



MODEL HYBRID PSO, FEATURE SELECTION CORRELATION DAN LOGISTIC REGRESSION UNTUK DETEKSI PENYAKIT JANTUNG

Muhammad Wahyu Hidayatullah, Taghfirul Azhima Yoga Siswa*, Wawan Joko Pranoto

Program Studi Teknik Informatika, Universitas Muhammadiyah Kalimantan Timur, Indonesia

Abstrak: Penyakit jantung merupakan salah satu penyebab utama kematian baik di Indonesia maupun secara global sehingga diperlukan model deteksi dini yang akurat. Penelitian ini bertujuan meningkatkan kinerja *Logistic Regression* dengan *regularisasi L2* melalui optimasi *Particle Swarm Optimization (PSO)* dan *feature selection* berbasis *correlation*. Metode yang digunakan meliputi *pre-processing*, *standarisasi*, seleksi fitur, serta evaluasi menggunakan *K-10 Fold Cross Validation*. Hasil pengujian menunjukkan bahwa *Logistic Regression* menghasilkan *accuracy* 82,47%, *precision* 80,31%, *recall* 88,56%, dan *F1-score* 84,10%. Setelah dioptimasi dengan PSO, performa meningkat menjadi *accuracy* 84,45%, *precision* 81,74%, *recall* 91,01%, dan *F1-score* 85,98%. Hasil tersebut menegaskan bahwa pendekatan *hybrid* yang diusulkan efektif dalam meningkatkan deteksi penyakit jantung.

Kata kunci: Jantung, *Correlation*, *Machine Learning*, *Logistic Regression*, *Particle Swarm Optimization*

I. PENDAHULUAN

Penyakit jantung merupakan kondisi ketika fungsinya terganggu akibat kelainan pada pembuluh darah, irama detak, katup, atau bawaan sejak lahir, yang dapat memengaruhi kemampuan jantung memompa darah ke seluruh tubuh (Junifer Pangaribuan et al., 2021). Hasil riset yang dilakukan Kemenkes RI, (2024) data penduduk tahun 2018 di Indonesia mencatat 1,5% pernah terdiagnosis penyakit jantung. Sementara itu, dari *World Health Organization*, (2025) pada tahun 2022 diperkirakan sebanyak 19,8 juta orang meninggal dunia akibat penyakit *kardiovaskular* yang mencakup salah satunya penyakit jantung, angka ini mewakili sekitar

32% dari seluruh kematian *global*. Permasalahan Penderita ini semakin sulit karena deteksi sejak dini kerap terabaikan, sementara proses pemeriksaan membutuhkan biaya tidaklah murah karena ditangani secara langsung oleh dokter *spesialis* dan melalui uji laboratorium (Sepharni et al., 2022). Untuk mempercepat serta meningkatkan keakuratan proses diagnosis penyakit jantung dapat memanfaatkan model *Machine Learning (ML)* (Taher & Abdulazeez, 2023).

Model *Machine Learning (ML)* menggunakan sistem kerja dengan cara mengenali pola karakteristik data melalui pemilihan metode, lalu pengaturan *parameter* awal contohnya jumlah lapisan dan kecepatan belajar secara evaluasi berulang kali hingga diperoleh performa akurasi klasifikasi dan prediksi (Black et al., 2023).

Beberapa penelitian telah memanfaatkan klasifikasi pada *ML* untuk mendiagnosis

*) 2211102441148@umkt.ac.id

Diterima: 3 Maret 2026

Direvisi: 22 April 2026

Disetujui: 22 April 2026

DOI: 10.23969/infomatek.v28i1.43123

penyakit jantung (Elshewey et al., 2025). Cara kerja klasifikasi dengan mengenali lalu menempatkan objek ke dalam suatu kategori target kelas tertentu terkait kesamaan karakteristiknya (Adhitya et al., 2023).

Penelitian terkait deteksi penyakit jantung telah banyak dilakukan, salah satunya oleh Ratnasari et al., (2024) dengan metode *Naive Bayes* mencapai akurasi 84%, *Logistic Regression* 84%, *Random Forest* 81%, *Support Vector Machine (SVM)* 81%, *Decision Tree* 74%, *K-Nearest Neighbors (KNN)* 73%, dan *Adaptive Boosting* 71%. (Wibowo et al., 2024; Hidayat et al., 2024) menggunakan *KNN* mencapai 94%, *Decision Tree* 93%, *Logistic Regression* 86%, dan *SVM* 85%. Penelitian terkait jantung koroner Oise et al., (2025) *Logistic Regression* didapatkan senilai 82%. Penelitian lain menunjukkan penurunan akurasi yang signifikan oleh Permana., (2024) model *KNN* hanya mencapai 64%. Pada penelitian *kardiovaskular* yang terkait penyakit jantung (Bietrosula et al., 2024) *Logistic Regression* senilai 73% dan *Random Forest* 71%. Perbedaan lain pada Agarwal et al., (2024) *KNN* senilai 79%, *Naive Bayes* 79%, tetapi *Logistic Regression* hanya 76%.

Metode *Logistic Regression* merupakan model analisis untuk mengestimasi hubungan antara seberapa besar komponen dengan dua kategori atau lebih jika memiliki karakteristik yang tidak kaku sehingga mudah dipahami (Zabor et al., 2022). Namun *Logistic Regression* memiliki kelemahan jika ditempatkan pada data tidak seimbang, karena model cenderung berpihak kepada salah satu kelas sehingga menurunkan akurasi (Zhang et al., 2022).

Untuk mengatasi keterbatasan tersebut, pendekatan berbasis optimasi dapat digunakan dalam meningkatkan kinerja deteksi penyakit jantung memanfaatkan

Genetic Algorithm (GA) akurasi senilai 85% dan *Particle Swarm Optimization (PSO)* 87%, dalam metode *SVM* (Rojas et al., 2024). Penelitian terkait penyakit jantung telah dilakukan Setiani et al., (2022) dengan optimasi *PSO* pada *Naive Bayes* didapatkan akurasi 91% dari sebelumnya tidak dioptimasi 83%. Penelitian oleh Saputra et al., (2022) *PSO* dikombinasikan dengan *SVM* senilai 84% dari sebelumnya 81% .

