



Evaluasi Performa Algoritma *Supervised Learning* untuk Prediksi Risiko Serangan Jantung: Pendekatan Rekayasa Sistem Cerdas

A Nugraha^a, D Rimirasih^{b,*}

^{a,b}Program Studi Informatika, Fakultas Teknologi Industri, Universitas Gunadarma, Jl. Margonda Raya No. 100, Depok 16424, Jawa Barata

INFORMASI ARTIKEL

Riwayat artikel:
Diterima 14 Maret 2025
Diterbitkan 24 Juni 2025

Kata kunci:

Serangan jantung
Gradient Boosting
Logistic Regression
Naive Bayes
Random Forest

ABSTRAK

Serangan jantung merupakan salah satu penyebab kematian tertinggi di negara berkembang. Penyakit ini terjadi akibat tersumbatnya aliran darah ke otot jantung akibat penyempitan atau penyumbatan arteri koroner. Faktor risiko serangan jantung terdiri atas faktor yang dapat diubah, seperti pola hidup, dan faktor yang tidak dapat diubah, seperti usia dan riwayat keluarga. Deteksi dini terhadap risiko serangan jantung sangat penting untuk meminimalkan angka kematian. Penelitian ini bertujuan untuk membangun dan mengevaluasi model prediksi risiko serangan jantung dengan mengelompokkan pasien ke dalam dua kategori, yaitu risiko rendah dan risiko tinggi, menggunakan pendekatan rekayasa sistem cerdas berbasis *supervised learning*. Proses penelitian mencakup tahap pengumpulan data, eksplorasi data, pemilihan fitur, pra-pemrosesan data, pelatihan model, serta pengujian model untuk evaluasi performa model menggunakan metrik akurasi. Model klasifikasi dibangun dengan empat algoritma *supervised learning* yaitu Gradient Boosting, Random Forest, Naive Bayes, dan Logistic Regression. Pada pelatihan model digunakan 10-fold cross validation untuk melihat akurasi dan konsistensi model. Hasil pengujian menunjukkan bahwa algoritma Naive Bayes memiliki akurasi tertinggi sebesar 90%, diikuti oleh Logistic Regression dan Random Forest (88%), dan Gradient Boosting. Model Naive Bayes tetap menunjukkan performa terbaik tidak hanya akurasi tertinggi tetapi juga nilai precision dan F1-score tertinggi untuk kelas positif, serta recall tertinggi untuk kelas negatif. Oleh karena itu, Naive Bayes dinilai sebagai model yang paling andal dan direkomendasikan untuk prediksi risiko serangan jantung secara dini, karena mampu memberikan klasifikasi yang seimbang dan akurat dalam konteks aplikasi medis.

1. Pendahuluan

Penyakit serangan jantung, atau dikenal juga sebagai infark miokard, merupakan salah satu penyebab utama kematian di seluruh dunia. Penyakit ini terjadi ketika aliran darah ke otot jantung terhambat, biasanya disebabkan oleh penyumbatan pada satu atau lebih arteri koroner. Kondisi ini bisa berakibat fatal jika tidak ditangani dengan cepat dan tepat.

Dalam beberapa dekade terakhir, insidensi penyakit ini terus meningkat, terutama di negara-negara berkembang, seiring dengan perubahan gaya hidup dan pola makan. Menurut data Organisasi Kesehatan Dunia (WHO), penyakit kardiovaskular, termasuk serangan jantung, merupakan penyebab kematian nomor satu secara global, bertanggung jawab atas sekitar 17,9 juta kematian setiap tahun (WHO, 2024). Di Indonesia, data dari Kementerian Kesehatan menunjukkan bahwa penyakit jantung

koroner adalah salah satu penyebab utama kematian (Rokom, 2022). Tren ini menunjukkan adanya urgensi untuk memahami faktor-faktor penyebab dan mencari solusi untuk mengurangi angka kejadian serta mortalitas akibat penyakit ini.

Perkembangan teknologi informasi telah diimplementasikan pada bidang kesehatan, mulai dari analisis pengolahan citra medis terkait salah satu penyakit kardiovaskular terkait aneurisma pada aorta (D Rimirasih dkk, 2016), implemetasi deep learning pada citra medis berupa citra chest x-ray untuk penyakit paru-paru (NP Ekananda dan D Rimirasih, 2022), analisis citra kulit untuk prediksi kanker kulit (Suryana dkk, 2024), hingga analisis pada data rekamedis pasien untuk prediksi metode persalinan (Prihandoko dkk, 2024). Fenomena ini semakin berkembang termasuk dalam analisis data rekam medis pasien untuk memprediksi resiko serangan jantung.

