

DETEKSI DINI RISIKO PENYAKIT KARDIOVASKULAR MENGUNAKAN TEKNIK STACKING ENSEMBLE LEARNING DENGAN PENDEKATAN CRISP-DM

Whilli Usmania¹, Yudo Bismo Utomo², Moh. Syaiful Anam³, Harso Kurniadi⁴

¹ Mahasiswa Prodi Teknik Komputer, Teknik Komputer, FT – UNISKA

^{2,3,4} Dosen Prodi Teknik Komputer, Teknik Teknik Komputer, FT – UNISKA

¹ whilliusmania@gmail.com, ² yudobismo@uniska-kediri.ac.id, ³ anam@uniska-kediri.ac.id,

⁴ harsokurniadi@uniska-kediri.ac.id

Abstrak

Penyakit kardiovaskular, termasuk penyakit jantung dan stroke, menjadi salah satu kasus penyakit tertinggi di Indonesia dalam daftar penyakit tidak menular (PTM). Penelitian ini bertujuan pada pengembangan model prediksi risiko penyakit kardiovaskular dan mengimplementasikannya dalam bentuk aplikasi web berbasis framework Streamlit yang diperuntukkan bagi pengguna umum sebagai alat deteksi dini, dengan output berupa probabilitas risiko kardiovaskular yang dihasilkan oleh model prediksi. Model prediksi dikembangkan menggunakan teknik Stacking Ensemble Learning. Penelitian ini menggunakan metode CRISP-DM sebagai kerangka kerja yang terstruktur dan sesuai untuk pengembangan model pembelajaran mesin. Hasil penelitian menunjukkan bahwa model prediksi menghasilkan akurasi sebesar 97% pada data uji. Model prediksi berhasil di-deploy ke dalam aplikasi web berbasis Streamlit yang memungkinkan pengguna memasukkan data kesehatan untuk memperoleh estimasi probabilitas risiko kardiovaskular. Selanjutnya, aplikasi diujikan kepada pengguna melalui kuesioner, yang menunjukkan tingkat penerimaan yang baik dengan skor 83,47%.

Kata kunci: kardiovaskular, deteksi dini, aplikasi web, streamlit, stacking ensemble learning, CRISPDM

1. Pendahuluan

Berdasarkan keterangan Menteri Kesehatan RI, Budi Gunadi Sadikin, angka mortalitas tertinggi di Indonesia dipicu oleh serangan stroke dan disusul oleh gangguan jantung (Tribrata News, 2025). Kedua kondisi medis ini merupakan bagian dari penyakit kardiovaskular, sebuah terminologi untuk berbagai gangguan pada jantung dan sistem pembuluh darah, yang mencakup gagal jantung, aritmia, penyakit jantung koroner, hingga kerusakan katup jantung ((NACDD), 2025). Saat ini, kelompok penyakit tersebut menempati posisi teratas dalam daftar kasus kesehatan di tanah air (Ganie dkk., 2025). Kondisi ini mendasari urgensi adanya sistem identifikasi risiko sejak dini demi memastikan langkah mitigasi dan pengobatan medis dapat diambil secepat mungkin.

Efisiensi dalam analisis data medis kini dapat dicapai berkat kemajuan kecerdasan buatan, khususnya melalui teknik pembelajaran mesin. Implementasi model *machine learning* untuk deteksi dini penyakit memerlukan dukungan tata kelola sistem informasi yang terintegrasi. Hal ini penting untuk memastikan bahwa aliran data dari pasien hingga menjadi output prediksi tetap terjaga keamanan dan validitasnya, selaras dengan prinsip manajemen tata kelola TI yang mengedepankan efisiensi dan penyelarasan strategis antara teknologi dan kebutuhan layanan (Satrio dkk., 2021). Penelitian ini memanfaatkan keunggulan teknik *Stacking Ensemble Learning* untuk memperkuat hasil prediksi dengan cara menggabungkan beberapa algoritma sekaligus (Ashika & Hannah Grace, 2025; Shah dkk., 2025; StackExchange, 2021). Strategi yang digunakan melibatkan sinergi antara tiga model utama, yaitu XGBoost, *Extra Trees*, dan *Random Forest*, yang kemudian disempurnakan oleh *Logistic Regression* yang bertindak sebagai meta-model pengambil keputusan akhir.

Penelitian ini berfokus pada pengembangan model prediksi risiko penyakit kardiovaskular dan implementasinya dalam bentuk aplikasi web berbasis *Streamlit*. *Streamlit* merupakan *framework Python opensource* yang dirancang untuk membantu *data scientist* dan praktisi AI/ML membangun aplikasi data yang interaktif hanya dengan beberapa baris kode (Streamlit Docs, 2025). Riset ini mengadopsi kerangka kerja CRISP-DM (*Cross Industry Standard Process for Data Mining*) sebagai panduan pengembangan karena menawarkan tahapan analisis yang terstruktur, dimulai dari pemahaman aspek bisnis hingga fase implementasi akhir (Rianti dkk., 2023). Sistem prediksi yang dihasilkan kemudian diintegrasikan ke dalam platform web berbasis *Streamlit*,

Available at:

<https://journal.unj.ac.id/unj/index.php/pinter/article/view/62704>

yang berfungsi sebagai instrumen skrining awal dengan menyajikan estimasi probabilitas risiko kesehatan jantung (Sufian dkk., 2024). Aplikasi ini berbasis kecerdasan buatan dan bukan merupakan alat diagnosis medis, sehingga hasil prediksi tetap memiliki kemungkinan kesalahan.