Sementara itu, penelitian penyakit diabetes Jibril et al., (2023) *PSO* dikombinasikan *Logistic Regression* didapatkan senilai 97% dari sebelumnya 76%. Optimasi *PSO* merupakan model kecerdasan dengan cara kerja meniru perilaku kelompok dalam bekerja sama, di mana *partikel* saling berinteraksi dalam ruang pencarian untuk menemukan solusi (Yi et al., 2024).

Meskipun metode *machine learning* telah banyak digunakan untuk deteksi penyakit jantung, hasil yang diperoleh masih bervariasi dan belum optimal, *logistic regression* sebagai salah satu metode yang umum digunakan masih memiliki keterbatasan dalam penentuan parameter dan pemilihan fitur. Oleh karena itu, penelitian ini mengusulkan model *hybrid* yang menggabungkan *Logistic Regression*, *feature selection* berbasis *correlation*, serta optimasi *Particle Swarm Optimization (PSO)* untuk meningkatkan kinerja deteksi dini penyakit jantung.

II. METODOLOGI

2.1. Objek Penelitian

Penelitian ini membahas deteksi penyakit jantung dengan memanfaatkan dataset *open source* dari Zenodo. Dataset ini dipilih karena bersifat publik, mudah diakses, serta telah banyak digunakan dalam berbagai studi akademik, khususnya penelitian *machine learning* untuk klasifikasi dan deteksi penyakit jantung. Selain itu, penggunaan dataset yang

telah tervalidasi dalam penelitian sebelumnya memungkinkan proses evaluasi model

dilakukan secara lebih objektif dan dapat dibandingkan dengan hasil studi terdahulu.

Tabel 1. Dataset Penyakit Jantung

age	sex	cp	trestbps	chol	fb	restecg	thalach	exang	oldpeak	slope	ca	thal	target
52	1	0	125	212	0	1	168	0	1	2	2	3	0
53	1	0	140	203	1	0	155	1	3,1	0	0	3	0
70	1	0	145	174	0	1	125	1	2,6	0	0	3	0
58	0	0	100	248	0	0	122	0	1	1	0	2	1
71	0	0	122	149	0	1	125	0	1,6	1	0	2	1

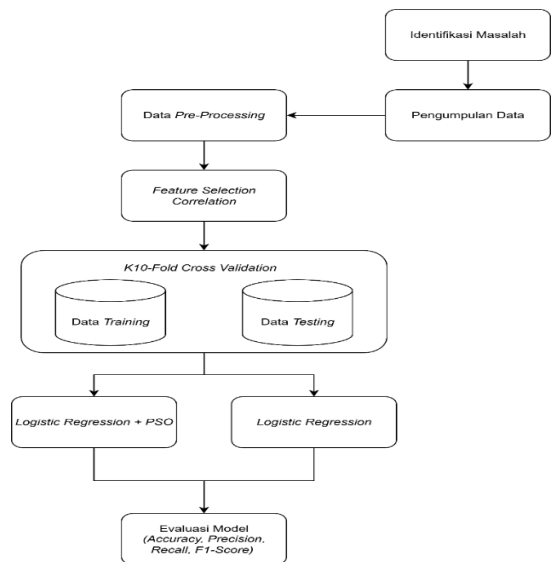
Tabel di atas menampilkan contoh data pasien dari berkas *heart.csv* yang terdiri dari beberapa atribut, yaitu *age* (usia), *sex* (jenis kelamin dengan nilai 1 = laki-laki dan 0 = perempuan), *cp* (*chest pain*) yang menunjukkan tipe nyeri dada dengan rentang nilai 0–3, *trestbps* (tekanan darah istirahat), *chol* (kadar kolesterol), *fb*s (gula darah puasa dengan nilai 1 jika >120 mg/dl dan 0 jika ≤120 mg/dl), *restecg* (hasil elektrokardiografi istirahat), *thalach* (denyut jantung maksimum), *exang* (indikasi nyeri dada akibat olahraga dengan nilai 1 = ya dan 0 = tidak), *oldpeak* (depresi segmen ST), *slope* (kemiringan segmen ST), *ca* (jumlah pembuluh darah utama), *thal* (hasil tes thalium), serta *target* sebagai variabel kelas dengan nilai 1 menunjukkan pasien terindikasi penyakit jantung dan 0 menunjukkan tidak terindikasi.

Dataset ini dipilih karena bersifat publik, mudah diakses, serta telah banyak digunakan dalam berbagai penelitian berbasis *machine learning*, sehingga memungkinkan proses evaluasi model dilakukan secara objektif dan dapat dibandingkan dengan penelitian sebelumnya.

Sebagai contoh, pada baris data pertama dengan nilai *age* = 52, *sex* = 1, dan *cp* = 0, menunjukkan bahwa pasien berusia 52 tahun, berjenis kelamin laki-laki, dan tidak mengalami tipe nyeri dada tertentu. Jika nilai *target* = 0, maka pasien tersebut tidak terindikasi penyakit jantung, sedangkan jika bernilai 1

menunjukkan pasien terindikasi penyakit jantung.

2.2. Prosedur Penelitian



Gambar 1. Diagram Alur Penelitian

Pada Gambar 1, tahapan berikutnya yaitu diagram alur penelitian menggambarkan tahapan utama terkait proses yang diawali dengan identifikasi masalah, pengumpulan data, tahap *pre-processing* untuk memastikan kualitas data yang digunakan, lalu *Feature Selection Correlation* untuk melihat atribut mana yang paling berpengaruh dalam analisis, selanjutnya dataset dibagi menggunakan metode *K10-Fold Cross Validation* menjadi data *training* dan *testing*, kemudian dibangun dengan dua pendekatan, yaitu *Logistic Regression* dan yang dioptimasi

dengan *optimasi PSO* , hasil dari kedua model tersebut dievaluasi dengan *Accuracy, Precision, Recall, dan F1-score*.