*Penulis korespondensi.

E-mail: destimath@staff.gunadarma.ac.id

Beberapa penelitian terdahulu telah memprediksi resiko serangan jantung dengan berbagai model dengan machine learning. (Oscar, 2024) memprediksi resiko serangan jantung dengan menggunakan Naive Bayes, hasil pengujian menunjukkan nilai akurasi di angka 79,92% %. Wahyu (2021) memprediksi resiko serangan jantung dengan nilai akurasi 0,77 atau 77% dari hasil model Random Forest dan nilai akurasi sebesar 0,78 atau 78% dari model Gradient Boosting. (Dharmawan, 2024) memprediksi resiko serangan jantung menggunakan model Logistic Regression dengan nilai akurasi sebesar 0,7631 atau 76%.

Tujuan penelitian ini adalah membangun model prediksi resiko seseorang mengalami serangan jantung menggunakan model Gradient Boosting, Random Forest, Naive Bayes, dan Logistic Regression dan membandingkan model mana yang memiliki performa terbaik.

1.1. Serangan Jantung

Serangan jantung dikenal juga dengan infark miokard. Serangan jantung adalah kondisi dimana terjadi kerusakan jaringan jantung yang menyebabkan berkurangnya atau terhentinya aliran darah ke sebagian otot jantung (miokardium). Sebagian besar kasus serangan jantung karena penyempitan atau penyumbatan pada arteri yang mensuplai darah ke jantung. Aliran darah yang tersumbat mengakibatkan suplai oksigen ke jantung berkurang dan dalam jangka Waktu lama akan menyebabkan kematian sel pada otot jantung. Serangan jantung bisa bersifat asimtomatik (silent), tanpa disadari oleh pasien, namun juga bisa terjadi secara akut dan fatal, dengan gejala penurunan tekanan darah yang cepat hingga kematian mendadak (Ojha N dkk, 2025).

Ada berbagai faktor risiko yang berkontribusi terhadap meningkatnya kejadian serangan jantung. Faktor risiko tersebut dibagi menjadi dua kategori: faktor risiko yang dapat diubah dan yang tidak dapat diubah. Studi internasional INTERHEART yang melibatkan 52 negara mengidentifikasi sembilan faktor risiko utama yang dapat dimodifikasi dan berkontribusi terhadap lebih dari 90% kasus infark miokard. Faktor-faktor tersebut meliputi merokok, profil lipid abnormal, hipertensi, diabetes melitus, obesitas abdominal, stres, kurang konsumsi buah dan sayur, minimnya aktivitas fisik, serta konsumsi alkohol yang menunjukkan asosiasi lemah namun protektif dalam beberapa kasus (Yusuf et al., 2004).

Kebiasaan merokok dan ketidakseimbangan rasio apolipoprotein terbukti memiliki asosiasi paling kuat terhadap kejadian infark miokard akut. Risiko yang ditimbulkan oleh hipertensi dan diabetes ditemukan lebih tinggi pada perempuan, demikian juga efek protektif dari olahraga dan konsumsi alkohol ringan (Anand et al., 2008). Selain itu, kadar homosistein plasma yang tinggi diakui sebagai faktor risiko independen yang dapat dimodifikasi dengan pemberian asam folat, vitamin B6, dan vitamin B12 (Nygård et al., 1997).

Faktor risiko yang tidak dapat diubah meliputi usia lanjut, jenis kelamin laki-laki (pria cenderung mengalami infark lebih awal), serta riwayat keluarga dengan penyakit jantung sebelum usia 50 tahun. Studi terbaru juga tengah meneliti kontribusi genetik melalui penemuan berbagai lokus genetik yang berkaitan dengan peningkatan risiko penyakit arteri koroner dan infark miokard (McPherson et al., 2007; Kathiresan & Srivastava, 2012).

1.2. Supervised Learning

Pada penelitian ini digunakan empat model *supervised learning* yang terdiri dari *Gradient Boosting*, *Random Forest*, *Naive Bayes*, dan *Logistic Regression*. Dua model awal merupakan *ensemble model* dengan model base berupa *tree*.

Gradient boosting merupakan salah satu algoritma machine learning yang diperkenalkan Friedman (2001). Gradient boosting sebagai aproksimasi fungsi dengan teknik *greedy* berbasis prinsip boosting, yang dilakukan melalui optimasi bertahap menggunakan pendekatan *gradient descent* dalam ruang fungsi.

$$F^*(x) = \arg \min_F \sum_{i=1}^n L(y_i, F(x_i)) \quad (1)$$

Pada persamaan (1) ditunjukkan tujuan utama dari *gradient boosting* yaitu meminimalkan $F(x)$ suatu fungsi prediksi yang dapat meminimalkan *expected value* dari suatu fungsi *Loss* $L(y_i, F(x_i))$.