2. Dasar Teori

2.1. Penyakit Kardiovaskular

Di seluruh dunia, penyakit kardiovaskular tetap mendominasi sebagai pemicu utama kematian dan gangguan kesehatan kronis. Kondisi ini terus berkembang pesat walaupun secara medis sebagian besar faktor risikonya telah diidentifikasi dan dapat dilakukan pencegahan sedini mungkin (Arsyad dkk., 2022). Berdasarkan penelitian An, dkk. (2023), penyakit *Atherosclerotic Cardiovascular Disease* (ASCVD) juga dapat terjadi pada usia muda. Penelitian tersebut melibatkan 414.260 orang berusia 18–39 tahun, dan selama masa tindak lanjut, tercatat 813 peserta benar-benar mengalami kejadian ASCVD. Faktor risiko utama yang mempengaruhi di antaranya adalah meliputi obesitas, diabetes mellitus, kadar kolesterol dan trigliserida tinggi, tekanan darah tinggi, aktivitas fisik rendah, serta kebiasaan merokok. (Aghaeishahsavari dkk., 2006).

2.2. Stacking Ensemble Learning

Stacking adalah salah satu jenis metode dalam *ensemble learning*, di mana selain *stacking*, terdapat pula teknik lain seperti *bagging* dan *boosting* (Bhanarkar & Amdani, 2024). Keunggulan teknik ini terletak pada kemampuannya menyatukan berbagai prediksi dari model tingkat pertama menggunakan lapisan meta-model. Melalui proses pelatihan khusus, meta-model ini bertugas mencari bobot atau kombinasi terbaik dari hasil prediksi yang ada guna mencapai tingkat akurasi yang lebih stabil dan tinggi (Rahmat & Wahyu Utomo, 2025).

2.3. CRISP-DM

Metodologi CRISP-DM (*Cross Industry Standard Process for Data Mining*) pada mulanya dirancang untuk mendukung aktivitas penggalian data di sektor industri, salah satunya pada perusahaan asuransi OHRA, guna menjamin proses analisis yang terorganisir dan terukur (Chapman, 2000). Seiring perkembangan teknologi, kerangka kerja ini menjadi standar yang luas diadaptasi dalam pengembangan *deep learning*, *machine learning*, hingga kecerdasan buatan secara umum karena alur kerjanya yang komprehensif (Rianti dkk., 2023). Secara garis besar, CRISP-DM terdiri dari enam fase krusial, yang meliputi pemahaman bisnis, eksplorasi data, penyiapan data, pembuatan model, evaluasi, serta tahap implementasi atau deployment (Chapman, 2000).

2.4. Streamlit


Streamlit adalah sebuah kerangka kerja berbasis Python dengan lisensi terbuka (*open-source*) yang dirancang khusus untuk memfasilitasi pembuatan platform web interaktif dalam waktu yang singkat (Streamlit Docs, 2025). Selain itu, Streamlit juga dianggap sebagai alat yang efektif untuk membuat aplikasi web berbasis model *machine learning* serta berguna dalam pengembangan kerangka kerja secara umum (Wallaard, 2023).

3. Metodologi

Dalam penelitian ini, metodologi CRISP-DM diterapkan sebagai kerangka kerja sistematis untuk merancang model estimasi risiko penyakit kardiovaskular. Pengembangan model tersebut mengandalkan teknik *Stacking Ensemble Learning*, yang kemudian diintegrasikan ke dalam platform digital menggunakan *framework* Streamlit untuk menghasilkan aplikasi web yang interaktif.

3.1. Tahapan Penelitian Berdasarkan Metodologi CRISP-DM

Prosedur penelitian ini dijalankan dengan mengacu pada kerangka CRISP-DM, yang mengintegrasikan enam fase fundamental: mulai dari pemahaman konteks bisnis (*business understanding*), eksplorasi data (*data understanding*), hingga penyiapan data (*data preparation*). Tahapan selanjutnya meliputi perancangan model (*modeling*), pengujian kualitas (*evaluation*), serta tahap implementasi (*deployment*) (Li dkk., 2024; Yasmeen dkk., 2025). Gambaran menyeluruh mengenai proses penelitian ini dipresentasikan dalam diagram alir yang tertera pada Gambar 3.1.



Gambar3.1Diagram CRISP-DM
Sumber: (Chumbar, 2023)

3.1.1. Business Understanding

Tujuan utama dari tahapan ini adalah menetapkan arah penelitian dan mendefinisikan problematikanya. Mengingat penyakit kardiovaskular masih menjadi salah satu penyebab utama kematian di Indonesia, penelitian ini berupaya menghadirkan solusi berupa pengembangan model prediksi risiko. Dengan memanfaatkan teknik Stacking Ensemble Learning, hasil penelitian diwujudkan dalam bentuk aplikasi web untuk mendukung upaya deteksi dini secara lebih efektif (Amritha dkk., 2026; Yasmeen dkk., 2025).

3.1.2. Data Understanding

Eksplorasi data dilakukan dengan mengambil dataset dari portal Kaggle guna mendukung pembuatan model. Pada tahap ini, peneliti mengidentifikasi susunan fitur, tipe variabel, serta atribut data lainnya. Pemahaman yang komprehensif mengenai karakteristik data ini menjadi fondasi penting agar proses pelatihan model pada tahapan berikutnya dapat berjalan secara optimal.