2.3. Data Cleaning

Data cleaning merupakan tahapan untuk memastikan kualitas dataset dengan memperbaiki atau menghapus data yang tidak lengkap, tidak konsisten, maupun kurang relevan sehingga siap digunakan dalam proses analisis. Pada penelitian ini, proses pembersihan data dilakukan dengan beberapa langkah, yaitu mengidentifikasi dan menangani *missing value* menggunakan metode imputasi nilai rata-rata (*mean*) pada atribut numerik, menghapus data duplikat sebanyak 723 baris sehingga tersisa 302 data unik, serta melakukan penyeragaman format data kategorikal seperti atribut *sex, exang, dan target* menjadi nilai biner (0 dan 1) agar konsisten pada tahap pemodelan (Oon Wira Yuda et al., 2022).

2.4. Data Standarisasi

Proses berikutnya yaitu *Standarisasi* diterapkan *Standard Scaler*, yaitu mengubah setiap fitur agar memiliki nilai rata-rata sebesar 0 dan standar *deviasi* sebesar 1, proses ini bertujuan memusatkan distribusi data di sekitar nilai rata-rata serta menyesuaikan skala atribut berdasarkan penyebaran datanya, dengan demikian, setiap atribut memiliki kontribusi yang seimbang dalam

proses pembelajaran model deteksi (Firnanda, 2025) (Fan et al., 2021).

$$x' = \frac{x-\mu}{\sigma} \tag{1}$$

2.5. Feature Selection Correlation

Analisis *Feature Selection Correlation* dilakukan sebagai tahapan penting untuk memahami keterkaitan antar atribut dalam suatu dataset, menggunakan *Heatmap* untuk mengukur tingkat hubungan antar setiap atribut lalu direpresentasikan dalam *Gradasi* warna dengan rentang nilai antara -1 hingga 1, di mana nilai yang mendekati 1 menunjukkan hubungan positif yang kuat, nilai mendekati -1 menunjukkan hubungan negatif yang kuat, serta nilai mendekati 0 menandakan tidak adanya hubungan *Linier* (Dinova & Prasetyo, 2024) (Sani et al., 2023).

$$Corr_{x,y} = \frac{\sum(x_i-\bar{x})(y_i-\bar{y})}{\sqrt{\sum(x_i-\bar{x})^2(y_i-\bar{y})^2}} \tag{2}$$

2.6. K10-Fold Cross Validation

Pada Tabel 2, adalah proses yang dilakukan dengan cara kerja membagi dataset *training* dan *testing* menjadi *K10 Fold* berukuran sama pada setiap literasi dan satu *Fold* dijadikan data uji lalu berikutnya sembilan *Fold* lainnya digunakan sebagai data latih, proses ini dilakukan dengan berulang sebanyak 10 kali hingga berperan sebagai data uji (Sonjaya et al., 2022).

Tabel 2. K10-Fold Cross Validation

1	Test	Train	Train	Train	Train	Train	Train	Train	Train	Train
2	Train	Test	Train	Train	Train	Train	Train	Train	Train	Train
3	Train	Train	Test	Train	Train	Train	Train	Train	Train	Train
4	Train	Train	Train	Test	Train	Train	Train	Train	Train	Train
5	Train	Train	Train	Train	Test	Train	Train	Train	Train	Train
6	Train	Train	Train	Train	Train	Test	Train	Train	Train	Train
7	Train	Train	Train	Train	Train	Train	Test	Train	Train	Train
8	Train	Train	Train	Train	Train	Train	Train	Test	Train	Train
9	Train	Train	Train	Train	Train	Train	Train	Train	Test	Train
10	Train	Train	Train	Train	Train	Train	Train	Train	Train	Test

2.7. Logistic Regression

Metode *logistic regression* memodelkan dan mengestimasi hubungan antara satu *variabel dependen biner* yang sering disebut hasil dengan satu atau lebih *variabel independen* dikenal sebagai *kovariat* (Zabor et al., 2022). *transformasi logit variabel* diubah menjadi *probabilitas* dengan rentang 0 hingga 1, bentuk statistik dari model *binary logistic regression* ditunjukkan pada persamaan (1) (Harris, 2021).

$$p(y) = \frac{1}{1+e^{-(b_0+b_1x_1+b_2x_2)}} \quad (3)$$

Model dengan *Regularisasi L2* menambahkan penalti norma *L2* kuadrat fungsi objektif untuk membatasi nilai parameter dan mengurangi *overfitting* pada *Logistic Regression*, kekuatan regularisasi dikendalikan oleh fungsi $C(t)$ sehingga solusi model berkembang secara bertahap menuju kondisi tanpa regularisasi, pendekatan ini secara khusus menitikberatkan pada penggunaan *Regularisasi L2*, namun secara konseptual dapat diperluas ke bentuk *kuadratik* (Zhu, 2021).

$$\theta(t) = \arg \min_{\theta \in \mathbb{R}^p} \left(C(t)L_n(\theta) + \frac{1}{2} |\theta|_2^2 \right) \quad (4)$$

2.8. Particle Swarm Optimization (PSO)

Optimasi *pso* yaitu pengendalian kecepatan algoritma yang merupakan aspek penting karena menjadi mekanisme utama yang mengarahkan perpindahan partikel dalam proses pencarian solusi optimal. *Eberhart* menerapkan batas maksimum kecepatan dan mengevaluasi hasil dari berbagai nilai kecepatan partikel ke- k pada *swarm* kemudian diperbarui iterasi ke- $(i+1)$ sesuai Persamaan (1) (Jain et al., 2022).

$$V_k(i+1) = V_k(i) + c_1r_1(p_{best,i}^k - X_k(i)) + c_2r_2(g_{best,i} - X_k(i)) \quad (5)$$

