

PREDIKSI KELANGSUNGAN HIDUP PASIEN GAGAL JANTUNG MENGGUNAKAN PENDEKATAN *MACHINE LEARNING* DENGAN OPTIMASI *GRID SEARCHCV*

Sri Mulyani¹, Toni Arifin²

¹Sistem Informasi, Fakultas Teknologi Informasi, Universitas Adhirajasa Reswara Sanjaya, Indonesia

²Teknik Informatika, Fakultas Teknologi Informasi, Universitas Adhirajasa Reswara Sanjaya, Indonesia

¹srin61102@gmail.com, ²toni.arifin@ars.ac.id

Abstrak

Gagal jantung menjadi salah satu penyebab utama tingginya angka kematian secara global, termasuk di Indonesia. Deteksi dini sangat *krusial* untuk mencegah *progresivitas* penyakit, tetapi pendekatan secara konvensional kerap memiliki keterbatasan hasil akurasi. Penelitian ini memiliki tujuan untuk meningkatkan akurasi prediksi terhadap kelangsungan hidup pasien dengan kondisi gagal jantung melalui proses optimasi algoritma *Machine Learning* menggunakan teknik penyesuaian *Hyperparameter Grid SearchCV*. Dataset yang digunakan pada penelitian ini berasal dari *Heart Failure Clinical Records Dataset* yang tersedia secara publik pada *website UCI Machine Learning Repository*, yang mencakup 299 data rekam medis pasien penderita gagal jantung dengan 13 atribut klinis. Penelitian ini menggunakan enam algoritma *Machine Learning*, yang terdiri dari *Random Forest*, *Decision Tree*, *Neural Network*, *K-Nearest Neighbors (K-NN)*, *Support Vector Machine (SVM)*, dan *Naïve Bayes*. Hasil evaluasi menunjukkan bahwa algoritma *Random Forest* menghasilkan akurasi tertinggi, yaitu sebesar 87%, sebelum dilakukan proses optimasi. Peningkatan performa dicapai dengan *Grid SearchCV*, menghasilkan akurasi akhir sebesar 95%. Temuan ini membuktikan bahwa optimasi menggunakan *Hyperparameter* mampu meningkatkan kinerja model klasifikasi secara signifikan. Implementasi hasil penelitian dapat mendukung rumah sakit dan layanan kesehatan dalam meningkatkan ketepatan diagnosis dini serta pemantauan pasien. Selain itu, studi ini menjadi referensi pengembangan sistem prediksi medis berbasis *Machine Learning* yang lebih mutakhir di masa depan.

Kata kunci: Gagal Jantung, Klasifikasi, *Random Forest*, Parameter Optimasi, *Grid SearchCV*

1. Pendahuluan

Gagal jantung merupakan kondisi yang sering dijumpai di masyarakat dan menjadi salah satu penyebab utama kematian secara global (Arisandi, 2023). Penyakit ini mengalami perkembangan secara perlahan dan ditandai dengan tingginya tingkat kematian (*mortalitas*) serta angka kesakitan (*morbiditas*), yang terjadi baik di negara-negara maju maupun berkembang, termasuk Indonesia (Novaldy & Herliana, 2021). Pada tahun 2013, Indonesia mencatat sedikitnya 883.447 orang yang didiagnosis menderita penyakit gagal jantung dengan mayoritas dari mereka berusia antara 55 hingga 64 tahun. Persentase kematian yang disebabkan oleh penyakit jantung juga tergolong tinggi yaitu sekitar 45% dari total kematian di Indonesia (Subarkah et al., 2022). Di tingkat global, Asosiasi Jantung Dunia melaporkan 1,8 juta kematian akibat gagal jantung di Asia Tenggara pada 2014 (Julia et al., 2023). Peningkatan jumlah kasus gagal jantung dan dampak serius yang ditimbulkan membuat kita perlu mencari cara yang lebih baik untuk mendeteksi dan mengelola penyakit ini sedini mungkin.

Proses untuk mendeteksi gagal jantung kini bisa dilakukan melalui pendekatan *Machine Learning* (Prasetyo, 2023). *Machine Learning* adalah bagian dari kecerdasan buatan yang berfokus pada pembuatan algoritma dan model. Tujuannya adalah agar komputer bisa belajar dari data dan membuat prediksi atau keputusan tanpa perlu pemrograman yang jelas (Taye, 2023). Dalam beberapa tahun terakhir, *Machine Learning* telah menjadi alat penting dalam bidang kesehatan, terutama untuk prediksi dan diagnosis penyakit menggunakan salah satu cara yaitu dengan penerapan teknik klasifikasi (Doni et al., 2021). Teknik ini digunakan untuk memisahkan data ke dalam kelompok atau kategori tertentu sesuai dengan ciri atau sifat tertentu (Rahayu et al., 2024). Beberapa algoritma klasifikasi yang umum digunakan antara lain *Logistic Regression*, *Support Vector Machine (SVM)*, *K-Nearest Neighbors (KNN)*, *Naïve Bayes*, *Decision Tree*, dan *Random Forest* (Bharti et al., 2021).

Algoritma *Random Forest* merupakan salah satu algoritma yang umum digunakan dalam penerapan teknik klasifikasi. Salah satu kelebihan utama dari algoritma *Random Forest* adalah kemampuannya

dalam menangani dataset berukuran besar yang mengandung berbagai macam fitur, sehingga algoritma ini efektif dalam mengurangi risiko terjadinya *overfitting*. Selain itu, algoritma ini mampu mempertahankan kinerja yang stabil dan optimal (Siregar et al., 2023). Meskipun *Random Forest* merupakan algoritma yang banyak digunakan, penerapannya tidak lepas dari beberapa kekurangan. Diantaranya adalah proses pemilihan titik pemisah dalam pohon keputusan yang dapat berpotensi menyebabkan *overfitting* dan mengurangi efisiensi algoritma (Huang et al., 2021). Selain itu, ketika dihadapkan pada dataset berukuran besar, *Random Forest* dapat mengalami peningkatan kompleksitas komputasi dan kebutuhan sumber daya yang signifikan (Bhadula et al., 2024). Tantangan lainnya adalah ketidakseimbangan data, yang dapat mempengaruhi kinerja dengan meningkatkan kompleksitas pelatihan dan memicu *overfitting* (Gu et al., 2022), serta akurasi individu pohon yang rendah atau korelasi tinggi antar pohon yang dapat membatasi kinerja model secara keseluruhan (Sun et al., 2024). Kekurangan-kekurangan inilah yang menjadi alasan utama perlunya teknik optimasi *hyperparameter* untuk memaksimalkan akurasi dan kinerja *Random Forest*.

