



OPTIMASI MODEL XGBOOST UNTUK PREDIKSI PENYAKIT JANTUNG MENGGUNAKAN OPTUNA

Yasni Optarina^{1*)}, Nana Suarna²⁾, Agus Bahtiar³⁾, Nining Rahaningsih⁴⁾, Willy Prihartono⁵⁾

^{1,2}Teknik Informatika, STMIK IKMI Cirebon

³Sistem Informasi, STMIK IKMI Cirebon

^{4,5}Komputerisasi Akuntansi, STMIK IKMI Cirebon

email: ¹yssnii7@gmail.com*, ²st_nana@yahoo.com, ³agusbahtiar038@gmail.com,

⁴niningr157@yahoo.co.id, ⁵willyprihartono@gmail.com

Abstract

Heart disease is one of the leading causes of mortality worldwide, emphasizing the need for accurate early detection systems. Machine learning models such as XGBoost have demonstrated strong performance in medical classification tasks; however, their effectiveness is highly dependent on optimal hyperparameter configurations. This study aims to improve the performance of XGBoost for heart disease classification by applying hyperparameter optimization using the Optuna framework with the Tree-structured Parzen Estimator (TPE) algorithm. The UCI Heart Disease dataset, consisting of 918 records, is used in this study. To address class imbalance, the Synthetic Minority Oversampling Technique (SMOTE) is applied to the training data. Model performance is evaluated using accuracy, precision, recall, F1-score, and ROC-AUC metrics. The experimental results show that the optimized XGBoost model achieves an accuracy of 89.13%, outperforming the baseline model with 87.50%, and improves recall from 87.50% to 89.10%. In addition, the optimized model attains a higher ROC-AUC value of 0.9319, indicating improved classification stability. These findings demonstrate that Optuna-based hyperparameter optimization effectively enhances the performance and reliability of XGBoost, making it suitable for supporting early heart disease diagnosis in medical decision support systems.

Keywords: XGBoost, Optuna, Hyperparameter Optimization, Heart Disease, SMOTE

Abstrak

Penyakit jantung merupakan salah satu penyebab utama kematian di dunia, sehingga diperlukan sistem deteksi dini yang akurat. Model *machine learning* seperti XGBoost telah menunjukkan kinerja yang baik dalam tugas klasifikasi medis, namun efektivitasnya sangat bergantung pada konfigurasi hyperparameter yang optimal. Penelitian ini bertujuan untuk meningkatkan kinerja XGBoost dalam klasifikasi penyakit jantung melalui optimasi hyperparameter menggunakan framework Optuna dengan algoritma *Tree-structured Parzen Estimator (TPE)*. Dataset yang digunakan adalah *UCI Heart Disease* yang terdiri dari 918 data. Untuk mengatasi ketidakseimbangan kelas, digunakan metode *Synthetic Minority Oversampling Technique (SMOTE)* pada data latih. Kinerja model dievaluasi menggunakan metrik akurasi, presisi, *recall*, *F1-score*, dan *ROC-AUC*. Hasil eksperimen menunjukkan bahwa model XGBoost teroptimasi mencapai akurasi sebesar 89.13%, lebih tinggi dibandingkan model baseline sebesar 87.50%, serta meningkatkan nilai *recall* dari 87.50% menjadi 89.10%. Selain itu, model teroptimasi memperoleh nilai *ROC-AUC* yang lebih tinggi, yaitu 0.9319, yang menunjukkan peningkatan stabilitas klasifikasi. Penelitian ini membuktikan bahwa optimasi *hyperparameter* berbasis Optuna secara efektif meningkatkan kinerja dan keandalan XGBoost, sehingga layak digunakan untuk mendukung diagnosis dini penyakit jantung dalam sistem pendukung keputusan medis.