Posisi *partikel ke-k* pada setiap iterasi ke- $(i+1)$ diperbarui berdasarkan persamaan (2) dengan posisi baru partikel ditentukan dari posisi sebelumnya ditambah dengan nilai kecepatan pada literasi tersebut, mekanisme ini memungkinkan *partikel* untuk terus bergerak dan menelusuri ruang pencarian, sehingga diharapkan dapat solusi yang lebih optimal pada setiap tahap iterasi.

$$X_k(i+1) = X_k(i) + V_k(i+1) \quad (6)$$

2.9. Confusion Matrix

Confusion Matrix merupakan metode evaluasi yang digunakan untuk menilai kinerja model klasifikasi dengan membandingkan hasil prediksi terhadap data dari baris yang merepresentasikan kelas aktual dan kolom yang merepresentasikan kelas prediksi (Markoulidakis et al., 2021). Performa model dievaluasi untuk menilai tingkat akurasi serta kualitas pembelajaran dari data latih yang digunakan, dengan mengukur kinerja model (Damari et al., 2025).

Tabel 3. Confusion Matrix

	Prediksi Positif	Prediksi Negatif
Positif	TP	FN
Negatif	FP	TN

Pada Tabel 3, True Positive (TP) adalah data yang sebenarnya termasuk dalam kelas positif dan berhasil diprediksi dengan benar sebagai positif oleh model. True Negative (TN) merupakan data yang sebenarnya termasuk dalam kelas negatif dan diprediksi dengan benar sebagai negatif. False Positive (FP) adalah data yang sebenarnya termasuk dalam kelas negatif tetapi oleh model salah diprediksi sebagai positif. Sementara itu, False Negative

(FN) adalah data yang sebenarnya termasuk dalam kelas positif namun salah diprediksi sebagai negatif oleh model.

2.10. Accuracy

Accuracy merupakan perbandingan antara jumlah sampel yang diprediksi dengan benar terhadap total seluruh sampel pada data uji, namun dapat menyesatkan jika proporsi kelas tidak seimbang karena model bisa saja memperoleh akurasi tinggi hanya dengan selalu memprediksi kelas mayoritas, nilai akurasi berada pada rentang (0,1), di mana nilai 1 menunjukkan semua data *positif* dan *negatif* diprediksi benar, sedangkan nilai 0 berarti tidak ada satupun prediksi yang benar (Hicks et al., 2022).

2.11. Precision

Precision digunakan untuk mengukur jumlah data yang sukses diprediksi sebagai positif, dibandingkan dengan seluruh data yang diprediksi positif (Aspiah et al., 2022). Didefinisikan sebagai rasio antara prediksi positif yang benar *true positive* dengan seluruh prediksi positif, nilai *precision* yang tinggi menunjukkan bahwa model memiliki sedikit *false positive* sehingga prediksi positif yang dihasilkan lebih akurat (Sathyanarayanan, 2024).

2.12. Recall

Recall merupakan ukuran performa klasifikasi yang dihitung dari *confusion matrix* dengan rumus, *metrik* ini menunjukkan seberapa banyak kasus *positif* yang berhasil dikenali model dibandingkan dengan total seluruh kasus *positif* sebenarnya, *Metrik* ini menggambarkan kemampuan model dalam meminimalkan kesalahan *false negative*, yaitu kondisi ketika pasien yang terindikasi penyakit justru terklasifikasi sebagai sehat (Sung et al., 2023).

2.13. F1-Score

F1-Score adalah rata-rata *harmonik presisi* dan *recall* yang menyeimbangkan keduanya sehingga nilai ekstrem pada salah satunya akan menurunkan skor, *metrik* ini bergantung pada penentuan kelas *positif* dan *negatif*, Jika model condong pada kelas mayoritas *f1* bisa tampak tinggi tetapi jika label dibalik, nilainya bisa rendah meski distribusi data sama, skor ini berada pada rentang (0–1), dengan 1 berarti *presisi* dan *recall* sempurna, sedangkan (0) berarti keduanya gagal (Salsabila et al., 2025).

III. HASIL DAN PEMBAHASAN

3.1. Data Cleaning

Diagram pada Gambar 1 memperlihatkan rekapitulasi vital dalam tahapan pra-pemrosesan data, khususnya pada prosedur penjaminan validitas melalui *deduplikasi*, dari total 1.025 baris data mentah yang dikumpulkan, dilakukan eliminasi masif terhadap 723 sampel duplikat tinggi berjumlah 302 baris.

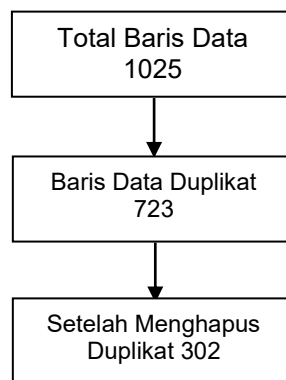


Diagram 1. Hasil *Cleaning* Data

3.2. Data Standarisasi

Berdasarkan Tabel 4 mengenai hasil *standarisasi* bahwa setiap atribut telah ditransformasikan ke dalam skala dengan

rata-rata mendekati nol dan simpangan baku satu, sehingga nilai data berada pada rentang positif maupun negatif. Nilai negatif mengindikasikan posisi data di bawah rata-

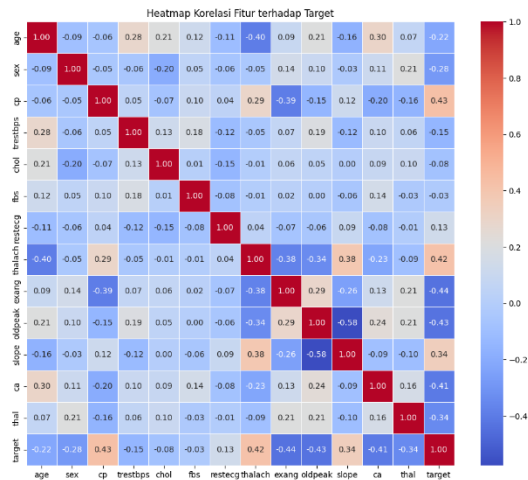
rata, sedangkan nilai positif menunjukkan data berada di atas rata-rata, besar kecilnya nilai merepresentasikan jarak terhadap pusat distribusi.