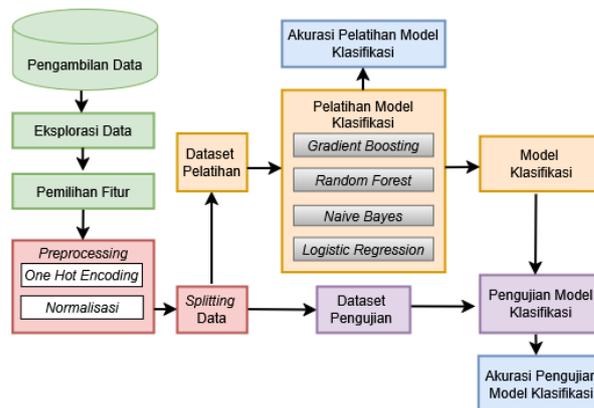
Random Forest adalah metode *ensemble* yang terdiri dari sejumlah base model berupa *decision tree* yang dilatih secara independen menggunakan teknik *bagging* dan pemilihan acak *subset* fitur. Prediksi akhir dari model klasifikasi ditentukan berdasarkan voting sedangkan untuk model regresi ditentukan berdasarkan rata-rata dari seluruh *tree* (Breiman, 2001).

Naive Bayes merupakan metode klasifikasi berbasis probabilistik berdasarkan Teorema Bayes sebagai dasar prediksi.

$$P(C_k|x) = \frac{P(C_k)P(x|C_k)}{P(x)} \quad (2)$$

Pada Persamaan (2) ditunjukkan Teorema Bayes dimana $P(C_k|x)$ adalah probabilitas posterior dari kelas C_k saat diberikan fitur x . $P(C_k)$ adalah probabilitas prior dari kelas C_k sedangkan $P(x|C_k)$ adalah probabilitas fitur x muncul jika diketahui kelas C_k . $P(x)$ dapat diabaikan karena bernilai konstan yang merupakan probabilitas fitur x secara keseluruhan. Asumsi yang diperlukan pada *Naive Bayes* adalah antar fitur dianggap tidak saling bergantung satu sama lain, dengan syarat bahwa kelas target diketahui atau dikenal dengan independensi bersyarat. Pada kehidupan nyata, asumsi ini sulit terpenuhi. Zhang (2004) menunjukkan bahwa meskipun asumsi tidak terpenuhi, Naive Bayes tetap optimal dalam banyak kasus prediksi, terutama ketika fitur saling mendukung kelas target meskipun tidak benar-benar independen. *Logistic Regression* merupakan metode untuk memodelkan peluang dari kejadian biner sebagai fungsi linier dari variabel-variabel input (Cox, 1958). *Logistic Regression* memodelkan logit dari probabilitas kejadian. Fungsi logit adalah logaritma dari perbandingan antara probabilitas sukses dan gagal. Probabilitas sukses dapat dituliskan menggunakan fungsi sigmoid (*logistic function*) dengan merepresentasikan logit sebagai fungsi linier (Hosmer, 2013).

2. Metodologi



Gambar 1. Diagram alur penelitian

Tahapan yang dilakukan dalam penelitian dapat dilihat pada Gambar 1. Penelitian diawali dengan pengambilan data, dilanjutkan dengan eksplorasi data, pemilihan fitur dan preprocessing fitur terpilih. Setelah itu dilakukan *splitting* data menjadi 2 yaitu dataset pelatihan dan dataset pengujian. Dataset pelatihan digunakan dalam proses pelatihan model untuk menghasilkan model klasifikasi. Selanjutnya, model tersebut digunakan untuk prediksi menggunakan dataset pengujian untuk mendapatkan akurasi model.

2.1 Pengumpulan Data

Dataset pada penelitian ini merupakan data sekunder. Data diambil dari web Kaggle dengan alamat URL <https://www.kaggle.com/datasets/johnsmith88/heart-disease-dataset> yang berasal dari database Cleveland, Hungaria, Swiss dan Long Beach. Dataset ini memiliki 303 record dan 14 kolom yang terdiri dari 1 kolom kelas atau target dan 13 kolom atribut yang mengacu pada faktor resiko serangan jantung. Pada penelitian ini data dikelompokkan ke dalam 2 kelas serangan jantung yaitu resiko rendah dan resiko tinggi.