Dalam penelitian ini, *Grid SearchCV* dipilih sebagai metode optimasi. Karena didasarkan pada kemampuannya yang teruji untuk mengeksplorasi semua kombinasi parameter yang telah ditentukan secara sistematis, guna memastikan ditemukannya konfigurasi optimal yang menghasilkan akurasi tertinggi (Subasi, 2024). Pada umumnya, *Grid SearchCV* menggabungkan metode pencarian *grid* yang komprehensif dengan validasi yang *robust* melalui *cross-validation*, sehingga memberikan penilaian kinerja model yang objektif (Arifin et al., 2024). Implementasinya yang terstandarisasi dengan bantuan *library* seperti *Scikit-Learn* juga memastikan proses optimasi dapat dilakukan secara efisien dan andal (Radzi et al., 2021).

Pada penelitian Novaldy dan Herliana (Novaldy & Herliana, 2021), mengembangkan model *Naïve Bayes* yang dioptimasi menggunakan metode *Particle Swarm Optimization (PSO)* guna meningkatkan akurasi dalam memprediksi harapan hidup pasien dengan gagal jantung. Studi ini menggunakan dataset *Heart Failure Clinical Records Dataset* (299 sampel, 13 variabel klinis), dengan *PSO* diterapkan untuk seleksi fitur optimal sebelum klasifikasi. Hasilnya menunjukkan peningkatan yang signifikan yakni akurasi naik dari 75% menjadi 91,67% dan nilai *AUC* meningkat dari 0,847 ke 0,908, mengindikasikan efektivitas model. Validasi dilakukan dengan *Split Validation* (rasio 70:30, 80:20, dan 90:10), untuk memastikan konsistensi hasil. Temuan ini mendukung pengambilan keputusan medis yang lebih presisi.

Selanjutnya penelitian yang dilakukan oleh Ramdhani et al (Ramdhani et al., 2023) membangun

model prediksi kelangsungan hidup pasien gagal jantung menggunakan algoritma *Random Forest* yang dioptimalkan melalui *algoritma genetika* untuk melakukan seleksi fitur pada *Heart Failure Clinical Records Dataset*. Melalui tahapan *preprocessing data* dan evaluasi terhadap berbagai algoritma (*KNN*, *SVM*, *Neural Network*, *Naïve Bayes*, dan *Decision tree*), kombinasi *Random Forest* dan algoritma genetika terbukti unggul dengan mencapai akurasi 93,36% dan *AUC* 0,892, mengatasi keterbatasan ketidakseimbangan data serta mengungguli metode komparasi lainnya. Temuan ini mengindikasikan bahwa penerapan seleksi fitur menggunakan pendekatan algoritma genetika secara substansial mampu meningkatkan akurasi prediksi, sehingga metode ini berpotensi besar untuk mendukung proses diagnosis klinis serta pengambilan keputusan medis yang lebih tepat dan akurat dalam penanganan kasus gagal jantung.


Penelitian ini bertujuan untuk mengevaluasi dan membandingkan performa enam algoritma klasifikasi yang berbeda dalam mengolah *Heart Failure Clinical Records Dataset*, dengan fokus utama untuk mengidentifikasi algoritma yang paling optimal dalam melakukan klasifikasi data medis. Evaluasi komparatif ini menjadi landasan penting dalam menentukan model yang paling sesuai untuk kasus gagal jantung. Selain itu, penelitian ini secara khusus mengkaji peningkatan tingkat akurasi prediksi melalui penerapan teknik optimasi parameter menggunakan *Grid SearchCV* yang diimplementasikan pada algoritma yang memiliki akurasi paling optimal. Pendekatan ini diharapkan tidak hanya mampu meningkatkan performa klasifikasi, tetapi juga memberikan kontribusi signifikan dalam pengembangan sistem pendukung keputusan klinis yang lebih presisi dan andal dalam penanganan kasus gagal jantung.

Berdasarkan uraian tentang permasalahan diatas, dapat diambil kesimpulan bahwa perlu melakukan pencegahan sejak dini. Dengan menggunakan algoritma yang telah melalui proses optimasi, studi ini memberikan kontribusi terhadap peningkatan sistem pendukung keputusan yang lebih tepat dan efisien, khususnya dalam sektor pelayanan kesehatan. Hal ini diharapkan dapat membantu tenaga medis dalam memberikan diagnosis yang lebih baik dan meningkatkan harapan hidup pasien.

2. Metode

Dalam menyelesaikan penelitian ini, dilakukan beberapa tahapan yang meliputi pengumpulan data dari *UCI Repository (Heart Failure Clinical Records Dataset)*, *pre-processing data*, pembagian data (*Cross validation 10-Fold*), implementasi optimasi *Hyperparameter (Grid SearchCV)*, penerapan algoritma *Machine Learning*, tahap evaluasi dan validasi, serta pelaporan kinerja merupakan bagian integral dari keseluruhan tahapan penelitian. Masing-

masing tahap memiliki fungsi krusial dalam menjamin bahwa sistem yang dikembangkan mampu beroperasi secara optimal. Rangkaian tahapan penelitian tersebut dapat dilihat pada Gambar 1.