Tabel 4. Data Standarisasi

No	Age	Sex	Cp	Trestbps	Chol	Fbs	Restecg	Thalach	Oldpeak	Slope	Ca	target
1	-0,267966	1	0	-0,376556	-0,667728	0	1	0,806035	-0,037124	2	2	0
2	-0,157260	1	0	0,478910	-0,841918	1	0	0,237495	1,773958	0	0	0
3	1,724733	1	0	0,764066	-1,403197	0	1	-1,074521	1,342748	0	0	0
4	0,728383	1	0	0,935159	-0,841918	0	1	0,499898	-0,899544	2	1	0
5	0,839089	0	0	0,364848	0,919336	1	1	-1,905464	0,739054	1	3	0

Berdasarkan diatas hasil *standarisasi* bahwa setiap atribut telah ditransformasikan ke dalam skala dengan rata-rata mendekati nol dan simpangan baku satu, sehingga nilai data berada pada rentang positif maupun negatif. Nilai negatif mengindikasikan posisi data di bawah rata-rata, sedangkan nilai positif menunjukkan data berada di atas rata-rata, besar kecilnya nilai merepresentasikan jarak terhadap pusat distribusi.

3.3. Feature Selection Correlation



Gambar 2. Heatmap Correlation

Analisis *Heatmap Feature Selection Correlation* menunjukkan bahwa beberapa atribut memiliki hubungan yang cukup kuat

terhadap variabel *target*. Atribut *cp* (0,432080) dan *thalach* (0,419955) menunjukkan korelasi positif tertinggi yang mengindikasikan peningkatan nilainya berkaitan dengan meningkatnya kemungkinan penyakit jantung. Sebaliknya, *exang* (-0,435601), *oldpeak* (-0,429146), dan *ca* (-0,408992) memiliki korelasi negatif relatif kuat yang menandakan hubungan berlawanan terhadap *target*. Sementara itu, *fbs* (-0,026826) menunjukkan korelasi sangat rendah sehingga kontribusinya dianggap tidak signifikan dan dieliminasi untuk meningkatkan efisiensi model.

3.4. Pembagian K10-Fold Cross Validation

Fold 01	Data Latih: 271 baris	Data Uji: 31 baris
Fold 02	Data Latih: 271 baris	Data Uji: 31 baris
Fold 03	Data Latih: 272 baris	Data Uji: 30 baris
Fold 04	Data Latih: 272 baris	Data Uji: 30 baris
Fold 05	Data Latih: 272 baris	Data Uji: 30 baris
Fold 06	Data Latih: 272 baris	Data Uji: 30 baris
Fold 07	Data Latih: 272 baris	Data Uji: 30 baris
Fold 08	Data Latih: 272 baris	Data Uji: 30 baris
Fold 09	Data Latih: 272 baris	Data Uji: 30 baris
Fold 10	Data Latih: 272 baris	Data Uji: 30 baris

Gambar 3. Hasil Pembagian Data

Gambar 3, merupakan visualisasi penerapan teknik *K-10 Fold Cross Validation* pada dataset yang terdiri dari 302 sampel data, karena jumlah data tidak dapat dibagi secara merata ke dalam sepuluh fold, terdapat variasi kecil pada jumlah data latih dan data uji pada setiap fold, di mana data latih berkisar antara

271 hingga 272 sampel dan data uji berjumlah 30 hingga 31 sampel data.

3.5. Hasil Metode Logistic Regression

Tabel 5. Hasil Logistic Regression

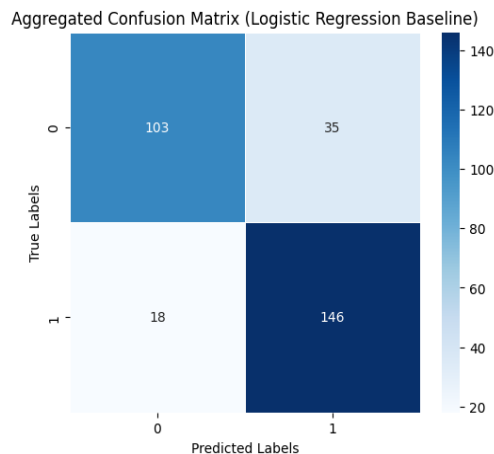
Fold	Accuracy	Precision	Recall	F1-Score
1	77.42%	72.22%	86.67%	78.79%
2	80.65%	75.00%	85.71%	80.00%
3	83.33%	76.47%	92.86%	83.87%
4	73.33%	75.00%	83.33%	78.95%
5	90.00%	86.36%	100.00%	92.68%
6	86.67%	88.89%	88.89%	88.89%
7	76.67%	76.92%	71.43%	74.07%
8	90.00%	90.00%	94.74%	92.31%
9	83.33%	83.33%	88.24%	85.71%
10	83.33%	78.95%	93.75%	85.71%

Hasil pengujian metode *Logistic Regression* menggunakan *K-10 Fold Cross Validation* yang dievaluasi dengan *Confusion Matrix*, hasil pengujian menunjukkan nilai kinerja tertinggi dengan *Accuracy* 90,00%, *Precision* 90,00%, *Recall* 100,00%, dan *F1-Score* 92,68%, sedangkan nilai terendah diperoleh dengan *Accuracy* 73,33%, *Precision* 72,22%, *Recall* 71,43%, dan *F1-Score* 74,07%, yang menandakan adanya variasi performa model pada setiap *fold*.

