaliknya, KNN hanya mampu meraih akurasi sebesar 0.68, precision 0.60, recall 0.54, dan F1-score 0.52, yang mengindikasikan performa klasifikasi yang lebih rendah dan kurang stabil dalam mengidentifikasi kasus pasien meninggal. Secara keseluruhan, model SVM lebih efektif dan andal dalam mendeteksi risiko gagal jantung dibandingkan model KNN, sehingga



lebih tepat digunakan dalam konteks medis yang memerlukan sensitivitas dan presisi tinggi.

Dari visualisasi tersebut, terlihat bahwa model SVM unggul secara konsisten di seluruh metrik. SVM memiliki tingkat akurasi dan presisi yang lebih tinggi, serta F1-score dan recall yang lebih seimbang, menandakan bahwa model ini tidak hanya mampu memprediksi dengan benar, tetapi juga mempertahankan kinerja yang baik dalam mendeteksi kelas minoritas (pasien yang meninggal). Sementara itu, KNN menunjukkan performa yang lebih rendah, terutama pada metrik recall dan balanced accuracy, yang mengindikasikan keterbatasannya dalam mengenali pasien berisiko tinggi. Performa yang lebih baik dari SVM ini menunjukkan bahwa algoritma tersebut lebih cocok digunakan dalam konteks klinis, khususnya dalam kasus prediksi gagal jantung di mana ketepatan dan sensitivitas terhadap kasus berisiko sangat penting.



Gambar 7 Confussion Matrix Data Uji model svm

Berdasarkan Confusion Matrix yang ditampilkan, hasil klasifikasi pada data uji menunjukkan bahwa model berhasil mengidentifikasi 69% pasien yang tidak mengalami

kematian (death event = 0) secara benar sebagai True Negative. Sebanyak 12% pasien yang benar-benar meninggal juga berhasil diprediksi dengan tepat sebagai True Positive. Namun, terdapat 17% pasien yang sebenarnya meninggal tetapi salah diklasifikasikan sebagai tidak meninggal (False Negative), yang menunjukkan kelemahan model dalam mendeteksi kasus berisiko. Selain itu, hanya sekitar 2% kasus yang merupakan False Positive, yaitu pasien yang tidak meninggal tetapi diprediksi meninggal. Hasil ini menunjukkan bahwa model cukup baik dalam mengenali pasien yang selamat, namun masih menghadapi tantangan dalam mendeteksi pasien yang benar-benar berisiko tinggi, yang krusial dalam konteks prediksi medis.

Perbandingan performa antara algoritma Support Vector Machine (SVM) dan K-Nearest Neighbors (KNN) dalam prediksi gagal jantung menunjukkan bahwa SVM memberikan hasil yang lebih unggul. Berdasarkan evaluasi yang dilakukan, SVM mampu menghasilkan prediksi yang lebih akurat dan seimbang, khususnya dalam mengidentifikasi pasien dengan risiko kematian. Hal ini menjadikan SVM lebih andal dalam menangani karakteristik data medis yang sering kali tidak seimbang antar kelas. Sementara itu, algoritma KNN menunjukkan performa yang lebih rendah pada sebagian besar metrik evaluasi. Kemampuannya dalam mendeteksi kasus positif masih terbatas, sehingga kurang efektif jika diterapkan pada data klinis dengan distribusi kelas yang tidak merata. Oleh karena itu, SVM dinilai lebih tepat untuk digunakan dalam sistem pendukung keputusan medis, khususnya dalam upaya deteksi dini risiko gagal jantung.

Kesimpulan dan Saran

Berdasarkan hasil akhir dari penelitian ini yang membandingkan dua algoritma klasifikasi, yaitu Support Vector Machine (SVM) dan K-Nearest Neighbors (KNN), diperoleh kesimpulan bahwa SVM menunjukkan performa yang lebih baik secara keseluruhan. Model SVM menghasilkan akurasi sebesar 0.80, f1-score 0.72, precision 0.84, recall 0.70, dan balanced accuracy 0.70. Nilai-nilai ini menunjukkan bahwa SVM mampu memberikan prediksi yang akurat dan seimbang, serta cukup andal dalam mengklasifikasikan pasien gagal jantung, khususnya dalam mengenali kasus kematian yang menjadi fokus utama.