Gambar 1. Metode Penelitian

2.1 Heart Failure Clinical Records Dataset

Penelitian ini memanfaatkan dataset *Heart Failure Clinical Records Dataset* yang diperoleh dari *UCI Machine Learning Repository* (UCI Machine Learning Repository, 2020). Dataset ini memuat informasi rekam medis dari 299 pasien yang telah dinyatakan mengalami gagal jantung. Dari jumlah tersebut, terdapat 194 pasien laki-laki dan 105 pasien perempuan. Seluruh pasien berusia di atas 40 tahun, dengan 203 pasien tercatat masih hidup (*Death Event=0*) dan 96 pasien mengalami kematian (*Death Event=1*). Secara statistik, persentase kematian mencapai 32,11%, sedangkan tingkat kelangsungan hidup sebesar 67,89%. Dataset ini terdiri dari 13 atribut, yaitu: *Age*, *Anemia*, *Creatine Phosphokinase (CPK)*, *Diabetes*, *Ejection Fraction*, *High Blood Pressure*, *Platelets*, *Serum Creatinine*, *Serum Sodium*, *Sex*, *Smoking*, *Time*, dan *Death Event*.

2.2 Data Preprocessing

Prapemrosesan data merupakan tahap krusial dalam *Machine Learning* yang melibatkan serangkaian transformasi untuk menyiapkan data mentah sebelum proses pelatihan model. Tahap ini memegang peranan penting karena secara signifikan memengaruhi kinerja dan akurasi model yang dihasilkan. Proses ini mencakup tahap-tahap seperti pembersihan data, transformasi data, serta normalisasi data, yang bertujuan untuk mempersiapkan data agar layak dan sesuai digunakan dalam proses analisis selanjutnya. Secara umum, *preprocessing data* merupakan tahapan penting yang bertujuan untuk mengatasi masalah data *noisy*, *missing values*, duplikasi, dan *inkonsistensi*. Tahapan

ini krusial dalam menjamin integritas data sebelum dilakukan analisis yang lebih mendalam (Rahmani et al., 2021). Gambar 2 dibawah ini merupakan proses dari *Data Preprocessing*.

```

# 2. Preprocessing Data
data = data.fillna(0)

# 3. Feature Selection
X = data.drop('DEATH_EVENT', axis=1)
y = data['DEATH_EVENT']
selector = SelectKBest(f_classif, k='all')
selector.fit(X, y)
X_new = selector.transform(X)

# 4. Normalisasi Data (Scaling)
scaler = StandardScaler()
X_scaled = scaler.fit_transform(X_new)
  
```

Gambar 2. Data Preprocessing

2.3 Pembagian Data

Tahap selanjutnya dalam penelitian ini adalah membagi dataset menjadi data pelatihan dan data pengujian. Penelitian ini menggunakan teknik *Cross validation 10-Fold* sebagai metode evaluasi model. *Cross validation 10-Fold* membagi dataset secara acak menjadi sepuluh bagian yang disebut *fold*. Setiap *fold* secara bergiliran berperan sebagai data pengujian, sementara sembilan *fold* sisanya digunakan sebagai data pelatihan. Proses ini berlangsung secara sistematis hingga semua *fold* mendapatkan kesempatan untuk menjadi data pengujian, sehingga memastikan evaluasi model yang komprehensif dan andal.

Penerapan *cross validation* memiliki dua tujuan utama, yaitu: (1) meningkatkan akurasi evaluasi model dengan memanfaatkan seluruh data secara maksimal, dan (2) memastikan bahwa model yang dikembangkan tidak hanya mampu mengenali pola pada data pelatihan, tetapi juga memiliki kemampuan generalisasi yang baik terhadap data baru yang belum pernah diujikan sebelumnya (Rahmani et al., 2021). Proses pelaksanaan *Cross validation 10-Fold* dalam penelitian ini ditunjukkan pada gambar 3. Pendekatan ini diharapkan dapat memberikan evaluasi model yang lebih konsisten serta mengurangi kemungkinan terjadinya *overfitting*.

Dalam penelitian *machine learning* untuk penyakit *kardiovaskular*, termasuk prediksi gagal jantung, *10-Fold Cross-Validation* menjadi praktik umum karena seimbang antara efisiensi komputasi dan kestabilan estimasi kinerja (Al Amin et al., 2025). Penggunaan *StratifiedKFold* penting untuk menjaga proporsi kelas pada dataset medis yang cenderung tidak seimbang, sehingga meningkatkan generalisasi model (Newaz et al., 2021). Mengingat dataset *Heart Failure Clinical Records* relatif kecil yaitu hanya 299 sampel, penggunaan metode seperti *fold* yang lebih banyak atau *Leave-One-Out Cross-Validation (LOOCV)* justru berisiko menghasilkan estimasi dengan varians tinggi dan hasil kurang stabil (Yuliani, 2022). Selain itu, penerapan *Grid Search*

dengan *Cross-Validation* sudah cukup intensif secara komputasi (Al Amin et al., 2025).

```
# 5. Cross Validation (StratifiedKFold)
kf = StratifiedKFold(n_splits=10, shuffle=True, random_state=42)
```

Gambar 3. *Cross validation 10-Fold*

2.4 Algoritma Machine Learning

Machine Learning didefinisikan sebagai kemampuan suatu sistem untuk meningkatkan kinerjanya dalam menyelesaikan tugas spesifik berdasarkan pengalaman yang diperoleh dari data pelatihan, yang diukur melalui metrik kinerja yang relevan (Janiesch et al., 2021). Tahap ini melibatkan pengujian dan evaluasi komprehensif untuk menentukan model klasifikasi yang paling sesuai dalam penelitian. Berikut ini sejumlah algoritma *Machine Learning* diidentifikasi sebagai calon model yang potensial, antara lain *Random Forest*, *Decision Tree*, *Neural Network*, *K-Nearest Neighbors (K-NN)*, *Support Vector Machine (SVM)*, dan *Naïve Bayes*.

Proses seleksi model dilakukan dengan membandingkan performa masing-masing algoritma, dimana model dengan akurasi paling optimal akan dipilih untuk tahap selanjutnya. Model terpilih tersebut kemudian akan melalui proses optimasi parameter menggunakan metode *Hyperparameter Grid SearchCV* guna meningkatkan performanya secara maksimal.