Tabel 6. Rata-Rata Logistic Regression

Hasil Rata-Rata			
Accuracy	Precision	Recall	F1-Score
82.47%	80.31%	88.56%	84.10%

Ringkasan kinerja rata rata atau *mean performance* dari model *Logistic Regression* yang diperoleh melalui perhitungan nilai *average* setelah data melewati tahapan *data selection*, *data cleaning*, *standarisasi*, lalu *Feature Selection Correlation* kemudian dilakukan pembagian dataset menggunakan *K10 Fold Cross Validation* sehingga menghasilkan nilai akhir berupa *Accuracy* sebesar 82.47%, *Precision* 80.31%, *Recall* 88.56%, serta *F1-Score* 84.10%.



Gambar 4. Confusion Matrix Baseline

Representasi *Confusion Matrix* menunjukkan hasil prediksi model total 302 data uji, di mana model mampu mengklasifikasikan kelas positif secara benar 146 data sebagai *True Positive* serta kelas negatif sebanyak 103 data sebagai *True Negative*, sementara kesalahan prediksi tercatat pada 35 data sebagai *False Positive* serta 18 data sebagai *False Negative*, berdasarkan akumulasi hasil tersebut, kinerja model menghasilkan nilai *Accuracy* sebesar 82,45% yang diperoleh dari perbandingan 249 prediksi benar terhadap keseluruhan data, tingkat keandalan prediksi positif ditunjukkan oleh *Precision* sebesar 80,66%, sedangkan kemampuan sensitivitas model dalam mendeteksi seluruh kasus positif yang direpresentasikan oleh *Recall* mencapai 89,02% dan *F1-Score* sebesar 84,59% yang mencerminkan rata-rata harmonis antara *Precision* serta *Recall*.

3.6. Hasil Metode Logistic Regression+PSO

Kinerja model *Logistic Regression* setelah dilakukan proses optimasi menggunakan metode *Particle Swarm Optimization (PSO)* melalui proses pembaruan kecepatan dan penyesuaian posisi partikel untuk mencari parameter *C* pada *Regularisasi L2* yang optimal sehingga diperoleh hasil kinerja

tertinggi berupa *Accuracy* sebesar 93.33%, *Precision* 94.44%, *Recall* 100.00%, serta *F1-Score* 94.44%.

Tabel 7. Hasil *Logistic Regression+PSO*


Fold	Accuracy	Precision	Recall	F1-Score
1	77.42%	72.22%	86.67%	78.79%
2	87.10%	81.25%	92.86%	86.67%
3	86.67%	81.25%	92.86%	86.67%
4	73.33%	75.00%	83.33%	78.95%
5	90.00%	86.36%	100.00%	92.68%
6	93.33%	94.44%	94.44%	94.44%
7	76.67%	76.92%	71.43%	74.07%
8	90.00%	90.00%	94.74%	92.31%
9	86.67%	80.95%	100.00%	89.47%
10	83.33%	78.95%	93.75%	85.71%

Tabel 8. Rata-Rata *Logistic Regression+PSO*

Hasil Rata-Rata			
Akurasi	Precision	Recall	F1-Score
84.45%	81.74%	91.01%	85.98%

Perhitungan nilai rata rata atau Perhitungan nilai rata rata atau *average* dari penerapan optimasi *Particle Swarm Optimization (PSO)* sehingga terjadi peningkatan kinerja model yang ditunjukkan oleh nilai *Accuracy* sebesar 84.45% sementara nilai *Precision* meningkat menjadi 81.74%, nilai *Recall* mencapai 91.01% serta *F1-Score* turut meningkat menjadi 85.98%.

Aggregated Confusion Matrix (Logistic Regression + PSO)



Gambar 5. *Confusion Matrix LR + PSO*

Representasi perhitungan *Confusion Matrix* pada model *Logistic Regression* yang telah dioptimasi menggunakan *Particle Swarm Optimization (PSO)* menunjukkan distribusi hasil prediksi terhadap total 302 data uji, model mampu mengklasifikasikan kelas positif secara benar sebanyak 150 data sebagai *True Positive* serta kelas negatif sebanyak 105 data sebagai *True Negative*, kesalahan prediksi tercatat pada 33 data sebagai *False Positive* dan 14 data sebagai *False Negative*, berdasarkan hasil tersebut, model menghasilkan nilai *Accuracy* sebesar 84,44%, *Precision* 81,97%, *Recall* 91,46%, serta *F1-Score* 86,46%, nilai *recall* yang tinggi menunjukkan bahwa optimasi *PSO* mampu meningkatkan sensitivitas model dalam mendeteksi kasus penyakit jantung dibandingkan dengan model *Logistic Regression* tanpa optimasi.

3.7. Pembahasan *Logistic Regression+PSO*

Pada penelitian ini proses analisis *Feature Selection Correlation* dengan melibatkan seluruh atribut untuk mengukur hubungan linier antara setiap fitur dengan variabel target dimana hasil *heatmap* menunjukkan bahwa atribut *cp* serta *thalach* memiliki *correlation* positif relatif kuat terhadap target sedangkan atribut *exang*, *oldpeak*, dan *ca* memperlihatkan *correlation* negatif yang cukup signifikan, di sisi lain atribut *lbs* memiliki nilai *correlation* sangat rendah dan mendekati nol sehingga dianggap tidak memiliki kontribusi linier yang berarti terhadap target lalu dieliminasi dari dataset.