Sebaliknya, algoritma KNN menunjukkan performa yang lebih rendah dengan akurasi 0.68, f1-score 0.52, precision 0.60, recall 0.54, dan balanced accuracy 0.54. Meskipun KNN merupakan metode yang sederhana dan mudah diimplementasikan, hasil evaluasi menunjukkan bahwa kemampuannya dalam mendeteksi kasus berisiko masih terbatas jika dibandingkan dengan SVM. Berdasarkan temuan ini, SVM dapat direkomendasikan sebagai metode yang lebih efektif untuk diterapkan dalam sistem pendukung keputusan medis pada prediksi gagal jantung, terutama ketika dibutuhkan model dengan ketepatan dan kestabilan yang baik.

Kontribusi utama dari penelitian ini adalah membuktikan efektivitas Isolation Forest sebagai solusi praktis dan efisien untuk deteksi anomali transaksi, serta memberikan perbandingan yang jelas terhadap metode supervised lainnya. Visualisasi hasil eksperimen juga menegaskan keunggulan model dalam menangani skenario nyata dengan data yang tidak seimbang.

Daftar Pustaka

- Adi, S., & Wintarti, A. (2022). Komparasi Metode Support Vector Machine (Svm), K-Nearest Neighbors (Knn), Dan Random Forest (Rf) Untuk Prediksi Penyakit Gagal Jantung. *MATHunesa: Jurnal Ilmiah Matematika*, 10(2), 258–268. <https://doi.org/10.26740/mathunesa.v10n2.p258-268>
- Assegie, T. A. (2021). Heart disease prediction model with k-nearest neighbor algorithm. *International Journal of Informatics and Communication Technology (IJ-ICT)*, 10(3), 225. <https://doi.org/10.11591/ijict.v10i3.pp225-230>
- Iacobescu, P., Marina, V., Anghel, C., & Anghel, A. D. (2024). Evaluating Binary Classifiers for Cardiovascular Disease Prediction: Enhancing Early Diagnostic Capabilities. *Journal of Cardiovascular Development and Disease*, 11(12), 1–17. <https://doi.org/10.3390/jcdd11120396>
- jabbar, M. A., Deekshatulu, B. L., & Chandra, P. (2013). Classification of Heart Disease Using K- Nearest Neighbor and Genetic Algorithm. *Procedia Technology*, 10, 85–94. <https://doi.org/10.1016/j.protcy.2013.12.340>
- Maulidan, M. I., Gunawan, G., & Fajar, M. Y. (2023). Perbandingan Algoritma K-Nearest Neighbor, Greedy dan Brute Force dalam Menentukan Rute Pengiriman Barang. *Bandung Conference Series: Mathematics*, 3(1), 35–43. <https://doi.org/10.29313/bcsm.v3i1.6403>
- Nuraeni, N., & Faisal, M. (2025). *Classification of sleep disorders using support vector machine*. 4(1). <https://doi.org/10.22219/kinetik.v10i1.2054>
- Rahmah, M. (2025). *Analisis Sentimen Berbasis Aspek Terhadap Ulasan Pengguna di Treaveloka Menggunakan Metode Support Vector Machine*.
- Romadhon, M. R., Faisal, M., & Imamudin, M. (2023). Improving The Performance of the K-Nearest Neighbor Algorithm in the Selection of KIP Scholarship Recipients. *Jurnal Riset Informatika*, 5(4), 465–470. <https://doi.org/10.34288/jri.v5i4.575>
- Souza, V. S., & Lima, D. A. (2025). Cardiac Disease Diagnosis Using K-Nearest Neighbor Algorithm: A Study on Heart Failure Clinical Records Dataset. *Artificial Intelligence and Applications*, 3(1), 56–71. <https://doi.org/10.47852/bonviewAIA42022045>