2.2 Eksplorasi Data

Eksplorasi data merupakan tahapan penting sebelum pelatihan model karena sangat mempengaruhi keberhasilan model dalam melakukan klasifikasi. Eksplorasi data dilakukan untuk mendapatkan informasi umum terkait data yang meliputi banyaknya data, banyaknya atribut, tipe data tiap atribut, adanya missing value, adanya data ganda atau *redundant*. Tipe data tiap atribut sangat penting untuk menentukan uji yang digunakan dalam menganalisis hubungan antara atribut tersebut dengan target. Tipe data dikelompokkan menjadi tipe data kategorik dan numerik.

Proses ini memungkinkan untuk menemukan dan memperbaiki masalah yang ada dalam kumpulan data sebelum melanjutkan ke tahap analisis atau pemodelan lebih lanjut. Data yang terduplikat dan data yang memiliki nilai tidak valid (NaN) akan dihapus untuk menindaklanjuti kecacatan data tersebut. Tujuan penghapusan data adalah untuk mencegah hasil analisis dan statistik menjadi salah karena nilai yang duplikat atau hilang, selain itu juga memastikan bahwa data yang digunakan representatif dan tidak mengandung informasi tambahan, langkah ini bertujuan untuk meningkatkan akurasi model.

2.3 Pemilihan Fitur

Tahapan pemilihan fitur dilakukan dengan analisis bivariat antara atribut dengan kelas. Analisis bivariat dilakukan menggunakan uji hipotesis untuk melihat independensi antara atribut dengan kelas. Uji hipotesis dilakukan dengan memperhatikan tipe data atribut. Kelas atau target pada penelitian ini merupakan data dengan tipe kategorik (rendah dan tinggi). Uji hypothesis independensi antara data atribut bertipe numerik dengan kelas dilakukan menggunakan uji t sedangkan untuk atribut numerik menggunakan uji Chi Kuadrat.

Tetapkan hipotesis nol (H_0) dan hipotesis alternatif (H_1), pada umumnya hipotesis nol mengklaim bahwa 2 populasi yang dites tidak berbeda secara statistically significant. Hipotesis alternatif mengklaim sebaliknya. Pengujian dilakukan pada Tingkat signifikansi 95%. Jika nilai *p-value* hasil pengujian lebih kecil dari 0.05 maka H_0 ditolak. . Apabila H_0 gagal ditolak maka dapat disimpulkan atribut yang dites tidak memiliki kontribusi untuk dapat melakukan klasifikasi. Sebaliknya apabila H_0 ditolak berarti dapat di simpulkan atribut tersebut memiliki kontribusi untuk melakukan klasifikasi.

2.4 Pra-pemrosesan Data

Pra-pemrosesan data adalah tahapan penting dalam analisis data yang bertujuan untuk mempersiapkan data sehingga data siap digunakan dalam pemodelan. Data yang masih mentah tentu tidak bisa langsung dilakukan pemodelan, karena bisa saja terjadi kesalahan saat membaca data tersebut yang mempengaruhi akurasi sehingga akurasi dari model tersebut tidak akurat. Pada penelitian ini pra-pemrosesan data yang dilakukan yaitu One Hot Encoding untuk atribut kategorik dan normalisasi untuk atribut numerik.

2.5 Splitting Data

Splitting data bertujuan untuk membagi dataset menjadi 2 bagian 80% untuk data pelatihan dan 20% untuk data pengujian. Data pelatihan digunakan dalam proses pelatihan model untuk membangun model klasifikasi. Data pengujian merupakan data yang tidak terlibat dalam proses pelatihan model. Data pengujian digunakan untuk menguji model klasifikasi yang dihasilkan pada proses pelatihan. Tujuannya adalah mengevaluasi performa model yang terbentuk.

2.6 Pelatihan Model

Pelatihan model dilakukan menggunakan data pelatihan. Pada penelitian model klasifikasi dibangun dengan menggunakan algoritma Gradient Boosting, Random Forest, Naive Bayes, dan Logistic Regression. Evaluasi performa model pada proses pelatihan dilakukan menggunakan cross validation dengan menguji seberapa baik model akan berkerja pada data yang digunakan pada penelitian ini. Cross-validation dilakukan dengan membagi data menjadi k fold, di mana setiap fold ditentukan melalui stratified random sampling agar distribusi data tetap terjaga di setiap fold. Pada penelitian ini digunakan nilai $k=10$.

2.7 Pengujian Model

Tahapan terakhir pada penelitian ini adalah pengujian model menggunakan data pengujian. Tahap ini dilakukan untuk mengevaluasi performa model klasifikasi yang telah dihasilkan. Evaluasi model dilihat berdasarkan confusion matrix yang menghasilkan ukuran model berupa accuracy, recall, precision, dan f1-score. Model dengan akurasi paling tinggi menunjukkan kemampuan lebih baik dalam memprediksi. Hasil dari evaluasi digunakan untuk membandingkan model dan menentukan model mana yang paling baik akurasinya diantara model yang akan digunakan yaitu, Gradient Boosting, Random Forest, Naive Bayes, dan Logistic Regression.