Tabel 9. Perbandingan Akhir

Confusion Matrix	Accuracy	Precision	Recall	F1-Score
<i>Logistic Regression</i>	82.47%	80.31%	88.56%	84.10%
<i>Logistic Regression + PSO</i>	84.45%	81.74%	91.01%	85.98%
Perubahan	+1.98%	+1.43%	+2.45%	+1.88%

Berdasarkan hasil pengujian pada tahap awal dengan model *Logistic Regression* Pada tahap berikutnya yaitu merupakan perbandingan dengan penggunaan model *Correlation* didapatkan bahwa fitur *fb*s dihapus dari atribut karena nilai yang rendah, hasil dari model *Logistic Regression* menghasilkan *Accuracy* sebesar 82,47%, *Precision* 80,31%, *Recall* 88,56%, dan *F1-Score* 84,10%, lalu pada optimasi *PSO* didapatkan *Accuracy* sebesar 84,45%, *Precision* 81,74%, *Recall* 91,01%, dan *F1-Score* 85,98%, hasil ini diperkuat pada penelitian penyakit diabetes dengan optimasi *PSO* dikombinasikan dengan *Logistic Regression* didapatkan *Accuracy* senilai 97% dari sebelumnya 76% (Jibril et al., 2023). peningkatan tersebut ditunjukkan oleh nilai *Accuracy* sebesar 1,98%, *Precision* 1,43%, *Recall* 2,45%, dan *F1-score* 1,88%, hasil ini mengindikasikan bahwa optimasi *PSO* berperan dalam menyesuaikan bobot parameter *C* pada model *Logistic Regression* dengan optimalisasi *Regularisasi L2* lebih optimal sehingga mampu meningkatkan kemampuan deteksi penyakit jantung.

IV. KESIMPULAN

Berdasarkan hasil penelitian, penerapan model *Hybrid Logistic Regression* yang dioptimasi menggunakan *Particle Swarm Optimization* (*PSO*) mampu meningkatkan performa deteksi penyakit jantung. Tahap *Feature Selection Correlation* menunjukkan bahwa atribut *fb*s dieliminasi karena memiliki nilai korelasi yang sangat rendah sehingga kurang berkontribusi terhadap proses klasifikasi. Model *Logistic Regression* menghasilkan *Accuracy* 82,47%, *Precision* 80,31%, *Recall* 88,56%, dan *F1-score* 84,10%. Setelah dilakukan optimasi *PSO*, kinerja model meningkat menjadi *Accuracy* 84,45%, *Precision* 81,74%, *Recall* 91,01%, dan *F1-score* 85,98%, dengan peningkatan *Recall* dan *Accuracy* yang menunjukkan

kemampuan deteksi kasus positif yang lebih baik.

DAFTAR PUSTAKA

- Adhitya, R. R., Witanti, W., & Yuniarti, R. (2023). Perbandingan metode CART dan Naïve Bayes untuk klasifikasi customer churn. *INFOTECH Journal*, 9(2), 307–318. <https://doi.org/10.31949/infotech.v9i2.5641>
- Agarwal, N., Deepakshi, Harikiran, J., Lakshmi, Y. B., Kumar, A. P., Muniandy, E., & Verma, A. (2024). Predictive modelling for heart disease diagnosis: A comparative study of classifiers *EAI Endorsed Transactions on Pervasive Health and Technology*, 10,1–11. <https://doi.org/10.4108/eetpht.10.5518>
- Permana, A. A. (2024). Implementasi Metode K-Nearest Neighbors (KNN) untuk Klasifikasi Penyakit Jantung. *G-Tech: Jurnal Teknologi Terapan*, 8(1), 186–195.
- Aspiah, R., Azhima, T., & Siswa, Y. (2022). Implementasi correlation based feature selection (CFS) untuk peningkatan akurasi algoritma C4.5 dalam prediksi performa akademik mahasiswa berbasis learning management system. *Jurnal Ilmiah Betrik*, 13(3), 199–207.
- Bietrosula, A. B., Werdiningsih, I., & Wuriyanto, E. (2024). Classification of cardiovascular disease based on lifestyle using random forest and logistic regression methods. *International Journal of Electrical and Electronic Engineering*, 12(2). <https://doi.org/10.52549/ijeei.v12i2.5388>

- Black, J. E., Kueper, J. K., & Williamson, T. S. (2023). An introduction to machine learning for classification and prediction. *Family Practice*, 40(1), 200–204. <https://doi.org/10.1093/fampra/cm104>
- Wibowo, A. C., Lestari, S. A., & Nurchim, N. (2024). Analisis penggunaan machine learning dalam klasifikasi penentuan penyakit jantung. *Simtek: Jurnal Sistem Informasi dan Teknik Komputer*, 9(2), 97–101. <https://doi.org/10.51876/simtek.v9i2.395>
- Damari, A., Azhima, T., Siswa, Y., & Pranoto, W. J. (2025). Penerapan metode PSO-SMOTE pada algoritma Naive Bayes untuk mengatasi class imbalance data bencana tanah longsor. *Jurnal Inovtek Polbeng*, 10(1), 332–343.
- Dinova, D. B., & Prasetyo, B. (2024). Implementasi random forest dalam klasifikasi kanker paru-paru. *JOINTER: Journal of Informatics Engineering*, 5(1), 27–31.
- Elshevey, A. M., Abed, A. H., Khafaga, D. S., Alhussan, A. A., Eid, M. M., & El-Kenawy, E. S. M. (2025). Enhancing heart disease classification using optimization algorithm and LSTM. *Scientific Reports*, 15(1), 1–21. <https://doi.org/10.1038/s41598-024-83592-0>
- Fan, C., Chen, M., Wang, X., Wang, J., & Huang, B. (2021). A review on data preprocessing techniques toward efficient knowledge discovery. *Frontiers in Energy Research*, 9, 1–17. <https://doi.org/10.3389/fenrg.2021.652801>
- Firnanda, P. A., Litaysa, S., Rahma, F., & Fauzi, F. (2025). Analisis perbandingan decision tree dan random forest dalam klasifikasi penjualan produk pada supermarket. *Emerging Statistics and Data Science Journal*, 3(1), 445–461.
- Harris, J. K. (2021). Primer on binary logistic regression. *Family Medicine and Community Health*, 9, 1–7. <https://doi.org/10.1136/fmch-2021-001290>
- Hicks, S. A., Strümke, I., Thambawita, V., Hammou, M., Riegler, M. A., Halvorsen, P., & Parasa, S. (2022). On evaluation metrics for medical applications of artificial intelligence. *Scientific Reports*, 12(1), 1–9. <https://doi.org/10.1038/s41598-022-09954-8>
- Hidayat, R., Saputra, Y., Sujana, T., Husnah, M., & Saputra, H. T. (2024). Implementasi machine learning untuk prediksi penyakit jantung menggunakan algoritma support vector machine. *BIOS: Jurnal Teknologi Informasi dan Rekayasa Komputer*, 5(2), 161–168.
- Jain, M., Saihjpal, V., Singh, N., & Singh, S. B. (2022). An overview of variants and advancements of PSO algorithm. *Applied Sciences*, 12(17), 1–21. <https://doi.org/10.3390/app12178392>
- Jibril, A. U., Haruna, K., & Jiangsheng, Z. (2023). Feature selection and parameter optimization using PSO. *Journal of Computer Science and*