- a) *Random Forest* merupakan algoritma *Machine Learning* yang digunakan untuk klasifikasi dan prediksi. Metode ini bekerja dengan menggabungkan sejumlah pohon keputusan (*decision tree*) yang masing-masing dilatih menggunakan subset data yang dipilih secara acak. Prediksi akhir ditentukan berdasarkan gabungan hasil seluruh *tree*, meningkatkan akurasi dibandingkan penggunaan satu *tree* saja (Salman et al., 2024).
- b) *Decision Tree* merupakan salah satu teknik dalam machine learning yang dimanfaatkan untuk menangani permasalahan klasifikasi dan regresi. Metode ini menggambarkan proses pengambilan keputusan dalam bentuk seperti pohon. Setiap simpul (*node*) mewakili fitur atau atribut dari data, cabang menunjukkan keputusan berdasarkan fitur tersebut, dan simpul akhir (*leaf node*) menunjukkan hasil akhirnya, seperti kelas atau kategori data (Saputra & Pratama, 2025).
- c) *Neural Network* merupakan sistem komputer yang meniru cara kerja otak manusia. Sistem ini terdiri dari banyak *neuron* buatan, yaitu unit kecil yang saling terhubung. Setiap koneksi antar neuron memiliki bobot yang menentukan seberapa kuat sinyal dikirim. *Neural Network* bisa belajar dari data yang rumit atau tidak rapi, dan secara otomatis membentuk pola atau representasi sendiri selama proses belajar (Sakti et al., 2024).

- d) *K-Nearest Neighbors (K-NN)* adalah algoritma dalam machine learning yang digunakan untuk tugas klasifikasi dan *regresi*. Algoritma ini termasuk pembelajaran terawasi dan bersifat *non-parametrik*, artinya tidak membuat asumsi khusus terhadap data. Cara kerjanya adalah dengan melihat data baru dan membandingkannya dengan beberapa data yang mirip (tetangganya) di data pelatihan. Kemudian, algoritma menentukan kelas atau nilai berdasarkan mayoritas tetangga terdekat tersebut (Ujianto et al., 2025).
- e) *Support Vector Machine (SVM)* merupakan algoritma yang termasuk dalam metode *Supervised Learning*, yang memprediksi kelas suatu data berdasarkan pola yang telah dipelajari saat proses pelatihan. Dalam melakukan klasifikasi, algoritma ini memanfaatkan sebuah *hyperplane* untuk memisahkan data ke dalam kelas-kelas yang berbeda (Yolanda et al., 2022). *Hyperplane* yang terbaik adalah yang memiliki jarak paling lebar antara dua kelas, karena semakin lebar jaraknya, biasanya semakin kecil kemungkinan model salah saat memprediksi data baru (Abdulloh & Pambudi, 2021).
- f) *Naïve Bayes* adalah algoritma klasifikasi yang bekerja berdasarkan *Teorema Bayes* dan digunakan untuk memprediksi suatu kelas berdasarkan peluang. Algoritma ini menganggap setiap fitur dalam data tidak saling bergantung dalam satu kelas. Meskipun anggapan ini tidak selalu sesuai dengan kondisi sebenarnya, *Naïve Bayes* tetap dikenal sebagai metode yang efisien, mudah digunakan, dan cukup akurat (Khoerunnisa et al., 2025).

2.5 Optimasi Hyperparameter

Optimasi *Hyperparameter* adalah langkah kunci dalam menyempurnakan model *Machine Learning* agar bekerja sebaik mungkin. Cara kerjanya adalah dengan mengatur nilai-nilai parameter yang menentukan proses belajar model dari data. Setelah memperoleh konfigurasi *Hyperparameter* yang optimal, model menjadi lebih akurat dan mampu memberikan hasil yang lebih baik. Dalam penelitian ini, penulis menerapkan metode *grid search* dan *cross-validation* untuk menentukan *Hyperparameter* terbaik. *Grid SearchCV* adalah suatu pendekatan sistematis yang dilakukan untuk menguji berbagai kombinasi dari nilai *Hyperparameter* untuk menemukan kombinasi terbaik yang akan meningkatkan kinerja model. Pada dasarnya, *Grid SearchCV* menjalankan model untuk semua kombinasi *Hyperparameter* yang memungkinkan dan memilih yang terbaik berdasarkan metrik kinerja tertentu, seperti *Area Under Curve (AUC)* (Jiang & Xu, 2022).

Metode *Grid SearchCV* bekerja dengan mengevaluasi berbagai kombinasi parameter secara

sistematis, sambil menilai kinerja model secara adil (Bischl et al., 2023). Pendekatan ini terbukti ampuh untuk meningkatkan akurasi secara optimal di berbagai jenis algoritma *Machine Learning*.

Tabel 1 menyajikan parameter yang akan diuji dalam penelitian ini beserta rentang nilainya. Parameter-parameter tersebut akan dikombinasikan secara sistematis guna memperoleh konfigurasi terbaik yang mampu menghasilkan akurasi paling optimal.

Tabel 1. Parameter *Grid SearchCV*

Parameter	Nilai
'n_estimators'	100, 200, 300
'max_depth'	5, 7, 10, None
'min_samples_split'	2, 3, 4
'min_samples_leaf'	1, 2, 3
'bootstrap'	True, False
'random_state'	42

2.6 Evaluasi Model

Tahap evaluasi model bertujuan mengukur efektivitas klasifikasi data pengujian melalui metrik utama yaitu akurasi, *Precision*, *recall*, dan *F1-score*. Setelah pengujian, data akan dianalisis untuk menilai keakuratan model, dengan fokus khusus pada nilai akurasi sebagai indikator utama kemampuan model dalam mengklasifikasikan penyakit gagal jantung.