3. Hasil dan pembahasan

3.1 Dataset Penelitian

Atribut yang dianggap mempengaruhi resiko seseorang mengalami serangan jantung pada dataset ini terdiri dari 13 faktor yang meliputi age (usia), trtbps (tekanan darah istirahat), chol (kadar kolestrol dalam darah), thalachh (detak jantung maksimum), oldpeak (depresi ST disebabkan oleh olahraga dibandingkan istirahat), cp (tipe nyeri dada), rest_ecg (hasil EKG), slp (latihan jantung atau tes stres jantung), caa (pembuluh darah besar diwarnai oleh flourosopy), thall (thalassemia), sex (gender), fbs (kadar gula darah puasa > 120 mg/dl), dan exng (angina yang diinduksi oleh olahraga).

Atribut bertipe numerik pada data penelitian terdiri dari 5 atribut yang meliputi age (usia), trtbps (tekanan darah istirahat),

chol (kadar kolestrol dalam darah), thalachh (detak jantung maksimum, oldpeak (depresi ST disebabkan oleh olahraga dibandingkan istirahat). 8 Atribut yang lain bertipe kategorik.

Tabel 1.
Hasil uji hipotesis atribut numerik

	Atribut	P-value	Keputusan
1.	age	0.00300	H0 ditolak
2.	trtbps	8.59973e-10	H0 ditolak
3.	chol	2.46336e-10	H0 ditolak
4.	thalachh	0.10095	H0 diterima
5.	oldpeak	0.39916	H0 diterima

Pada Tabel 1 ditunjukkan hasil pengujian hipotesis atribut dengan tipe numerik. Berdasarkan nilai *p-value* maka atribut yang digunakan adalah atribut yang memiliki keputusan H0 ditolak. H0 ditolak artinya H1 diterima artinya ada perbedaan rata-rata antar kelas rendah dan tinggi sehingga disimpulkan atribut tersebut berkontribusi dalam melakukan klasifikasi.

Tabel 2.
Hasil uji hipotesis atribut kategorik

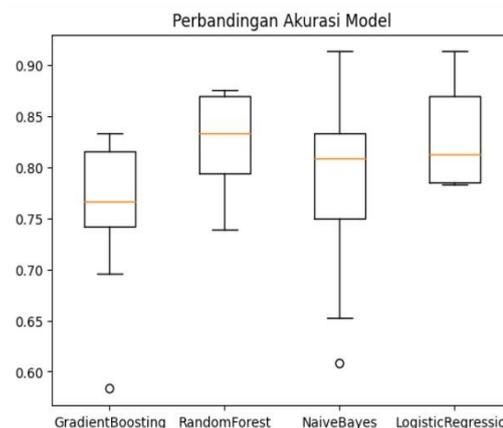
	Atribut	P-value	Keputusan
1.	sex	4.96614e-07	H0 ditolak
2.	cp	2.04776e-16	H0 ditolak
3.	restecg	0.00837	H0 ditolak
4.	slp	1.48739e-10	H0 ditolak
5.	thall	1.69713e-17	H0 ditolak
6.	caa	1.17154e-14	H0 ditolak
7.	exng	1.31309e-13	H0 ditolak
8.	fbs	0.67209	H0 diterima

Pada Tabel 2 ditunjukkan hasil pengujian hipotesis atribut dengan tipe kategorik. Berdasarkan nilai *p-value* maka atribut yang tidak berkontribusi dalam melakukan klasifikasi hanya fbs. Berdasarkan hasil pemilihan fitur menggunakan uji hipotesis didapat 3 atribut yang independen terhadap kelas atau target yaitu trtbps (tekanan darah istirahat), chol (kadar kolestrol dalam darah) dan fbs (kadar gula darah puasa > 120 mg/dl). Ketiga atribut tersebut tidak diikutkan dalam pembentukan model.

Data awal sebanyak 303 tetapi berdasarkan hasil cleaning diperoleh data yang siap digunakan untuk membangun model sebanyak 293, ada 10 data yang dihapus. 80% data pelatihan terdiri dari 234 data dengan resiko tinggi sebanyak 128 pasien sedangkan resiko rendah sebanyak 106. 20% data pelatihan terdiri dari 59 data dengan resiko tinggi sebanyak 34 pasien sedangkan resiko rendah sebanyak 25. Kelas untuk resiko tinggi diberikan symbol angka 1 sedangkan untuk yang rendah angka 0.