Kata Kunci: XGBoost, Optuna, Optimasi Hyperparameter, Penyakit Jantung, SMOTE

PENDAHULUAN

Penyakit jantung merupakan salah satu masalah kesehatan global dengan tingkat mortalitas yang tinggi dan masih menjadi penyebab utama kematian di berbagai negara. Oleh karena itu, deteksi dini dan diagnosis yang akurat menjadi faktor krusial dalam meningkatkan peluang keselamatan serta kualitas hidup pasien (Saraswat P. and Verma A. and Prasad V. and Tanwar S. and Sharma G. and Sharma R., 2022). Perkembangan *machine learning* membuka peluang besar dalam mendukung proses diagnosis penyakit jantung berbasis data medis, khususnya melalui pemanfaatan *Electronic Health Records* (EHRs) yang menyediakan data pasien secara sistematis dan terstruktur (Amosa L. and Sebastian P. and Ismail I. and Ibrahim O. and Ayinla S., 2023).

Algoritma XGBoost dikenal sebagai salah satu metode *ensemble learning* yang memiliki performa sangat baik untuk tugas klasifikasi, terutama pada data tabular seperti data medis. Berbagai penelitian menunjukkan bahwa XGBoost mampu menghasilkan akurasi dan stabilitas model yang tinggi dalam prediksi penyakit jantung dibandingkan algoritma klasifikasi konvensional (Abdellatif et al., 2022). Namun demikian, performa XGBoost sangat dipengaruhi oleh pengaturan *hyperparameter* yang tepat. Pengaturan secara manual sering kali tidak optimal, sementara metode pencarian tradisional seperti *Grid Search* memerlukan waktu komputasi yang besar dan kurang efisien pada ruang pencarian parameter yang kompleks (Baghdadi S. and Malki A. and Gad I. and Ewis A. and Atlam E., 2023).

Untuk mengatasi permasalahan tersebut, Optuna menawarkan pendekatan optimasi *hyperparameter* otomatis berbasis *Tree-structured Parzen Estimator* (TPE) yang mampu melakukan eksplorasi ruang parameter secara adaptif dan efisien. Pendekatan ini terbukti dapat meningkatkan performa model serta mempercepat proses optimasi dibandingkan metode pencarian konvensional maupun heuristik lainnya (Gabriel L., 2023).

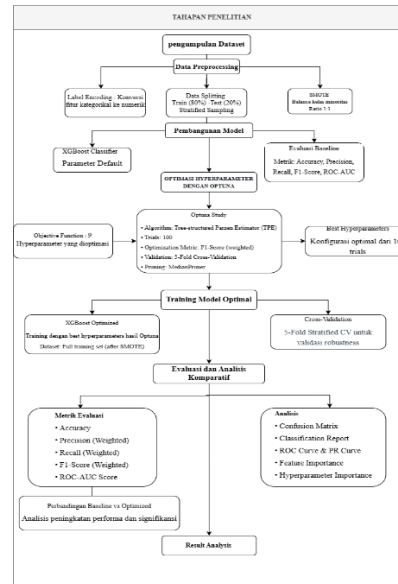
Selain itu, dataset penyakit jantung UCI yang digunakan dalam penelitian ini memiliki ketidakseimbangan kelas yang cukup signifikan, sehingga berpotensi menyebabkan bias model terhadap kelas mayoritas. Kondisi ini dapat menurunkan sensitivitas model dalam mendeteksi kasus positif penyakit jantung. Oleh karena itu, diperlukan metode penyeimbangan data seperti *Synthetic Minority Over-sampling Technique* (SMOTE) untuk meningkatkan kemampuan model dalam mengenali kelas minoritas secara lebih akurat (Jafar & Lee, 2023).

Berdasarkan permasalahan tersebut, penelitian ini bertujuan menerapkan Optuna untuk mengoptimalkan *hyperparameter* XGBoost agar menghasilkan model prediksi penyakit jantung dengan akurasi dan sensitivitas yang lebih baik, dengan penekanan khusus pada peningkatan nilai

recall guna meminimalkan kesalahan *false negative* dalam konteks diagnosis medis.

METODOLOGI PENELITIAN

Metodologi penelitian ini merincikan langkah-langkah, prosedur, serta pendekatan yang digunakan dalam proses penelitian untuk mencapai tujuan yang telah ditetapkan. Tahapan yang dilakukan meliputi perencanaan, pengolahan data, pemodelan, optimasi, serta evaluasi performa model. Penjelasan lengkap dari setiap tahapan disajikan sebagai berikut.