3.1.3. Data Preparation

Tahap preparasi data dilaksanakan guna memastikan bahwa informasi yang ada telah layak untuk digunakan dalam tahap pelatihan model. Serangkaian prosedur yang dilakukan meliputi pembersihan data melalui eliminasi nilai yang hilang (*missing values*) serta data pencilan (*outliers*), melakukan transformasi berupa normalisasi dan penyesuaian satuan, hingga pembentukan fitur-fitur baru. Selain itu, dilakukan pula penyeimbangan kelas data menggunakan teknik SMOTE, konversi variabel kategorik melalui pengkodean, serta pemisahan *dataset* ke dalam kelompok data latih dan data uji.

3.1.4. Modeling

Tahap modeling difokuskan pada perancangan sistem cerdas yang dilatih untuk mengekstraksi informasi berharga dari data yang ada. Penelitian ini menggunakan pendekatan Stacking, sebuah teknik ansambel yang menyatukan kekuatan algoritma XGBoost, *Random Forest*, dan *Extra Trees* (Halim dkk., 2026; S. dkk., 2025). Luaran dari ketiga model tersebut kemudian dikombinasikan dan diproses ulang melalui *Logistic Regression* yang berperan sebagai meta-model untuk memproduksi prediksi akhir yang lebih konsisten.

3.1.5. Evaluation

Guna menjamin keakuratan prediksi, tahap evaluasi dilaksanakan dengan mengukur sejauh mana model dapat mengenali data uji dengan tepat. Instrumen penilaian yang digunakan mencakup *Confusion Matrix* dan berbagai metrik performa utama (presisi, akurasi, F1-score, dan recall). Evaluasi ini berfungsi sebagai kendali mutu untuk menghindari gejala *overfitting*, sehingga model yang dihasilkan benar-benar reliabel untuk dianalisis lebih lanjut (Ganie dkk., 2025; S. dkk., 2025).

3.1.6. Deployment

Pada fase implementasi atau deployment, model yang telah berhasil dikembangkan diintegrasikan ke dalam sebuah platform digital agar dapat diakses oleh publik. Studi ini memanfaatkan *framework* Streamlit untuk membangun antarmuka web, yang memberikan kemudahan bagi pengguna dalam menginput indikator kesehatan pribadi dan menerima estimasi risiko penyakit kardiovaskular secara langsung dan interaktif.

3.2. Pengujian Aplikasi oleh Pengguna

Evaluasi sistem dilakukan dengan tujuan mengukur tingkat aksesibilitas, kejelasan informasi hasil prediksi, serta kualitas desain antarmuka pada platform web Streamlit. Proses pengumpulan data respons pengguna dilakukan melalui survei daring dengan memanfaatkan instrumen Google Form, yang hasilnya menjadi dasar dalam menganalisis kualitas aplikasi secara keseluruhan.

4. Hasil dan Analisis

4.1. Metodologi CRISP-DM

Metodologi penelitian ini berlandaskan pada standar CRISP-DM (*Cross-Industry Standard Process for Data Mining*), sebuah model proses yang dipilih karena strukturnya yang mapan untuk proyek pengolahan data dan pengembangan model pembelajaran mesin. Dengan mengikuti enam tahapan inti yang tersedia, penelitian memiliki arah yang jelas dan metodis. Hal ini memudahkan peneliti dalam memantau perkembangan setiap fase sekaligus memastikan bahwa hasil akhir model prediksi memenuhi kriteria yang ditetapkan.

4.1.1. Business Understanding

Tingginya kasus penyakit jantung dan stroke yang mendominasi daftar penyebab kematian di Indonesia menjadi landasan utama dilakukannya riset ini. Hal ini menegaskan perlunya perhatian serius terhadap manajemen risiko penyakit kardiovaskular secara sistematis. Oleh karena itu, diperlukan media deteksi dini berbasis *AI* untuk meningkatkan kesadaran masyarakat terhadap kesehatan jantung dan pembuluh darah. Aplikasi web yang dikembangkan dengan Streamlit ini dirancang agar mudah digunakan oleh masyarakat umum, sebagai sarana untuk memprediksi tingkat risiko penyakit kardiovaskular secara mandiri. Perlu ditekankan bahwa hasil dari aplikasi ini merupakan prediksi berdasarkan model *machine learning*, bukan diagnosis medis.

4.1.2. Data Understanding

Data yang menjadi basis penelitian ini bersumber dari platform Kaggle dalam format tabular dengan total 12 parameter atau fitur. Atribut yang tersedia mencakup variabel fisik dan gaya hidup seperti umur, dimensi tubuh (tinggi dan berat badan), gender, indikator klinis (tekanan darah, kadar kolesterol, glukosa), serta perilaku kesehatan (merokok, konsumsi alkohol, dan intensitas aktivitas fisik). Dari total tersebut, 11 variabel digunakan sebagai input prediktor, sementara satu variabel lainnya, yakni 'cardio', berfungsi sebagai label target yang mengindikasikan status penyakit kardiovaskular. Observasi ini dilakukan guna mendalami susunan data sebelum melangkah ke fase prapemrosesan (*Data Preparation*).

4.1.3. Data Preparation

Guna menjamin kesiapan data untuk algoritma *machine learning*, dilakukan rangkaian prosedur pembersihan serta transformasi pada dataset sebelum memasuki fase pelatihan model.