3.2 Hasil Pelatihan Model

Pelatihan model



Gambar 2. Bloxplot akurasi pelatihan model klasifikasi model

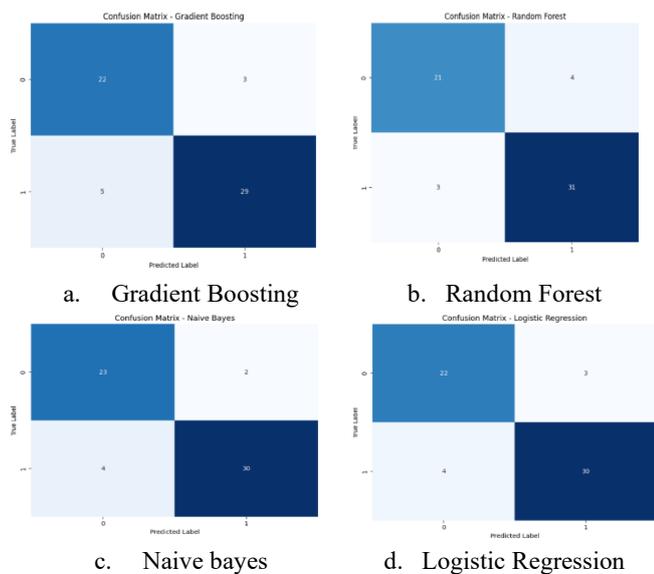
Pada Gambar 2 ditunjukkan boxplot akurasi pelatihan model klasifikasi. Boxplot memberikan informasi yang sangat penting untuk memilih model yang tidak hanya akurat, tetapi juga konsisten. Berdasarkan boxplot tersebut, Random Forest menunjukkan performa paling unggul dengan nilai median akurasi tertinggi, yaitu sekitar 0,86, serta distribusi yang paling sempit tanpa adanya outlier. Hal ini menunjukkan bahwa model Random Forest tidak hanya akurat tetapi juga sangat konsisten dalam berbagai skenario pelatihan. Di sisi lain, Logistic Regression juga menunjukkan performa yang baik dengan median akurasi yang tinggi (sekitar 0,85) dan variabilitas yang rendah, menandakan stabilitas model ini dalam melakukan klasifikasi.

Naive Bayes memiliki distribusi akurasi yang paling lebar dengan rentang nilai yang bervariasi dari sekitar 0,65 hingga lebih dari 0,90. Meskipun model ini sesekali menghasilkan akurasi yang sangat tinggi, keberadaan outlier di bawah 0,60 menunjukkan bahwa performanya kurang stabil dan tidak selalu dapat diandalkan. Sementara itu, Gradient Boosting menunjukkan kinerja yang cukup baik dengan median akurasi sekitar 0,80, namun juga terdapat satu outlier yang menunjukkan hasil akurasi sangat rendah (~0,60), yang menandakan bahwa model ini dapat mengalami penurunan performa secara signifikan dalam kondisi tertentu.

Secara keseluruhan, berdasarkan analisis boxplot ini, Random Forest dapat dianggap sebagai model dengan performa terbaik dalam hal akurasi dan konsistensi, diikuti oleh Logistic Regression. Kedua model ini menunjukkan distribusi akurasi yang relatif sempit dan nilai median yang tinggi, yang penting untuk memastikan keandalan prediksi dalam aplikasi nyata.

3.3 Hasil Pengujian Model

Hasil pengujian keempat model disajikan dalam confusion matriks pada Gambar 3 berikut. Random Forest memiliki jumlah True Positive tertinggi dan False Negative terendah, menjadikannya model terbaik dalam hal deteksi penyakit jantung. Naive Bayes unggul dalam memprediksi pasien tidak sakit (True Negative). Logistic Regression dan Gradient Boosting memberikan hasil yang baik dan seimbang, namun Gradient Boosting cenderung lebih sering gagal mendeteksi pasien yang sakit (FN lebih tinggi) dibandingkan model lain.



Gambar 3. Confution matrix hasil pengujian model

Pada Gambar 3 ditunjukkan *confusion matrix* hasil pengujian keempat model. Berdasarkan nilai pada confusion matrix diperoleh hasil bahwa Random Forest memiliki jumlah True Positive tertinggi dan False Negative terendah, menjadikannya model terbaik dalam hal deteksi penyakit jantung. Naive Bayes unggul dalam memprediksi pasien tidak sakit (True Negative). Logistic Regression dan Gradient Boosting memberikan hasil yang baik dan seimbang, namun Gradient Boosting cenderung lebih sering gagal mendeteksi pasien yang sakit (FN lebih tinggi) dibandingkan model lain.