Accuracy merupakan rasio prediksi benar terhadap total prediksi, yang berguna untuk data seimbang namun kurang *representatif* untuk data tidak seimbang karena mengabaikan distribusi kelas (Islam et al., 2022). Nilai *Accuracy* diperoleh dengan persamaan sebagai berikut (1):

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN} \quad (1)$$

Precision merupakan perbandingan antara jumlah prediksi positif yang benar (*true positive*) dengan keseluruhan prediksi positif (*true positive* + *false positive*), yang menggambarkan tingkat ketepatan model dalam mengenali kelas positif (Islam et al., 2022). Nilai *Precision* diperoleh dengan persamaan sebagai berikut (2):

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

Recall adalah rasio prediksi benar positif (*true positive*) dibandingkan dengan total kasus positif sebenarnya, yang menggambarkan seberapa baik model menghindari *false negative* (Islam et al., 2022). Nilai *Recall* diperoleh dengan persamaan sebagai berikut (3):

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

F1 Score merupakan hasil integrasi antara *Precision* dan *Recall* yang dihitung menggunakan

rata-rata harmonik dari kedua metrik tersebut. Metrik ini berguna untuk mengevaluasi kinerja model pada dataset tidak seimbang karena mempertimbangkan baik kesalahan prediksi positif (*false positive*) maupun kesalahan prediksi negatif (*false negative*) secara seimbang (Islam et al., 2022). Nilai *F1 Score* diperoleh dengan persamaan sebagai berikut (4):

$$F1 = \frac{2}{\frac{1}{Precision} + \frac{1}{Recall}} \quad (4)$$

3. Hasil dan Pembahasan

Penelitian ini menggunakan algoritma enam *Machine Learning* dan melakukan optimasi *Hyperparameter* dengan metode *Grid SearchCV* pada *Heart Failure Clinical Records Dataset*. Tujuan utamanya adalah untuk mengetahui seberapa baik algoritma ini dapat mengklasifikasikan pasien dengan risiko gagal jantung, serta melihat apakah hasil akurasi bisa lebih baik dibandingkan penelitian-penelitian sebelumnya. Untuk mengetahui hal tersebut, dilakukan dua tahap eksperimen. Pada tahap awal, menentukan algoritma *Machine Learning* yang memiliki akurasi paling optimal tanpa dilakukan proses optimasi, sedangkan pada tahap selanjutnya, digunakan algoritma *Random Forest* yang dioptimasi menggunakan *Grid SearchCV*. Hasil dari kedua tahap ini akan menunjukkan apakah optimasi yang dilakukan benar-benar bisa meningkatkan akurasi atau tidak.

3.1 Hasil Eksperimen Algoritma *Machine Learning*


Tabel 2 di bawah ini menyajikan hasil pengujian dan pelatihan dari enam algoritma klasifikasi, yaitu *Random Forest*, *Decision Tree*, *Neural Network*, *K-Nearest Neighbors (K-NN)*, *Support Vector Machine (SVM)*, dan *Naïve Bayes*. Keenam algoritma tersebut dievaluasi secara komprehensif untuk menentukan model yang paling optimal dalam melakukan proses klasifikasi pada *Heart Failure Clinical Records Dataset*.

Tabel 2. Hasil Evaluasi dari Algoritma *Machine Learning*

Algoritma	Accuracy	Precision	Recall	F1 Score
Random Forest	87%	0.87	0.87	0.87
Decision Tree	79%	0.79	0.79	0.79
Neural Network	77%	0.76	0.77	0.77
K-NN	76%	0.75	0.76	0.73
SVM	80%	0.79	0.80	0.79
Naïve Bayes	77%	0.76	0.77	0.75

Gambar 4 dibawah menunjukkan grafik perbandingan akurasi dari enam algoritma yang diuji. Dari hasil evaluasi, *Random Forest* mendapat akurasi paling tinggi, yaitu 87%, dibanding algoritma lainnya. Tingginya nilai akurasi ini mengindikasikan bahwa *Random Forest* memiliki kemampuan yang

lebih baik dalam mengklasifikasikan data pada dataset yang digunakan. Karena memperoleh akurasi tertinggi, *Random Forest* dipilih sebagai model utama untuk dioptimasi lebih lanjut dalam penelitian ini.



Gambar 4. Grafik Perbandingan Akurasi Model Klasifikasi

Gambar 5 menunjukkan hasil evaluasi model *Random Forest* sebelum dioptimasi. Pada tahap ini, pengujian dilakukan dengan metode *Cross validation 10-Fold*. Metode ini membagi data jadi 10 bagian, lalu tiap bagian dipakai bergantian sebagai data uji dan data latih, tujuannya agar hasil evaluasi lebih stabil. Dari pengujian ini, *Random Forest* mencapai akurasi 87%, yang merupakan akurasi tertinggi dibanding algoritma lain dalam penelitian ini.

Model: Random Forest				
	precision	recall	f1-score	support
0	0.88	0.93	0.91	203
1	0.84	0.74	0.78	96
accuracy			0.87	299
macro avg	0.86	0.84	0.85	299
weighted avg	0.87	0.87	0.87	299
Confusion Matrix:				
[[189 14]				
[25 71]]				

Gambar 5. Confusion Matrix Random Forest

Dengan demikian, hasil eksperimen mengkonfirmasi bahwa algoritma *Random Forest* menghasilkan nilai akurasi klasifikasi tertinggi yaitu sebesar 87%. Nilai ini merepresentasikan performa yang lebih baik dibandingkan dengan algoritma-algoritma lain yang telah diuji dalam studi ini.

3.2 Hasil Eksperimen Algoritma *Random Forest* menggunakan *Hyperparameter Grid SearchCV*

Setelah melakukan eksperimen awal menggunakan algoritma *Random Forest* dan memperoleh akurasi tertinggi sebesar 87%, dilakukan proses lanjutan berupa optimasi model melalui penyesuaian *Hyperparameter* menggunakan metode *Grid SearchCV*. Evaluasi tetap menggunakan metode *Cross validation 10-Fold*, namun dengan penambahan sejumlah parameter tertentu yang digunakan untuk mencari kombinasi terbaik dari konfigurasi model.