Gambar 1 Metodologi Penelitian

1. Jenis dan Desain Penelitian

Penelitian ini merupakan penelitian kuantitatif eksperimental dengan pendekatan pemodelan machine learning. Desain penelitian yang digunakan adalah comparative experimental design, yaitu membandingkan performa dua model, yakni model XGBoost baseline dan model XGBoost yang telah dioptimasi menggunakan Optuna.

Pendekatan ini dipilih karena memungkinkan evaluasi objektif terhadap dampak optimasi *hyperparameter* terhadap peningkatan performa model prediksi penyakit jantung berdasarkan metrik evaluasi yang terukur secara statistik (Sharma et al., 2023)

2. Sumber Data Penelitian

Objek penelitian ini adalah **Heart Disease Dataset** yang diperoleh dari *UCI Machine Learning Repository*. Dataset ini terdiri dari 918 sampel, 12 fitur prediktor, serta satu variabel target biner yang menunjukkan keberadaan penyakit jantung, dengan nilai 0 untuk pasien tanpa penyakit jantung dan nilai 1 untuk pasien dengan penyakit jantung. Dataset ini dipilih karena telah banyak digunakan sebagai *benchmark* dalam penelitian prediksi penyakit jantung berbasis *machine learning*, sehingga memungkinkan perbandingan hasil

penelitian secara objektif dan konsisten dengan studi sebelumnya.

3. Preprocessing Data

Tahap *preprocessing* meliputi pemeriksaan kualitas data, penanganan tipe data, serta transformasi variabel kategorikal ke dalam bentuk numerik agar dapat diproses oleh algoritma *machine learning*. Selanjutnya, data dibagi menggunakan metode *stratified split* dengan rasio 80% data latih dan 20% data uji untuk menjaga proporsi kelas pada masing-masing subset data.

Untuk mengatasi permasalahan ketidakseimbangan kelas yang umum ditemukan pada data medis, diterapkan metode *Synthetic Minority Over-sampling Technique* (SMOTE) pada data latih. Pendekatan ini bertujuan meningkatkan representasi kelas minoritas sehingga model mampu mempelajari pola data secara lebih seimbang dan mengurangi bias terhadap kelas mayoritas (Park et al., 2021)

4. Pembangunan Model Baseline

Model baseline dibangun menggunakan algoritma **XGBoost Classifier** dengan konfigurasi *hyperparameter* default. Pembangunan model ini bertujuan untuk memperoleh gambaran performa awal sebelum dilakukan optimasi. Hasil dari model baseline digunakan sebagai acuan perbandingan dalam mengevaluasi efektivitas optimasi *hyperparameter* menggunakan Optuna (Ghosh & Khandoker, 2024).

5. Optimasi Hyperparameter Menggunakan Optuna

Optimasi *hyperparameter* dilakukan menggunakan *framework* Optuna dengan algoritma *Tree-structured Parzen Estimator* (TPE). Optuna dipilih karena menggunakan pendekatan *Bayesian optimization* yang adaptif dan efisien dalam menelusuri ruang *hyperparameter* yang kompleks dibandingkan metode pencarian konvensional. Jumlah **100 trial** digunakan dalam proses optimasi untuk mencapai keseimbangan antara eksplorasi ruang parameter yang memadai dan efisiensi komputasi. Penelitian terdahulu menunjukkan bahwa jumlah trial pada kisaran tersebut mampu menghasilkan konfigurasi *hyperparameter* yang stabil dan optimal tanpa meningkatkan beban komputasi secara signifikan (Mahawan et al., 2024).

Proses optimasi bertujuan untuk memperoleh kombinasi *hyperparameter* terbaik yang memaksimalkan performa model pada data latih.

6. Skema Validasi dan Evaluasi

Evaluasi performa model dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *ROC-AUC*. Penekanan utama diberikan pada metrik *recall* karena sangat krusial dalam konteks diagnosis medis untuk meminimalkan kesalahan *false negative*, yaitu kondisi ketika pasien yang sebenarnya sakit diprediksi sebagai sehat.

Selain itu, digunakan metode *5-fold cross-validation* untuk memastikan stabilitas dan kemampuan generalisasi model terhadap data yang tidak terlibat secara langsung dalam proses pelatihan (Wei J. and Yu P. and Li A. and Xiong Z. and Yuan Z. and Luo J., 2024).