1. Transformasi dan pembersihan data, termasuk mengubah satuan usia menjadi tahun, tinggi menjadi meter, serta menghapus nilai pada setiap kolom yang terdeteksi sebagai outlier atau tidak wajar, termasuk data tekanan darah dengan nilai ekstrem.
2. Penambahan fitur baru seperti BMI, pulse pressure, dan MAP dilakukan untuk memberikan informasi lebih bermakna. Contohnya, BMI dihitung dari berat dan tinggi badan ($BMI = \text{berat} / \text{tinggi}^2$) untuk menunjukkan kategori tubuh seperti ideal atau obesitas.
3. Penanganan ketidakseimbangan data diselesaikan dengan metode SMOTE (*Synthetic Minority Over-sampling Technique*), yang menciptakan data sintesis berdasarkan observasi pada pola data yang sudah ada. Langkah ini memastikan bahwa kelas minoritas memiliki jumlah sampel yang setara dengan kelas mayoritas, sehingga menciptakan basis data yang lebih proporsional untuk pelatihan *machine learning*. Setelah proses SMOTE, total data meningkat dari sekitar 70.000 menjadi 1.851.716 baris. Meskipun tidak sepenuhnya riil, data ini tetap logis dan membantu model belajar secara seimbang agar tidak bias terhadap kelas mayoritas serta mencegah *overfitting*.
4. Normalisasi dilakukan dengan *Standard Scaler* pada fitur numerik agar memiliki skala yang seragam, sehingga model dapat mempelajari semua fitur secara seimbang dan hasil pelatihan lebih stabil (Ashika & Hannah Grace, 2025; Shah dkk., 2025). Peneliti melakukan standarisasi pada sekumpulan fitur numerik (termasuk *pulse pressure*, *map*, dan variabel gaya hidup) untuk mencapai rata-rata 0 dan standar deviasi 1. Skala yang seragam ini sangat penting dalam *machine learning* agar fitur-fitur tersebut sebanding satu sama lain. Secara teknis, nilai positif mencerminkan data yang melebihi rata-rata populasi, sedangkan nilai negatif mencerminkan kondisi sebaliknya, guna mempercepat konvergensi model saat fase pelatihan.
5. *Encoding* diterapkan pada fitur kategorikal menggunakan *one-hot encoding*. Model *machine learning* tidak bisa langsung membaca data kategorikal seperti kolesterol (normal, above_normal, well_above_normal),

sehingga setiap kategori diubah menjadi kolom terpisah dengan nilai 1 (*True*) jika baris tersebut termasuk kategori itu, dan 0 (*False*) jika tidak.

6. Setelah seluruh rangkaian prapemrosesan selesai, *dataset* dibagi menjadi kategori data latih dan data uji dengan proporsi 67:33. Perlu dicatat bahwa implementasi teknik SMOTE pada tahap sebelumnya telah meningkatkan volume data secara signifikan, dari semula berkisar 70.000 entri menjadi total 1.851.716 baris data yang siap diolah.

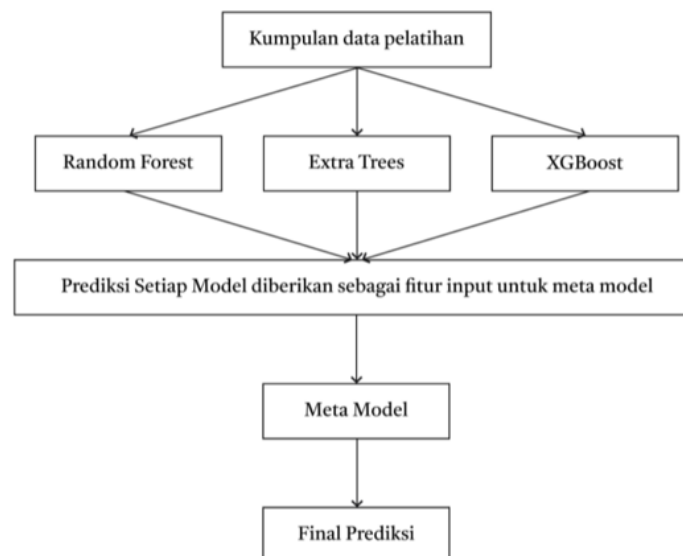
Tabel 4.1. Komposisi Pembagian Data Latih dan Uji Sesudah SMOTE

Kelas Output	Presentase	Jumlah Data Setelah SMOTE
Data Latih	67%	1.240.649
Data Uji	33%	611.067
Total	100%	1.851.716

Implementasi SMOTE bertujuan untuk mengeliminasi bias terhadap kelas mayoritas yang sering muncul akibat ketidakseimbangan data. Meskipun efektif, metode ini memiliki potensi memicu overfitting lantaran model dapat menangkap pola buatan secara berlebihan. Oleh karena itu, guna menjamin kemampuan generalisasi model, proses pengujian dilakukan menggunakan testing set murni yang tidak tersentuh oleh prosedur SMOTE. Langkah ini memastikan bahwa metrik performa yang didapat merupakan representasi akurat dari kemampuan model dalam menghadapi data dunia nyata.

4.1.4. Modeling

Tahap ini menggunakan teknik *Stacking Ensemble Learning* untuk meningkatkan akurasi prediksi. Pada metode *stacking*, model dibangun dalam dua tahap. Tahap pertama melibatkan pelatihan berbagai *base learners* untuk menghasilkan serangkaian prediksi. Data hasil prediksi ini kemudian dikonsolidasikan dan diumpungkan ke dalam meta-model sebagai basis pelatihan tahap kedua. Melalui proses ini, meta-model mampu mempelajari cara terbaik untuk menggabungkan keputusan dari model-model dasar, yang pada akhirnya meningkatkan akurasi keseluruhan sistem. Setelah semua model selesai dilatih, dilakukan evaluasi menggunakan data testing yang benar-benar baru dan tidak pernah digunakan saat pelatihan, sehingga hasil evaluasinya lebih objektif dan akurat.