- Technology*, 11(1), 21–47.
<https://doi.org/10.15640/jcsit.v11n1a3>
- Junifer, J., Tanjaya, H., & Kenichi, K. (2021). Mendeteksi penyakit jantung menggunakan logistic regression. *Journal Information System Development*, 6(2), 1–10.
- Markoulidakis, I., Rallis, I., Georgoulas, I., Kopsiaftis, G., Doulamis, A., & Doulamis, N. (2021). Multiclass confusion matrix reduction method. *Technologies*, 9(4).
<https://doi.org/10.3390/technologies9040081>
- Oise, G. P., Oyedotun, S. A., Nwabuokei, O. C., Babalola, A. E., & Unuigbokhai, N. B. (2025). Enhanced prediction of coronary artery disease using logistic regression. *Fudma Journal of Sciences*, 9(3), 201–208.
<https://doi.org/10.33003/fjs-2025-0903-3263>
- Oon, W. Y., Tuti, D., Yee, L. S., & Susanti. (2022). Penerapan data mining untuk klasifikasi kelulusan mahasiswa. *SATIN - Sains dan Teknologi Informasi*, 8(2), 122–131.
<https://doi.org/10.33372/stn.v8i2.885>
- World Health Organization. (2025). Cardiovascular diseases.
<https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases>
- Ratnasari, R., Wahidin, J., Setiawan, A. E., & Bintoro, P. (2024). Machine learning untuk klasifikasi penyakit jantung. *Aisyah Journal of Informatics and Electrical Engineering*, 6(1), 145–150.
<https://doi.org/10.30604/jti.v6i1.272>
- Kementerian Kesehatan RI. (2024). Kenali gejala jantung sejak dini.
<https://kemkes.go.id/id/kenali-gejala-jantung-sejak-dini>
- Rojas, R., Seseña, H., Zuñiga, M., & Martínez, M. (2024). Performance comparison in optimization algorithms. *Revista de Ciencias de la Salud*, 1–8.
<https://doi.org/10.35429/johs.2024.11.30.1.8>
- Salsabila, C. A., Yulianto, F., & Siswa, T. A. Y. (2025). Implementasi metode Naive Bayes untuk klasifikasi kecelakaan lalu lintas. *Jurnal Informatika dan Teknik Elektro Terapan*, 13(1).
<https://doi.org/10.23960/jitet.v13i1.5890>
- Sani, N. S., Esa, M. I., & Musawi, B. A. (2023). Malware detection using deep learning and correlation-based feature selection. *Symmetry*, 15(3).
- Saputra, D., Dharmawan, W. S., & Irmayani, W. (2022). Performance comparison of SVM and SVM-PSO algorithms. *International Journal of Advances in Data and Information Systems*, 3(2), 74–86.
<https://doi.org/10.25008/ijadis.v3i2.1243>
- Sathyanarayanan, S. (2024). Confusion matrix-based performance evaluation metrics. *African Journal of Biomedical Research*, 4023–4031.
<https://doi.org/10.53555/ajbr.v27i4s.4345>
- Separni, A., Hendrawan, I. E., & Rozikin, C. (2022). Klasifikasi penyakit jantung menggunakan algoritma C4.5. *STRING*, 7(2), 117.
<https://doi.org/10.30998/string.v7i2.12012>

- Setiani, H., Sunyoto, A., & Nasiri, A. (2022). Metode Naïve Bayes dan particle swarm optimization untuk klasifikasi penyakit jantung. *Explore*, 12(2), 6. <https://doi.org/10.35200/explore.v12i2.566>
- Sonjaya, C., Masruriyah, A. F. N., Kusumaningrum, D. S., & Pratama, A. R. (2022). Performance comparison of classification algorithm. *INTERNAL Journal*, 5(2), 166–175. <https://doi.org/10.32627/internal.v5i2.595>
- Sung, W. T., Isa, I. G. T., & Hsiao, S. J. (2023). Designing aquaculture monitoring system based on data fusion. *Electronics*, 12(9). <https://doi.org/10.3390/electronics12092032>
- Taher, H. A., & Abdulazeez, A. M. (2023). Machine learning approaches for heart disease detection. *International Journal of Research and Applied Technology*, 3(2), 267–282.
- Yi, J., Yu, P., Huang, T., & Xu, Z. (2024). Optimization of transformer heart disease prediction model. *ICFTIC Proceedings*, 1109–1113. <https://doi.org/10.1109/ICFTIC64248.2024.10913096>
- Zabor, E. C., Reddy, C. A., Tendulkar, R. D., & Patil, S. (2022). Logistic regression in clinical studies. *International Journal of Radiation Oncology Biology Physics*, 112(2), 271–277. <https://doi.org/10.1016/j.ijrobp.2021.08.007>
- Zhang, L., Geisler, T., Ray, H., & Xie, Y. (2022). Improving logistic regression on imbalanced data. *Journal of Applied Statistics*, 49(13), 3257–3277. <https://doi.org/10.1080/02664763.2021.1939662>
- Zhu, Y., & Liu, R. (2021). An algorithmic view of L2 regularization. *Journal of Machine Learning Research*, 22, 1–62.