7. Teknik Analisis

Analisis dilakukan dengan membandingkan performa model baseline dan model hasil optimasi berdasarkan nilai metrik evaluasi. Selain itu, dilakukan analisis visualisasi berupa *confusion matrix*, kurva ROC, serta *feature importance*. Analisis *feature importance* digunakan untuk mengidentifikasi fitur medis yang paling berpengaruh dalam prediksi penyakit jantung, sehingga meningkatkan interpretabilitas model dan relevansinya dalam pengambilan keputusan klinis (Yi et al., 2023).

HASIL DAN PEMBAHASAN

Bagian ini merangkum hasil inti dari penelitian yang telah dilakukan. Hasil penelitian disajikan melalui analisis performa model *baseline*, hasil optimasi *hyperparameter* dengan Optuna, evaluasi perbandingan performa, serta analisis fitur penting yang berkontribusi terhadap prediksi penyakit jantung. Setiap temuan dibahas secara mendalam dan didukung oleh tabel maupun gambar sebagai bentuk visualisasi data.

1. Hasil Preprocessing Data

Tahap *preprocessing* menunjukkan bahwa *UCI Heart Disease Dataset* tidak mengandung nilai hilang, sehingga proses imputasi data tidak diperlukan. Variabel kategorikal berhasil ditransformasikan ke dalam bentuk numerik agar kompatibel dengan algoritma XGBoost. Pembagian data menggunakan metode *stratified split* dengan rasio 80% data latih dan 20% data uji mampu menjaga proporsi kelas tetap konsisten pada masing-masing subset data. Penerapan *Synthetic Minority Over-sampling Technique* (SMOTE) pada data latih berhasil menyeimbangkan distribusi kelas antara pasien dengan dan tanpa penyakit jantung. Pendekatan ini berperan penting dalam meningkatkan kemampuan model untuk mempelajari pola pada kelas minoritas, yang secara langsung berkontribusi terhadap peningkatan nilai *recall*. Temuan ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa penanganan ketidakseimbangan kelas merupakan faktor krusial dalam meningkatkan sensitivitas model pada data medis.

2. Performa Model Baseline dan Model Teroptimasi

Tabel berikut menunjukkan hasil evaluasi model baseline:

Tabel 1 Hasil Evaluasi Model *Baseline*

Metrik Evaluasi	Nilai Kinerja
Akurasi	87.50%
Presisi (Weighted)s	87.52%
Recall (Weighted)	87.50%
F1-Score (Weighted)	87.51%
ROC-AUC Score	0.9283

Hasil pada Tabel 1 Model baseline XGBoost dengan konfigurasi *hyperparameter* default menghasilkan nilai akurasi sebesar 87,50% dan *recall* sebesar 87,50%, yang menunjukkan bahwa model telah memiliki performa awal yang cukup baik. Namun demikian, nilai *recall* yang masih terbatas mengindikasikan adanya risiko kesalahan *false negative*, yaitu kondisi ketika pasien yang sebenarnya menderita penyakit jantung diprediksi sebagai sehat. Dalam konteks medis, kesalahan ini memiliki implikasi serius karena dapat menyebabkan keterlambatan diagnosis dan penanganan klinis (Wei J. and Yu P. and Li A. and Xiong Z. and Yuan Z. and Luo J., 2024).

Berikut hasil evaluasi model setelah optimasi:

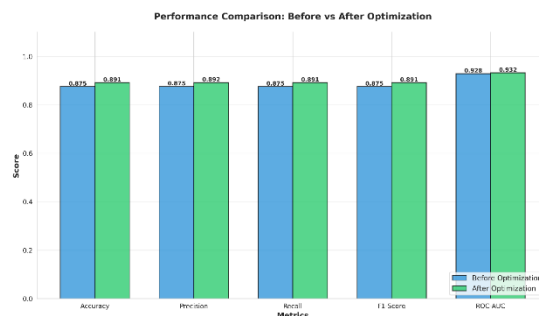
Tabel 2 Hasil Evaluasi Model setelah Optimasi

Metrik	Nilai
Accuracy	89.13%
Precision	89.32%
Recall	89.10%
F1-Score	89.14%
ROC-AUC	0.9319