Gambar4.1.DiagramArsitektur *Stacking Ensemble Learning*


4.1.5. Evaluation

Tahap ini bertujuan untuk memvalidasi sejauh mana model mampu memberikan hasil prediksi yang akurat pada data baru. Proses evaluasi diimplementasikan dengan menerapkan Confusion Matrix sebagai acuan utama, diikuti dengan perhitungan metrik statistik seperti: Akurasi untuk melihat ketepatan umum, Presisi dan Recall untuk melihat detail klasifikasi, F1-score untuk melihat keseimbangan performa model.

Tabel 4.2. Jumlah Data Untuk Setiap Kelas pada Data Uji

Kelas <i>Output</i>	Jumlah Data
Tidak Berisiko (0)	374.793
Berisiko (1)	236.274
Total	611.067

Berikut merupakan hasil *Confusion Matrix* dari model *Stacking Ensemble Learning* pada data uji.



Gambar 4.2 *Confusion Matrix Data Testing*

- TP (*True Positive*): Prediksi positif dan memang positif
- TN (*True Negative*): Prediksi negatif dan memang negatif
- FP (*False Positive*): Prediksi positif tetapi sebenarnya negatif
- FN (*False Negative*): Prediksi negatif tetapi sebenarnya positif

Pada gambar di atas ditampilkan *Confusion Matrix* untuk data uji yang berjumlah 611.067 baris, sesuai hasil pembagian data pada tahap *data preparation*. Jika dijumlahkan, hasilnya tetap sama:

$$TP + TN + FP + FN = 366.856 + 227.501 + 8.773 + 7.937 = 611.067 \quad (1)$$

Berdasarkan *Classification Report* pada data uji, model *Stacking Ensemble Learning* yang dikembangkan berhasil memperoleh tingkat akurasi sebesar 97%. Selain itu, nilai *weighted precision* serta *recall* menunjukkan hasil yang impresif untuk semua kategori kelas. Rincian mengenai perhitungan metrik evaluasi yang mencakup presisi, akurasi, *f1-score*, dan *recall* dipaparkan dalam poin-poin di bawah ini:

1. Akurasi menunjukkan seberapa banyak prediksi model yang benar terhadap seluruh data uji.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} = \frac{365924 + 226110}{365924 + 226110 + 1016 + 8869} \quad (2)$$

$$Accuracy = \frac{592034}{611067} = 0.9689 \times 100\% = 96.89\% = 97\%$$

2. Presisi mencerminkan tingkat akurasi model dalam mengklasifikasikan data sebagai positif dibandingkan dengan seluruh hasil prediksi positif yang dihasilkan.

$$Precision = \frac{TP}{TP+FP} = \frac{365924}{365924+10164} = 0.973 \times 100\% = 97.3\% \quad (3)$$

3. *Recall* atau sensitivitas menunjukkan sejauh mana model mampu menjangkau seluruh data pada kelas positif agar tidak terjadi kesalahan klasifikasi yang menganggap data positif sebagai negatif (*false negative*).

$$Recall = \frac{TP}{TP+FN} = \frac{0.976}{365924+8869} = 0.976 \times 100\% = 97.6\% \quad (4)$$

4. *F1-Score* merupakan nilai rata-rata harmonis yang mengintegrasikan presisi dan *recall* guna menyajikan estimasi performa model yang lebih komprehensif. Metrik ini menjadi parameter krusial, khususnya ketika peneliti berhadapan dengan kondisi ketidakseimbangan kelas (*class imbalance*), untuk memastikan model tetap objektif.

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} = 2 \times \frac{0.973+0.976}{0.973+0.976} = 0.9745 \times 100\% = 97.45\% \quad (5)$$

Berikut perbandingan performa model dasar dengan meta-model *stacking* berdasarkan hasil evaluasi pada data uji (testing):

Tabel 4.3. Hasil Evaluasi Base Model dan Meta Model pada Data Uji

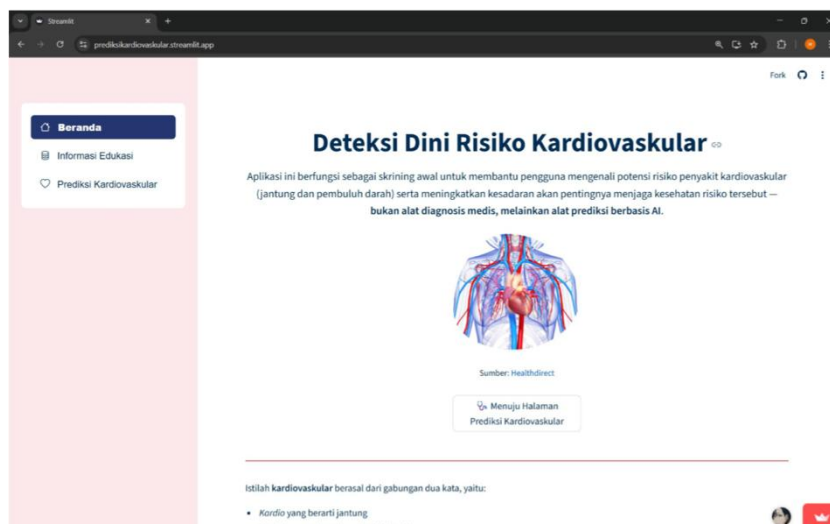
Model	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
Random Forest	86	85	86	86
Extra Trees	81	80	78	79
XGBoost	88	87	87	87
Stacking Classifier (logistic regression)	97	97	97	97

Temuan ini membuktikan bahwa arsitektur *stacking ensemble*, yang mengintegrasikan sejumlah *base learners* dengan satu meta-model sebagai pembuat keputusan akhir, efektif dalam mengkonsolidasikan berbagai proyeksi model dasar. Proses penggabungan ini memungkinkan sistem untuk menghasilkan tingkat akurasi yang lebih superior jika dibandingkan dengan penggunaan model klasifikasi tunggal.