Setelah dilakukan pencarian kombinasi parameter terbaik, pada gambar 6 dilakukan implementasi optimasi *Hyperparameter* menggunakan *Grid SearchCV* pada model *Random Forest*. Hasil optimasi menunjukkan peningkatan signifikan pada performa model dengan akurasi mencapai 95%. Parameter optimal yang berhasil ditemukan mencakup: *bootstrap=True*, *max_depth=10*, *min_samples_leaf=3*, *min_samples_split=2*, *n_estimators=300*, dan *random_state=42*.

Model: Random Forest dengan GridSearchCV				
	precision	recall	f1 score	support
0	0.94	0.99	0.96	203
1	0.97	0.88	0.92	96
accuracy			0.95	299
macro avg	0.95	0.93	0.94	299
weighted avg	0.95	0.95	0.95	299
Confusion Matrix:				
[[208 12]				
[12 84]]				
Parameter Terbaik:				
{'bootstrap': True, 'max_depth': 10, 'min_samples_leaf': 3, 'min_samples_split': 2, 'n_estimators': 300, 'random_state': 42}				

Gambar 6. Confusion Matrix Random Forest dengan *Grid SearchCV*


Hasil ini menunjukkan bahwa proses optimasi dengan *Grid SearchCV* berhasil meningkatkan performa model secara signifikan. Akurasi algoritma *Random Forest* meningkat dari 87% menjadi 95% setelah dilakukan penyesuaian parameter. Sehingga dapat disimpulkan bahwa penerapan *Grid SearchCV* memberikan kontribusi positif dalam meningkatkan kinerja klasifikasi model.

3.3 Pembahasan

Berdasarkan penelitian sebelumnya, pada tahap ini akan dilakukan evaluasi untuk mengukur peningkatan akurasi yang diperoleh dari pengujian klasifikasi menggunakan algoritma *Random Forest* serta *Random Forest* yang telah dioptimasi dengan *Hyperparameter Grid SearchCV*. Evaluasi dilakukan menggunakan metode *Cross validation 10-Fold*, penggunaan *Hyperparameter Grid SearchCV* bertujuan untuk meningkatkan performa model.

Pada gambar 7 dibawah ini merupakan grafik perbandingan dari nilai akurasi, *Precision*, *Recall* dan *F1 Score* pemodelan *Random Forest* dan *Random Forest* yang telah dioptimasi menggunakan *Hyperparameter Grid SearchCV*. Grafik ini menunjukkan bahwa akurasi model *Random Forest* yang dioptimasi menggunakan *Hyperparameter Grid SearchCV* mengalami peningkatan akurasi sebesar 8,00%. Dari grafik, terlihat bahwa semua metrik untuk model yang menggunakan *Grid SearchCV* menunjukkan nilai yang lebih tinggi, yaitu 0.95% dibandingkan dengan model *Random Forest* yang mencatat nilai 0.87%.

Hasil ini membuktikan efektivitas *Grid SearchCV* dalam meningkatkan performa klasifikasi *Random Forest* untuk prediksi pasien gagal jantung. Temuan dari penelitian ini selanjutnya akan dianalisis dengan membandingkannya terhadap hasil-hasil penelitian terdahulu guna menilai keseluruhan capaian studi ini.



Gambar 7. Grafik Perbandingan Hasil Pengujian

Adapun perbandingan dari penelitian sebelumnya terdapat pada tabel 3 sebagai berikut:

Tabel 3. Perbandingan Hasil Penelitian

Penelitian	Algoritma Machine Learning	Accuracy
Novaldy dan Herliana (Novaldy & Herliana, 2021)	Naïve Bayes dan Particle Swarm Optimization (PSO)	91,67%
Ramdhani et al (Ramdhani et al., 2023)	Random Forest dan Algoritma Genetika	93,36%
Penelitian ini	Random Forest dan Grid SearchCV	95,00%

Tabel 3 mempresentasikan perbandingan antara hasil penelitian ini dengan penelitian sebelumnya yang menggunakan dataset *Heart Failure Clinical Records Dataset*. Temuan ini mengonfirmasi bahwa pendekatan optimasi *hyperparameter* yang sistematis dengan *Grid SearchCV* pada algoritma yang tepat (*Random Forest*) menghasilkan kinerja yang unggul. Kelebihan *Grid SearchCV* terletak pada kemampuannya untuk menemukan konfigurasi parameter yang benar-benar optimal (seperti $n_estimators=300$ dan $max_depth=10$) melalui pencarian *brute-force* yang terstruktur, yang mungkin terlewat oleh algoritma optimasi berbasis populasi seperti *PSO* dan *Algoritma Genetika*, terutama pada ruang parameter yang tidak terlalu besar.

Temuan penelitian membuktikan bahwa optimasi *Hyperparameter* menggunakan *Grid SearchCV* berhasil meningkatkan performa model *Random Forest* secara signifikan, dengan pencapaian akurasi klasifikasi sebesar 95,00%. Hasil ini menunjukkan keefektifan pendekatan yang diusulkan dalam menangani dataset klinis pasien gagal jantung.

4. Kesimpulan

Berdasarkan hasil eksperimen yang dilakukan, algoritma *Random Forest* terbukti menjadi model yang paling optimal di antara enam algoritma klasifikasi yang diuji, dengan akurasi awal sebesar 87%. Hasil ini membuktikan bahwa *Random Forest* memiliki performa yang lebih unggul dalam memprediksi kelangsungan hidup pasien dibandingkan dengan algoritma lain seperti *Decision Tree*, *Neural Network*, *K-Nearest Neighbors*, *Support*

Vector Machine, dan *Naïve Bayes*. Setelah penerapan optimasi *Hyperparameter* menggunakan *Grid SearchCV* pada model *Random Forest*, akurasi model meningkat secara signifikan menjadi 95%. Peningkatan ini tidak hanya menunjukkan efektivitas teknik optimasi yang diterapkan, tetapi juga menegaskan pentingnya penyesuaian parameter dalam meningkatkan kinerja model klasifikasi. Evaluasi performa model dilakukan dengan menggunakan metrik seperti *precision*, *recall*, dan *F1-score* turut menunjukkan adanya peningkatan performa setelah dilakukan proses optimasi, yang menandakan bahwa model yang telah dioptimalkan mampu meminimalkan kesalahan klasifikasi serta menghasilkan prediksi yang lebih tepat dan andal.