Hasil pada Tabel 2 menunjukkan adanya peningkatan kinerja model setelah dilakukan optimasi *hyperparameter* menggunakan Optuna dengan algoritma *Tree-structured Parzen Estimator* (TPE) sebanyak 100 trial, performa model menunjukkan peningkatan yang konsisten. Model teroptimasi mencapai akurasi sebesar 89,13%, nilai *recall* sebesar 89,10%, serta peningkatan nilai ROC-AUC menjadi 0,9319. Peningkatan ini menunjukkan bahwa optimasi *hyperparameter* mampu menghasilkan konfigurasi parameter yang lebih sesuai dengan karakteristik data, sehingga meningkatkan kemampuan generalisasi dan sensitivitas model dalam mendeteksi penyakit jantung.

3. Perbandingan Model Baseline dan Model Teroptimasi

Gambar berikut memberikan ilustrasi visual perbandingan akurasi antara model *baseline* dan model hasil optimasi.

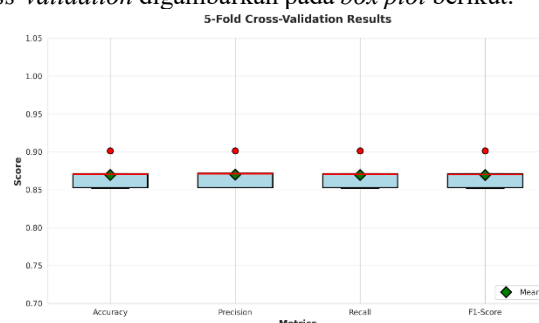


Gambar 2 Perbandingan Akurasi Model *Baseline* dan Teroptimasi

Hasil visualisasi menunjukkan adanya peningkatan akurasi sebesar 1.63% setelah optimasi *hyperparameter*. Meskipun peningkatannya terlihat kecil secara persentase, namun dalam konteks klasifikasi medis, peningkatan kecil tersebut dapat berdampak signifikan dalam mengurangi kesalahan prediksi pada kasus penyakit jantung.

4. Evaluasi Cross-Validation

Untuk memastikan stabilitas dan generalisasi model, dilakukan *5-Fold Cross-Validation*. Hasil *cross-validation* digambarkan pada *box plot* berikut.



Gambar 3 *Box Plot* Hasil *Cross-Validation* Model Teroptimasi

Visualisasi menunjukkan bahwa sebaran nilai akurasi antar *fold relatif* sempit, menandakan bahwa model berada dalam kondisi stabil dan tidak mengalami *overfitting*. Konsistensi performa pada setiap *fold* menjadi indikator bahwa model teroptimasi dapat diandalkan apabila diterapkan pada data nyata.

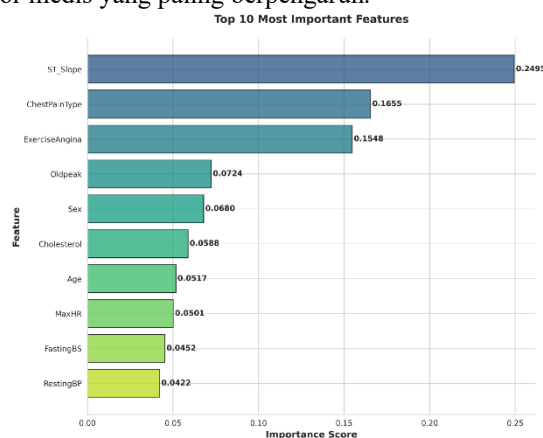
5. Implikasi Kesalahan Klasifikasi dalam Konteks Medis

Dalam diagnosis penyakit jantung, kesalahan *false negative* memiliki dampak klinis yang lebih kritis dibandingkan *false positive*. Peningkatan nilai *recall* pada model teroptimasi menunjukkan bahwa lebih banyak kasus penyakit jantung berhasil diidentifikasi secara benar, sehingga risiko terlewatnya pasien berisiko tinggi dapat diminimalkan. Temuan ini menegaskan bahwa penekanan pada metrik *recall* merupakan strategi evaluasi yang tepat untuk sistem pendukung keputusan medis berbasis *machine learning* (Yi et al., 2023).