4.1.6. Deployment

Untuk memberikan manfaat praktis, model *stacking classifier* di-deploy ke dalam kerangka kerja Streamlit. Aplikasi web ini memungkinkan publik melakukan skrining mandiri terhadap risiko penyakit kardiovaskular, mengubah model pembelajaran mesin yang kompleks menjadi alat bantu kesehatan yang interaktif. Aplikasi ini dapat diakses secara dinamis melalui Streamlit *Cloud*. Aplikasi memiliki tiga halaman utama:

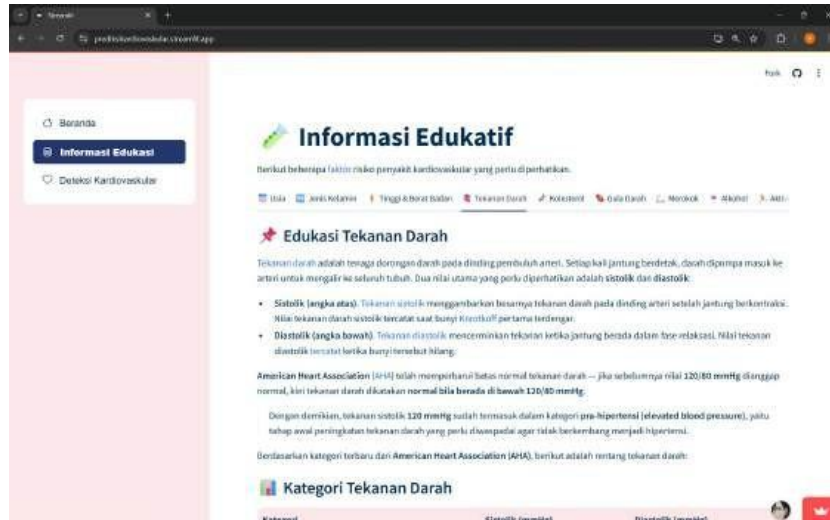
1. Halaman Beranda merupakan halaman pertama yang dilihat pengguna, menyediakan informasi dasar tentang penyakit kardiovaskular serta menjelaskan fungsi aplikasi sebagai alat skrining awal, bukan sebagai alat medis atau diagnosis pasti.



Gambar 4.4 Halaman Beranda Aplikasi

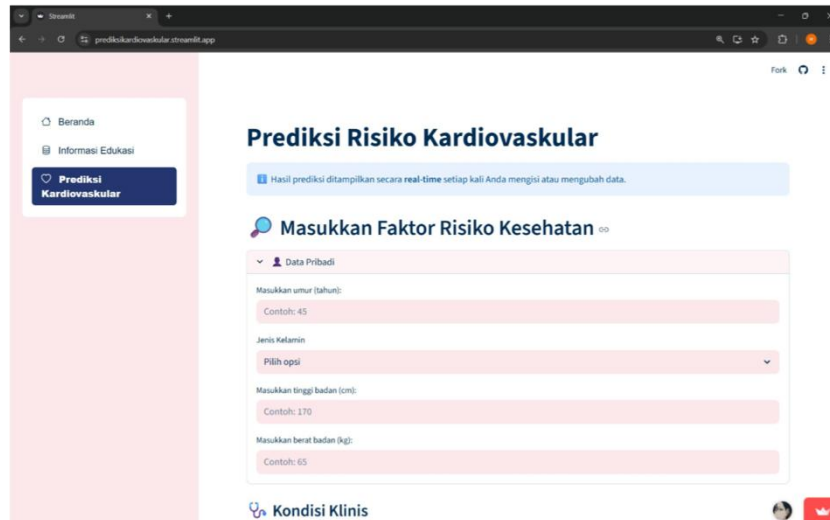
2. Pada bagian Informasi Edukasi, dipaparkan berbagai indikator kesehatan yang menjadi basis dalam kalkulasi prediksi. Variabel tersebut mencakup faktor-faktor krusial seperti usia, profil tekanan darah, kadar kolesterol dan glukosa, hingga aspek gaya hidup seperti merokok, penggunaan alkohol, dan intensitas olahraga.

Halaman ini juga menyertakan kategorisasi dari masing-masing faktor tersebut untuk membantu pengguna memahami pengaruhnya terhadap risiko penyakit kardiovaskular.