Untuk penelitian selanjutnya, disarankan untuk menerapkan algoritma *Random Forest* pada dataset yang berbeda guna menguji generalisasi model. Selain itu, eksplorasi teknik optimasi *Hyperparameter* lain seperti *Random Search* atau *Bayesian Optimization* dapat dilakukan untuk mencapai akurasi yang lebih tinggi. Implementasi model yang telah dioptimasi ke dalam aplikasi praktis juga dapat menjadi langkah penting untuk mendukung pengelolaan pasien gagal jantung secara lebih efektif.

Daftar Pustaka:

- Abdulloh, F. F., & Pambudi, I. R. (2021). Analisis Sentimen Pengguna Youtube Terhadap Program Vaksin Covid-19. *CSRID (Computer Science Research and Its Development Journal)*, 13(3), 141-148. <https://doi.org/10.22303/csr.13.3.2021.141-148>
- Al Amin, I., Wibisono, S., Lestariningsih, E., & Lutfi M.A, M. (2025). Optimizing Heart Disease Prediction with Random Forest and Ensemble Methods. *CogITO Smart Journal*, 11(1), 80–90. <https://doi.org/10.31154/cogito.v11i1.782.80-90>
- Arifin, T., Agung, I. W. P., Junianto, E., Rachman, R., Wibowo, I. R., & Agustin, D. D. (2024). Breast Cancer Identification Using Machine Learning and Hyperparameter Optimization. *Indonesian Journal of Electrical Engineering and Computer Science*, 36(3), 1620–1630. <https://doi.org/10.11591/ijeecs.v36.i3.pp1620-1630>
- Arisandi, R. (2023). Perbandingan Model Klasifikasi Random Forest Dengan Resampling Dan Tanpa Resampling Pada Pasien Penderita Gagal Jantung. *Jurnal Gaussian*, 12(1), 136–145. <https://doi.org/10.14710/j.gauss.12.1.136-145>
- Bhadula, S., Adnan, M. M., Kumar, R., Rana, A., Kaliyaperumal, G., Rao, B. D., & Boob, N. S. (2024). Optimizing Random Forest Algorithms for LargeScale Data Analysis. 2024 7th

- International Conference on Contemporary Computing and Informatics (IC3I)*, 1673–1678. <https://doi.org/10.1109/IC3I61595.2024.10829145>
- Bharti, R., Khamparia, A., Shabaz, M., Dhiman, G., Pande, S., & Singh, P. (2021). Prediction of Heart Disease Using a Combination of Machine Learning and Deep Learning. *Computational Intelligence and Neuroscience*, 2021(1). <https://doi.org/10.1155/2021/8387680>
- Bischi, B., Binder, M., Lang, M., Pielok, T., Richter, J., Coors, S., Thomas, J., Ullmann, T., Becker, M., Boulesteix, A., Deng, D., & Lindauer, M. (2023). Hyperparameter optimization: Foundations, algorithms, best practices, and open challenges. *WIREs Data Mining and Knowledge Discovery*, 13(2). <https://doi.org/10.1002/widm.1484>
- Doni, B. T. R., Susanti, S., & Mubarak, A. (2021). Penerapan Data Mining Untuk Klasifikasi Penyakit Hepatocellular Carcinoma Menggunakan Algoritma Naïve Bayes. *Jurnal Responsif: Riset Sains Dan Informatika*, 3(1), 12–19. <https://doi.org/10.51977/jti.v3i1.403>
- Gu, Q., Tian, J., Li, X., & Jiang, S. (2022). A novel Random Forest integrated model for imbalanced data classification problem. *Knowledge-Based Systems*, 250, 109050. <https://doi.org/10.1016/j.knosys.2022.109050>
- Huang, S., Gu, W., & Chen, S. (2021). Optimization of Classification Rules and Voting Strategies for Random Forest. *2021 IEEE 7th International Conference on Cloud Computing and Intelligent Systems (CCIS)*, 381–387. <https://doi.org/10.1109/CCIS53392.2021.9754599>
- Islam, S. S., Haque, M. S., Miah, M. S. U., Sarwar, T. Bin, & Nugraha, R. (2022). Application of machine learning algorithms to predict the thyroid disease risk: an experimental comparative study. *PeerJ Computer Science*, 8. <https://doi.org/10.7717/PEERJ-CS.898>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31, 685–695. <https://doi.org/10.1007/s12525-021-00475-2/Published>
- Jiang, X., & Xu, C. (2022). Deep Learning and Machine Learning with Grid Search to Predict Later Occurrence of Breast Cancer Metastasis Using Clinical Data. *Journal of Clinical Medicine*, 11(19), 5772. <https://doi.org/10.3390/jcm11195772>
- Julia, T., Yovi, P., & Yanti, E. (2023). Komparasi Dalam Prediksi Gagal Jantung Dengan Menggunakan Metode C4.5 dan Naïve Bayes. *Jurnal Informatika Dan Rekayasa Komputer (JAKAKOM)*, 3(1), 394–402. <https://doi.org/10.33998/jakakom.2023.3.1.75>
- Khoerunnisa, S., Shiddieq, D. F., & Nurhayati, D. (2025). Penerapan Algoritma Naive Bayes dengan Teknik TF-IDF dan Cross Validation untuk Analisis Sentimen Terhadap Starlink. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 5(2), 566–577. <https://doi.org/10.57152/malcom.v5i2.1852>
- Newaz, A., Ahmed, N., & Shahriyar Haq, F. (2021). Survival prediction of heart failure patients using machine learning techniques. *Informatics in Medicine Unlocked*, 26, 100772. <https://doi.org/10.1016/j.imu.2021.100772>
- Novaldy, F., & Herliana, A. (2021). Penerapan PSO pada Naïve Bayes untuk Prediksi Harapan Hidup Pasien Gagal Jantung. *Jurnal Responsif: Riset Sains Dan Informatika*, 3(1), 37–43. <https://doi.org/10.51977/jti.v3i1.396>
- Prasetyo, S. Y. (2023). Prediksi Gagal Jantung Menggunakan Artificial Neural Network. *Jurnal SAINTEKOM*, 13(1), 79–88. <https://doi.org/10.33020/saintekom.v13i1.379>
- Radzi, S. F. M., Karim, M. K. A., Saripan, M. I., Rahman, M. A. A., Isa, I. N. C., & Ibahim, M. J. (2021). Hyperparameter Tuning and Pipeline Optimization via Grid Search Method and Tree-Based AutoML in Breast Cancer Prediction. *Journal of Personalized Medicine*, 11(10). <https://doi.org/10.3390/jpm11100978>
- Rahayu, W. P., Sudipta, I. I. G., Suryani, Surachman, A., Darmawiguna, M. I. G., Sutoyo, N. M., Slamet, I., Harlina, S., & Maysanjaya, D. I. M. (2024). *Buku Ajar Data Mining* (Efitra, Ed.; Pertama). Sonpedia.com. <https://www.researchgate.net/publication/377415198>
- Rahmani, A. M., Yousefpoor, E., Yousefpoor, M. S., Mehmood, Z., Haider, A., Hosseinzadeh, M., & Ali Naqvi, R. (2021). Machine Learning (ML) in Medicine: Review, Applications, and Challenges. *Mathematics*, 9(22), 2970. <https://doi.org/10.3390/math9222970>
- Ramdhani, Y., Putra, C. M., & Alamsyah, D. P. (2023). Heart Failure Prediction Based on Random Forest Algorithm using Genetic Algorithm for Feature Selection. *International Journal of Reconfigurable and Embedded Systems (IJRES)*, 12(2), 205–214. <https://doi.org/10.11591/ijres.v12.i2.pp205-214>
- Sakti, A. I., Saputra, L., Suhendra, H., Halim, N., Alviari, I., Ilham, M. R. N., Putri, M. H. N., & Dalimunthe, D. Y. (2024). Implementasi Artificial Neural Network (ANN) dalam Memprediksi Nilai Tukar Rupiah terhadap Dolar Amerika. *Euler: Jurnal Ilmiah Matematika, Sains Dan Teknologi*, 12(2), 124–130. <https://doi.org/10.37905/euler.v12i2.26654>