6. Analisis Feature Importance

XGBoost menyediakan mekanisme untuk menilai pentingnya fitur dalam proses prediksi.

Hasil *feature importance* membantu memahami faktor medis yang paling berpengaruh.



Gambar 4 Visualisasi Feature Importance XGBoost

Hasil analisis *feature importance* menunjukkan bahwa fitur **thalach**, **age**, **cp**, **oldpeak**, dan **ca** memiliki kontribusi terbesar dalam proses prediksi penyakit jantung. Secara klinis, fitur-fitur tersebut berkaitan erat dengan kondisi kardiovaskular, seperti respons denyut jantung terhadap aktivitas fisik (*thalach*), usia sebagai faktor risiko utama (*age*), serta indikasi iskemia dan penyempitan pembuluh darah (*oldpeak* dan *ca*). Konsistensi antara hasil model dan literatur medis menunjukkan bahwa model tidak hanya akurat secara numerik, tetapi juga memiliki relevansi klinis yang kuat.

7. Perbandingan dengan Penelitian Terdahulu

Dibandingkan dengan penelitian sebelumnya yang melaporkan tingkat akurasi pada kisaran 85–88% menggunakan pendekatan *machine learning* konvensional, model XGBoost teroptimasi dalam penelitian ini menunjukkan performa yang kompetitif dengan peningkatan sensitivitas yang lebih baik. Fokus pada optimasi *hyperparameter* berbasis Optuna serta penekanan pada metrik *recall* menjadi kontribusi utama yang membedakan penelitian ini dari studi terdahulu, khususnya dalam konteks penerapan model prediksi penyakit jantung yang berorientasi pada keselamatan pasien (Baghdadi S. and Malki A. and Gad I. and Ewis A. and Atlam E., 2023).

SIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa optimasi *hyperparameter* menggunakan Optuna secara signifikan mampu meningkatkan performa algoritma XGBoost dalam melakukan klasifikasi penyakit jantung. Model baseline yang pada awalnya memiliki keterbatasan terutama dalam mendeteksi kasus positif, berhasil ditingkatkan setelah dilakukan optimasi melalui pendekatan *Tree-structured Parzen Estimator (TPE)*. Peningkatan akurasi, *recall*, *F1-score* dan nilai *ROC-AUC* mencerminkan bahwa model teroptimasi lebih sensitif, stabil, dan mampu memberikan prediksi yang lebih tepat. Selain itu, penggunaan

SMOTE dalam tahap preprocessing terbukti efektif dalam mengurangi *bias* akibat ketidakseimbangan kelas, sehingga model dapat mengenali pola pada data minoritas dengan lebih akurat. Berdasarkan hasil tersebut, penelitian ini memberikan kontribusi penting dalam pemanfaatan machine learning untuk mendukung sistem deteksi dini penyakit jantung.

Penelitian ini memiliki beberapa keterbatasan yang perlu diperhatikan. Pertama, ukuran dataset yang digunakan relatif terbatas dan berasal dari satu sumber publik, sehingga variasi karakteristik pasien dan kondisi klinis belum sepenuhnya terwakili. Kedua, jumlah fitur yang dianalisis masih terbatas pada atribut yang tersedia dalam dataset, sehingga faktor risiko lain yang berpotensi relevan belum dapat dieksplorasi.

Untuk penelitian selanjutnya, disarankan penggunaan dataset yang lebih besar dan lebih beragam agar kemampuan generalisasi model dapat ditingkatkan. Eksplorasi metode optimasi lain seperti Bayesian Optimization alternatif atau Hyperband juga dapat dilakukan untuk membandingkan efektivitasnya dengan Optuna. Selain itu, penerapan pendekatan *Explainable AI (XAI)* direkomendasikan guna meningkatkan transparansi dan kepercayaan pengguna klinis terhadap hasil prediksi. Integrasi model ke dalam sistem berbasis web atau aplikasi klinis juga menjadi langkah lanjutan yang potensial agar hasil penelitian dapat memberikan dampak langsung dalam praktik layanan kesehatan.