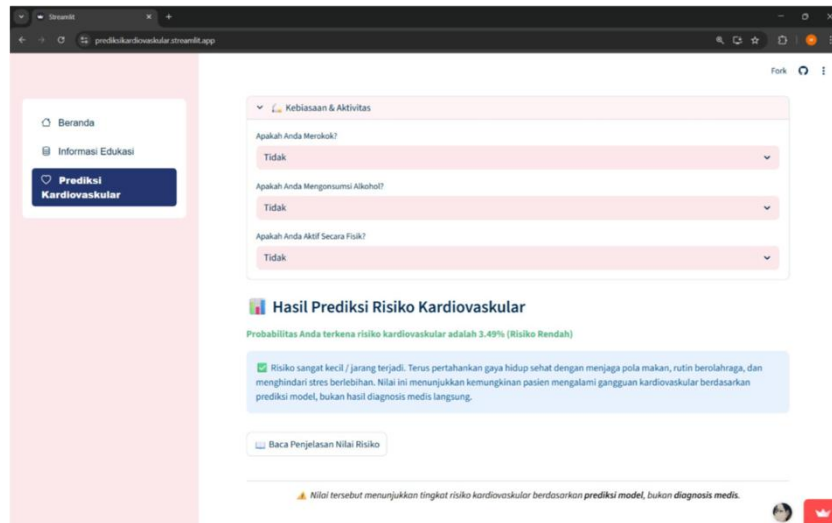
Gambar4.5. Halaman Informasi Edukasi

3. Fitur Prediksi Kardiovaskular memungkinkan pengguna untuk menginput sepuluh indikator kesehatan secara dinamis. Parameter yang diperlukan mencakup profil demografis dan fisik—seperti usia, gender, serta indeks massa tubuh (tinggi dan berat badan)—hingga variabel klinis yang meliputi tekanan darah dan kadar biokimia darah. Selain itu, pengguna juga diminta mengisi data perilaku terkait gaya hidup, seperti aktivitas fisik serta riwayat konsumsi rokok dan alkohol.



Gambar 4.6 Halaman Prediksi Kardiovaskular

Pada halaman terakhir prediksi kardiovaskular, menampilkan hasil prediksi risiko kardiovaskular berdasarkan data yang diisi pengguna. Hasil ditampilkan secara *real time* dalam bentuk kemungkinan atau probabilitas (%), sehingga setiap perubahan *input* seperti usia, tekanan darah, atau kebiasaan aktivitas langsung memperbarui hasil prediksi tanpa perlu menekan tombol tambahan.



Gambar 4.7. Tampilan Hasil Prediksi Risiko Kardiovaskular Secara *Real Time* pada Aplikasi Web.

4.2. Pengujian Aplikasi oleh Pengguna

Pengujian dilakukan terhadap 15 responden menggunakan 10 pertanyaan skala *Likert* 1–5. Perhitungan persentase keseluruhan aplikasi dilakukan sebagai berikut:

$$\text{Persentase} = \frac{\text{Total Skor Semua Pertanyaan}}{\text{Total Skor Maksimal}} \times 100\% \quad (6)$$

$$\text{Persentase} = \frac{626}{750} \times 100\% = 83.47\%$$

Dengan total skor semua pertanyaan dari 15 responden sebesar 626, dan skor maksimal keseluruhan untuk seluruh aplikasi sebesar 750, diperoleh rata-rata penerimaan pengguna sebesar 83,47%, yang termasuk kategori baik. Aspek yang mendapat nilai tinggi mencakup kemudahan penggunaan fitur prediksi, kejelasan tampilan, dan manfaat aplikasi dalam meningkatkan kesadaran kesehatan kardiovaskular. Beberapa aspek, seperti navigasi menu dan pemahaman alur penggunaan, memiliki skor sedikit lebih rendah, menunjukkan masih ada ruang untuk perbaikan.

5. Kesimpulan dan Saran

Melalui metode *stacking ensemble learning*, penelitian ini menghasilkan model prediksi dengan akurasi 97% yang kemudian diwujudkan dalam aplikasi web interaktif. Inovasi ini bertujuan untuk mendukung upaya deteksi dini dan penyebaran informasi kesehatan di masyarakat luas. Namun, penting untuk digarisbawahi bahwa aplikasi ini hanya berperan sebagai sarana pendukung dan bukan merupakan otoritas diagnosis medis yang mutlak. Pengujian terhadap pengguna menunjukkan tingkat penerimaan yang baik sebesar 83,47%, yang tercermin dari kemudahan pengisian data serta kejelasan tampilan hasil prediksi secara *real-time*. Walaupun aspek navigasi masih memerlukan peningkatan, pengembangan di masa depan akan difokuskan pada fitur riwayat prediksi dan kolaborasi dengan lembaga medis guna meningkatkan validitas serta memperluas pemanfaatan aplikasi dalam layanan kesehatan.

Daftar Pustaka:

- (NACDD), N. A. of C. D. D. (2025). *Cardiovascular Health*. Chronicdisease.org. <https://chronicdisease.org/cardiovascularhealth/>
- Aghaeishahsavari, M., Noroozianavval, M., Veisi, P., Parizad, R., & Samadikhah, J. (2006). Cardiovascular disease risk factors in patients with confirmed cardiovascular disease. *Saudi medical journal*, 27(9), 1358—1361. <http://europepmc.org/abstract/MED/16951773>
- Amritha, Y. D., Luh, N., Ika, P., & Dananjaya, W. P. (2026). *Model Machine Learning yang Dioptimalkan untuk Prediksi Penyakit Jantung Menggunakan R Shiny*. 8(01), 1–10.
- An, J., Zhang, Y., Zhou, H., Zhou, M., Safford, M. M., Muntner, P., Moran, A. E., & Reynolds, K. (2023). Incidence of Atherosclerotic Cardiovascular Disease in Young Adults at Low Short-Term But High Long-