Tabel 3.
Hasil performa keempat model

Model	Accuracy	Precision		Recall		F1-Score	
		0	1	0	1	0	1
Gradient Boosting	0,86	0,81	0,91	0,88	0,85	0,85	0,88
Random Forest	0,88	0,88	0,89	0,84	0,91	0,86	0,90
Naive Bayes	0,90	0,85	0,94	0,92	0,88	0,88	0,91
Logistic Regression	0,88	0,85	0,91	0,88	0,88	0,86	0,90

Pada Tabel 3 disajikan perbandingan performa empat model *machine learning* Gradient Boosting, Random Forest, Naive Bayes, dan Logistic Regression berdasarkan hasil evaluasi *confusion matrix*. Setiap model dinilai menggunakan empat metrik utama yaitu *accuracy* (tingkat keseluruhan prediksi benar), *precision* (ketepatan model dalam memprediksi kelas positif), *recall* (kemampuan model dalam menemukan seluruh kasus positif), dan *F1-score* (harmonisasi antara precision dan recall). dapat dilihat bahwa akurasi model tertinggi didapat model.

Berdasarkan hasil evaluasi terhadap confusion matrix, seluruh model menunjukkan tingkat akurasi yang tinggi, dengan nilai berkisar antara 0,85 hingga 0,88. Model Naive Bayes mencatatkan akurasi tertinggi sebesar 0,90, diikuti oleh Random Forest dan Logistic Regression masing-masing dengan akurasi 0,88, serta Gradient Boosting dengan akurasi 0,86.

Naive Bayes memiliki precision tertinggi (0,94), artinya sangat jarang salah dalam memprediksi resiko pasien mengalami serangan jantung. Random Forest memiliki recall tertinggi (0,91), artinya paling baik dalam menangkap seluruh kasus resiko pasien mengalami serangan jantung. Baik resiko rendah maupun resiko tinggi. Naive Bayes juga memiliki nilai F1-score tertinggi (0,91), menunjukkan keseimbangan baik antara precision dan recall. Semua model menunjukkan akurasi tinggi (di atas 0,85), namun distribusi kekuatannya berbeda.

Berdasarkan hasil perbandingan keempat model maka model Naive Bayes menempati posisi teratas dalam tiga kategori sekaligus. Model Naive Bayes selain memiliki akurasi tertinggi yaitu 0,90 melainkan juga

memiliki precision dan recall tinggi untuk kedua kelas. Selain itu, nilai F1-score untuk model Naive Bayes tertinggi dan seimbang.

4. Kesimpulan

Penelitian ini telah berhasil membangun dan mengevaluasi model prediksi risiko serangan jantung dengan mengelompokkan pasien ke dalam dua kategori, yaitu risiko rendah dan risiko tinggi, menggunakan pendekatan rekayasa sistem cerdas berbasis *supervised learning*. Model yang digunakan yaitu Gradient Boosting, Random Forest, Naive Bayes, dan Logistic Regression Berdasarkan hasil pengujian model maka secara umum keempat model tersebut memiliki performa yang baik karena memiliki akurasi di atas 85%.

Model Naive Bayes mencapai akurasi tertinggi sebesar 0,90, diikuti oleh Random Forest dan Logistic Regression masing-masing dengan akurasi 0,88, serta Gradient Boosting dengan akurasi 0,86. Selain berdasarkan akurasi, nilai *precision* dan *F1-score* untuk model Naive Bayes juga tertinggi untuk kelas positif, serta *recall* tertinggi untuk kelas negatif. Oleh karena itu, Naive Bayes dinilai sebagai model yang paling andal dan direkomendasikan untuk prediksi risiko serangan jantung secara dini, karena mampu memberikan klasifikasi yang seimbang dan akurat dalam konteks aplikasi medis.

Penelitian ini dapat dikembangkan dengan menggunakan model *supervised learning* yang lainnya hingga akurasi model mencapai di atas 95%. Selain itu, model dapat dikembangkan dengan melakukan *deployment* pada aplikasi berbasis web atau android sehingga dapat dimanfaatkan lebih banyak pengguna.