TERIMA KASIH

Penulis menyampaikan apresiasi kepada STMIK IKMI Cirebon atas dukungan institusional, fasilitas akademik, serta lingkungan penelitian yang kondusif sehingga penelitian dan penulisan artikel ini dapat dilaksanakan dan diselesaikan dengan baik. Penelitian ini juga mendapatkan manfaat dari berbagai sumber referensi ilmiah dan dataset publik yang digunakan sebagai dasar analisis, khususnya dataset UCI Heart Disease yang berkontribusi dalam mendukung proses eksperimen dan evaluasi model. Seluruh dukungan tersebut berperan penting dalam memastikan kelancaran dan kualitas penelitian ini.

DAFTAR PUSTAKA

- Abdellatif, A., Abdellatef, H., Kanesan, J., Chow, C., Chuah, J., & Ghenni, H. (2022). An effective heart disease detection and severity level classification model using machine learning and hyperparameter optimization methods. *IEEE Access*, *10*, 79974–79985. <https://doi.org/10.1109/access.2022.3191669>
- Amosa L. and Sebastian P. and Ismail I. and Ibrahim O. and Ayinla S., T. and I. (2023). Clinical errors from acronym use in electronic health record: a review of NLP-based

- disambiguation techniques. *IEEE Access*, *11*, 59297–59316. <https://doi.org/10.1109/access.2023.3284682>
- Baghdadi S. and Malki A. and Gad I. and Ewis A. and Atlam E., N. and A. (2023). Advanced machine learning techniques for cardiovascular disease early detection and diagnosis. *Journal of Big Data*, *10*(1). <https://doi.org/10.1186/s40537-023-00817-1>
- Gabriel L., J. and A. (2023). Optimizing coronary artery disease diagnosis: a heuristic approach using robust data preprocessing and automated hyperparameter tuning of extreme gradient boosting. *IEEE Access*, *11*, 112988–113007. <https://doi.org/10.1109/access.2023.3324037>
- Ghosh, S., & Khandoker, A. (2024). Investigation on explainable machine learning models to predict chronic kidney diseases. *Scientific Reports*, *14*(1). <https://doi.org/10.1038/s41598-024-54375-4>
- Jafar, A., & Lee, M. (2023). HypGB: High accuracy GB classifier for predicting heart disease with HyperOpt HPO framework and LASSO FS method. *IEEE Access*, *11*, 138201–138214. <https://doi.org/10.1109/access.2023.3339225>
- Mahawan, T., Luckett, T., Iza, A., Pornputtapong, N., & Caamaño-Gutiérrez, E. (2024). Robust and consistent biomarker candidates identification by a machine learning approach applied to pancreatic ductal adenocarcinoma metastasis. *BMC Medical Informatics and Decision Making*, *24*(S4). <https://doi.org/10.1186/s12911-024-02578-0>
- Park, D., Park, M., Lee, H., Kim, Y., Kim, Y., & Park, Y. (2021). Development of machine learning model for diagnostic disease prediction based on laboratory tests. *Scientific Reports*, *11*(1). <https://doi.org/10.1038/s41598-021-87171-5>
- Saraswat P. and Verma A. and Prasad V. and Tanwar S. and Sharma G. and Sharma R., D. and B. (2022). Explainable AI for Healthcare 5.0: Opportunities and challenges. *IEEE Access*, *10*, 84486–84517. <https://doi.org/10.1109/access.2022.3197671>
- Sharma, N., Appukutti, S., Garg, U., Mukherjee, J., & Mishra, S. (2023). Analysis of Student's Academic Performance based on their Time Spent on Extra-Curricular Activities using Machine Learning Techniques. *International Journal of Modern Education and Computer Science*, *15*(1), 46–57. <https://doi.org/10.5815/ijmeecs.2023.01.04>
- Wei J. and Yu P. and Li A. and Xiong Z. and Yuan Z. and Luo J., C. and W. (2024). Comparison of different machine learning classification models for predicting deep vein thrombosis in lower extremity fractures. *Scientific Reports*, *14*(1). <https://doi.org/10.1038/s41598-024-57711-w>
- Yi, F., Yang, H., Chen, D., Qin, Y., Han, H., Cui, J., & Yu, H. (2023). XGBoost-SHAP-based interpretable diagnostic framework for Alzheimer's disease. *BMC Medical Informatics and Decision Making*, *23*(1). <https://doi.org/10.1186/s12911-023-02238-9>.