- Term Risk. *Journal of the American College of Cardiology*, 81(7).
<https://doi.org/10.1016/j.jacc.2022.11.051>
- Arsyad, D. S., Westerink, J., Cramer, M. J., Ansar, J., Wahiduddin, Visseren, F. L. J., Doevendans, P. A., & Ansariadi. (2022). Modifiable risk factors in adults with and without prior cardiovascular disease: findings from the Indonesian National Basic Health Research. *BMC Public Health*, 22(1).
<https://doi.org/10.1186/s12889-022-13104-0>
- Ashika, T., & Hannah Grace, G. (2025). Enhancing heart disease prediction with stacked ensemble and MCDM-based ranking: an optimized RST-ML approach. *Frontiers in Digital Health*, 7, 1609308.
<https://doi.org/10.3389/fgth.2025.1609308>
- Bhanarkar, P., & Amdani, S. Y. (2024). A Comparative Framework of Stacking, Bagging, and Boosting Ensembles for Deep Learning-Based Hyperspectral Image Classification. In *Original Research Paper International Journal of Intelligent Systems and Applications in Engineering IJISAE* (Vol. 2024, Nomor 22s).
- Chapman, P. (2000). *CRISP-DM 1.0: Step-by-step data mining guide*.
<https://api.semanticscholar.org/CorpusID:59777418>
- Chumbar, S. (2023). The CRISP-DM Process: A Comprehensive Guide. *Medium*.
- Ganie, S. M., Pramanik, P. K. D., & Zhao, Z. (2025). Ensemble learning with explainable AI for improved heart disease prediction based on multiple datasets. *Scientific Reports*, 15(1), 13912.
<https://doi.org/10.1038/s41598-025-97547-6>
- Halim, A. M., Rosli, M. M., Musa, N., & Ibrahim, N. (2026). *Ensemble Learning Approaches for Cardiovascular Disease Prediction*. 16(1), 31632–31637. <https://doi.org/10.4018/978-1-7998-3327-7.ch006>
- Li, C., Liu, X., Shen, P., Sun, Y., Zhou, T., Chen, W., Chen, Q., Lin, H., Tang, X., & Gao, P. (2024). Improving cardiovascular risk prediction through machine learning modelling of irregularly repeated electronic health records. *European Heart Journal. Digital Health*, 5(1), 30–40.
<https://doi.org/10.1093/ehjdh/ztad058>
- Rahmat, A., & Wahyu Utomo, D. (2025). DIABETES DETECTION USING STACKING TECHNIQUE: A COMBINATION OF XGBOOST, GRADIENT BOOSTING, AND META MODEL. *Inovtek Polbeng Seri Informatika*, 10(2).
- Rianti, A., Wachid, N., Majid, A., Fauzi, A., Sistem, P., Informasi, T., Telekomunikasi, S., Upi Di Purwakarta, K., & Edu, A. (2023). CRISP-DM: Metodologi Proyek Data Science. *Prosiding Seminar Nasional Teknologi Informasi dan Bisnis (SENATIB)*.
- S., S., Zolghikar, S., S. H., M., & K. R., V. (2025). Cardio meta-stack: a meta-classifier ensemble for enhanced cardiovascular disease prognosis. *Indonesian Journal of Electrical Engineering and Computer Science*, 40(3), 1630. <https://doi.org/10.11591/ijeecs.v40.i3.pp1630-1637>
- Satrio, B., Herindra, L. D., & Widodo, A. P. (2021). Analisis Tata Kelola Sistem Informasi Balai Penelitian Lingkungan Pertanian menggunakan Framework COBIT-5. *Explore: Jurnal Sistem Informasi dan Telematika*, 12(1), 28. <https://doi.org/10.36448/jsit.v12i1.1966>
- Shah, P., Shukla, M., Dholakia, N. H., & Gupta, H. (2025). Predicting cardiovascular risk with hybrid ensemble learning and explainable AI. *Scientific Reports*, 15(1), 17927. <https://doi.org/10.1038/s41598-025-01650-7>
- StackExchange. (2021). *Does ensemble (bagging, boosting, stacking, etc) always at least increase performance?* Stack Exchange Inc. <https://datascience.stackexchange.com/questions/17146/does-ensembl-e-bagging-boosting-stacking-etc-always-at-least-increase-perfor>
- Streamlit Docs. (2025). *Streamlit Documentation*. Streamlit.io. <https://docs.streamlit.io/>
- Sufian, M. A., Hamzi, W., Zaman, S., Alsadder, L., Hamzi, B., Varadarajan, J., & Azad, M. A. K. (2024). Enhancing Clinical Validation for Early Cardiovascular Disease Prediction through Simulation, AI, and Web Technology. *Diagnostics (Basel, Switzerland)*, 14(12). <https://doi.org/10.3390/diagnostics14121308>
- Tribrata News. (2025). *Menkes: Stroke dan Jantung Jadi Penyebab Kematian Tertinggi di Indonesia*. Tribrata News. <https://tribratanews.polri.go.id/blog/kesehatan-7/menkes-stroke-dan-jantung-jadi-penyebab-kematian-tertinggi-di-indonesia-86600>
- Wallaard, L. (2023). Model Deployment of A Predictive Machine Learning Model for Clinical Decision Support. *Leiden Institute of Advanced Computer Science (LIACS)*, 13.
- Yasmeen, R., Khan, L., & Choi, A. (2025). Heart disease prediction using hybrid TabNet architecture with stacked ensemble learning. *Frontiers in Physiology*, Volume 16. <https://doi.org/10.3389/fphys.2025.1665128>