Daftar pustaka

Anand, S. S., Islam, S., Rosengren, A., Franzosi, M. G., Steyn, K., Yusufali, A. H., Yusuf, S. (2008). Risk factors for myocardial infarction in women and men: Insights from the INTERHEART study. *European Heart Journal, 29*(7), 932–940. <https://doi.org/10.1093/eurheartj/ehn018>

Breiman, L. (2001). Random forests. *Machine Learning, 45*(1), 5–32. <https://doi.org/10.1023/A:1010933404324>

Cox, D. R. (1958). The regression analysis of binary sequences. *Journal of the Royal Statistical Society: Series B (Methodological), 20*(2), 215–242. <https://www.jstor.org/stable/2983890>

Dharmawan, S., Fernandes, V., & Halim, H. (2024). Prediksi serangan jantung dengan menggunakan metode logistic regression classifier dan Adaboost. *Computatio: Journal of Computer Science and Information Systems, 8*(1). <https://doi.org/10.24912/computatio.v8i1.15176>

Ekananda, N. P., & Rimirasih, D. (2022). Identifikasi penyakit pneumonia berdasarkan citra chest X-ray menggunakan convolutional neural network. *Jurnal Ilmiah Informatika Komputer, 27*(1), 79–94. <https://doi.org/10.35760/ik.2022.v27i1.6487>

Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics, 29*(5), 1189–1232. <https://doi.org/10.1214/aos/1013203451>

Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression* (3rd ed.). Wiley.

Kathiresan, S., & Srivastava, D. (2012). Genetics of human cardiovascular disease. *Cell, 148*(6), 1242–1257. <https://doi.org/10.1016/j.cell.2012.03.001>

McPherson, R., Pertsemliadis, A., Kavaslar, N., Stewart, A., Roberts, R., Cox, D. R., ... Kathiresan, S. (2007). A common allele on chromosome 9 associated with coronary heart disease. *Science, 316*(5830), 1488–1491. <https://doi.org/10.1126/science.1142447>

- Nugraha, W. (2021). Prediksi penyakit jantung cardiovascular menggunakan model algoritma klasifikasi. *JURNAL SIGMATA, 9*(2), 78–84.
- Nygård, O., Nordrehaug, J. E., Refsum, H., Ueland, P. M., Farstad, M., & Vollset, S. E. (1997). Plasma homocysteine levels and mortality in patients with coronary artery disease. *New England Journal of Medicine, 337*(4), 230–236. <https://doi.org/10.1056/NEJM199707243370403>
- Ojha, N., & Dhamoon, A. S. (2023, August 8). Myocardial infarction. In *StatPearls [Internet]*. StatPearls Publishing. <https://www.ncbi.nlm.nih.gov/books/NBK537076/>
- Oskar, F. R., Rupina, & P., N. (2024). Pengelolaan data penyakit jantung dengan menggunakan metode Naive Bayes. *Infact: International Journal of Computers, 8*(02), 49–54. <https://doi.org/10.61179/jurnalinfact.v8i02.531>
- Prihandoko, A., Fahrurozi, A., Rimirasih, D., & Jayanti, K. (2024). Effective feature selection methods for vaginal birth after cesarean data. In *2024 Ninth International Conference on Informatics and Computing (ICIC)* (pp. 1–5). IEEE. <https://doi.org/10.1109/ICIC64337.2024.10956317>
- Rimirasih, D., Karyati, C. M., Mutiara, A. B., Wahyudi, B., & Ernastuti. (2016). MRI sagittal image segmentation from patients with abdominal aortic aneurysms. *TELKOMNIKA (Telecommunication Computing Electronics and Control), 14*(3), 1105–1112. <https://doi.org/10.12928/telkommika.v14i3.3520>
- Rokom. (2022, September 29). Penyakit jantung penyebab utama kematian, Kemenkes perkuat layanan primer. *Kementerian Kesehatan Republik Indonesia.* <https://sehatnegeriku.kemkes.go.id/baca/rilis-media/20220929/0541166/penyakit-jantung-penyebab-utama-kematian-kemenkes-perkuat-layanan-primer/>
- Suryana, D. H., Mutiara, A. B., Raharja, W. K., & Rimirasih, D. (2024). Hair removal methods in skin cancer images using Black Top Hat transform and wavelet transform. In *2024 Ninth International Conference on Informatics and Computing (ICIC)* (pp. 1–6). IEEE. <https://doi.org/10.1109/ICIC64337.2024.10957513>
- WHO. (n.d.). *Cardiovascular diseases.* https://www.who.int/health-topics/cardiovascular-diseases#tab=tab_1
- Yusuf, S., Hawken, S., Ôunpuu, S., Dans, T., Avezum, A., Lanas, F., ... INTERHEART Study Investigators. (2004). Effect of potentially modifiable risk factors associated with myocardial infarction in 52 countries (the INTERHEART study): Case-control study. *The Lancet, 364*(9438), 937–952. [https://doi.org/10.1016/S0140-6736\(04\)17018-9](https://doi.org/10.1016/S0140-6736(04)17018-9)
- Zhang, H. (2004). The optimality of naive Bayes. In *Proceedings of the 17th International Florida Artificial Intelligence Research Society Conference* (pp. 562–567).