- Salman, H. A., Kalakech, A., & Steiti, A. (2024). Random Forest Algorithm Overview. *Babylonian Journal of Machine Learning*, 2024, 69–79. <https://doi.org/10.58496/bjml/2024/007>
- Saputra, R. A., & Pratama, A. (2025). Implementasi Decision Tree Untuk Prediksi Harga Rumah Di Daerah Tebet. *Journal of Information System Management (JOISM) e-ISSN*, 6(2), 164–170.
- Siregar, P. A., Purba, P. D., Pasaribu, P. J., & Bakara, R. K. (2023). Implementasi Algoritma Random Forest Dalam Klasifikasi Diagnosis Penyakit Stroke. *Jurnal Penelitian Rumpun Ilmu Teknik*, 2(4), 155–164. <https://doi.org/10.55606/juprit.v2i4.3039>
- Subarkah, P., Damayanti, W. R., & Permana, R. A. (2022). Comparison of Correlated Algorithm Accuracy Naive Bayes Classifier and Naive Bayes Classifier for Classification of heart failure. *ILKOM Jurnal Ilmiah*, 14(2), 120–125. <https://doi.org/10.33096/ilkom.v14i2.1148.120-125>
- Subasi, N. (2024). Comprehensive Analysis of Grid and Randomized Search on Dataset Performance. *European Journal of Engineering and Applied Sciences*, 7(2), 77–83. <https://doi.org/10.55581/ejeas.1581494>
- Sun, Z., Wang, G., Li, P., Wang, H., Zhang, M., & Liang, X. (2024). An improved random forest based on the classification accuracy and correlation measurement of decision trees. *Expert Systems with Applications*, 237, 121549. <https://doi.org/10.1016/j.eswa.2023.121549>
- Taye, M. M. (2023). Understanding of Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions. *Computers*, 12(5), 91. <https://doi.org/10.3390/computers12050091>
- UCI Machine Learning Repository. (2020, April 2). *Heart Failure Clinical Records*. UCI Machine Learning Repository. <https://archive.ics.uci.edu/dataset/519/heart+failure+clinical+records>
- Ujjianto, N. T., Gunawan, Fadillah, H., Fanti, A. P., Saputra, A. D., & Ramadhan, I. G. (2025). Penerapan algoritma K-Nearest Neighbors (KNN) untuk klasifikasi citra medis. *IT-Explore: Jurnal Penerapan Teknologi Informasi Dan Komunikasi*, 4(1), 33–43. <https://doi.org/10.24246/itexplore.v4i1.2025.p33-43>
- Yolanda, N., Santi, I. H., & Permadi, D. F. H. (2022). Analisis Sentimen Analisis Sentimen Popularitas Aplikasi Moodle dan Edmodo Menggunakan Algoritma Support Vector Machine. *Jurnal Algoritme*, 3(1), 48–59. <https://doi.org/10.35957/algoritme.v3i1.3313>
- Yuliani, Y. (2022). Algoritma Random Forest Untuk Prediksi Kelangsungan Hidup Pasien Gagal Jantung Menggunakan Seleksi Fitur Bestfirst. *Infotek: Jurnal Informatika Dan Teknologi*, 5(2), 298–306. <https://doi.org/10.29408/jit.v5i2.5896>

Halaman ini sengaja dikosongkan