p-issn : 2338-4697
e-issn : 2579-3322

PENGEMBANGAN MODEL PREDIKTIF RISIKO PENYAKIT JANTUNG MENGGUNAKAN ALGORITMA XGBOOST DENGAN OPTIMASI HYPERPARAMETER

Hery Oktafiandi[1] ,Winarnie[2], Pebriyanti Panjaitan[3], M. Fajar Ramadhan[4], Yohanes[5]*) M. Denny Ricardo[6]*)
[1,3,4] *Teknik Informatika, Satu University, Bandung, West Java, Indonesia.*
[1,5,6] *Sistem Informasi, Satu University, Bandung, West Java, Indonesia*
Email:*[1]hery.oktafiandy@univ.satu.ac.id,,[2]winarnie@satu.univ.ac.id,,
[3]pebriyanti.panjaitan@univ.satu.ac.id, m.ramadham@univ.satu.ac.id, yohanes@univ.satu.ac.id, denny.richardo@univ.satu.ac.id

Abstract

Heart disease remains one of the leading causes of mortality worldwide, posing a major challenge to global healthcare. Early detection of heart disease risk is crucial for improving prevention efficacy and patient management. This study aimed to develop a heart disease risk prediction model using the Extreme Gradient Boosting (XGBoost) algorithm optimized with GridSearchCV-based hyperparameter tuning. The dataset was sourced from the Heart Disease Dataset, comprising 1,025 patient records and 14 medical attributes reflecting physiological conditions. The experimental method involved exploratory data analysis, data cleaning, train-test splitting (80:20), data standardization, hyperparameter tuning, and model evaluation using a confusion matrix. The results demonstrated that the optimized hyperparameter configuration achieved a high classification performance, yielding an accuracy of 98.54%, precision of 100%, recall of 97.09%, and an F1-score of 98.52%. Based on the feature importance analysis, thalach (maximum heart rate achieved), cp (chest pain type), and ca (number of major vessels) were identified as the three most influential clinical factors driving the model's predictions. These findings prove that the optimized XGBoost algorithm holds significant potential as a clinical decision support tool to assist in the early screening of heart disease risk consistently and accurately.

Keywords: *Machine Learning, **XG**Boost, Heart Disease, Risk Prediction*

1. Pendahuluan

Penyakit kardiovaskular atau penyakit jantung tetap menjadi ancaman kesehatan global utama dengan tingkat mortalitas tertinggi di dunia. *World Health Organization* (WHO) melaporkan bahwa jutaan kematian setiap tahunnya disebabkan oleh gangguan fungsi jantung dan pembuluh darah, yang juga berdampak langsung pada penurunan kualitas hidup serta beban ekonomi sektor kesehatan. Mengingat progresivitas penyakit yang cepat, penanganan medis yang terlambat sering kali berakibat fatal. Oleh karena itu, identifikasi risiko dan deteksi dini kondisi fisiologis pasien menjadi langkah krusial dalam upaya preventif dan intervensi klinis yang lebih efektif.[1]

Perkembangan teknologi kecerdasan buatan, khususnya *machine learning*, membuka paradigma baru dalam pengolahan data medis untuk mendukung keputusan klinis. Melalui kemampuannya dalam menganalisis data terstruktur dalam volume besar, *machine learning* mampu mengenali pola-pola anomali dan korelasi nonlinier kompleks dari indikator klinis pasien yang sering kali sulit diidentifikasi melalui pendekatan statistik konvensional. Berbagai algoritma klasifikasi seperti *Support Vector Machine* (SVM), *Random Forest*, dan *Artificial Neural Network* (ANN) telah banyak dieksplorasi dalam penelitian terdahulu dan terbukti mampu memberikan akurasi prediksi risiko penyakit jantung yang menjanjikan.[2]

Di antara rumpun algoritma berbasis pohon keputusan (*tree-based models*), *Extreme Gradient Boosting* (XGBoost) menonjol sebagai salah satu metode terbaik karena efisiensi komputasi dan kinerja generalisasinya yang superior pada data tabular. Algoritma ini mengintegrasikan mekanisme *boosting* bertingkat dengan teknik regularisasi formal L1 dan L2, sehingga sangat efektif dalam menekan risiko *overfitting* sekaligus meminimalkan fungsi kerugian (*loss function*) secara optimal.

p-issn : 2338-4697
e-issn : 2579-3322

Kendati XGBoost menawarkan keunggulan komputasional yang tinggi, performa akhirnya sangat bergantung pada konfigurasi kombinasi parameter internalnya (*hyperparameters*). Penggunaan parameter bawaan (*default*) tanpa proses penyelarasan yang presisi sering kali membuat model gagal mencapai titik konvergensi terbaik.[3]

Berdasarkan pemetaan *State of the Art* (SOTA), sebagian besar literatur terfokus pada peningkatan akurasi mentah dengan menguji berbagai arsitektur algoritma tunggal maupun *ensemble*. Namun, terdapat beberapa keterbatasan utama (*research gap*) yang melandasi penelitian ini.[4] Pertama, proses pencarian *hyperparameter* pada algoritma *boosting* dalam prediksi klinis sering kali dilakukan secara trial-and-error atau belum dioptimasi secara komprehensif.[5] Kedua, terdapat ambiguitas atau kurangnya pembahasan mendalam mengenai aspek interpretabilitas klinis; sebagian besar studi melaporkan model berperforma tinggi sebagai sebuah *black-box* tanpa mengeksplorasi kontribusi dan relevansi medis dari fitur-fitur dominan yang memengaruhi keputusan model. Masih terdapat kesenjangan yang lebar antara metrik performa komputasional dan pemahaman indikator medis secara empiris.[6]

Untuk mengatasi keterbatasan tersebut, penelitian ini mengusulkan pengembangan model prediksi risiko penyakit jantung menggunakan algoritma XGBoost yang dioptimasi secara sistematis melalui pendekatan *GridSearchCV*, sekaligus diintegrasikan dengan analisis *feature importance*. Konfigurasi *GridSearchCV* diterapkan untuk mengevaluasi ruang parameter secara menyeluruh guna menemukan kombinasi *n_estimators*, *learning_rate*, dan *max_depth* terbaik.[7] Nilai kebaruan (*novelty*) dari penelitian ini terletak pada integrasi kerangka kerja yang tidak hanya mengejar metrik akurasi tinggi, melainkan menjembatani performa model dengan pemahaman klinis melalui identifikasi faktor-faktor kesehatan dominan (seperti *thalach*, *cp*, dan *ca*) secara transparan.[8]

Kontribusi ilmiah dari penelitian ini dirumuskan ke dalam empat poin utama:

1. Membangun model prediksi risiko penyakit jantung berbasis XGBoost dengan tingkat generalisasi tinggi melalui optimasi parameter terukur menggunakan *GridSearchCV*.
2. Mengidentifikasi kontribusi dan peringkat faktor-faktor medis utama yang memengaruhi hasil klasifikasi melalui ekstraksi nilai *feature importance*.
3. Menyediakan analisis integratif yang menghubungkan metrik evaluasi *machine learning* dengan indikator fisiologis medis untuk mengurangi risiko kesalahan diagnosis klinis (*false negative*).
4. Memberikan landasan empiris yang kuat untuk pengembangan *Clinical Decision Support System* (CDSS) sebagai instrumen skrining dini penyakit jantung di fasilitas pelayanan kesehatan.

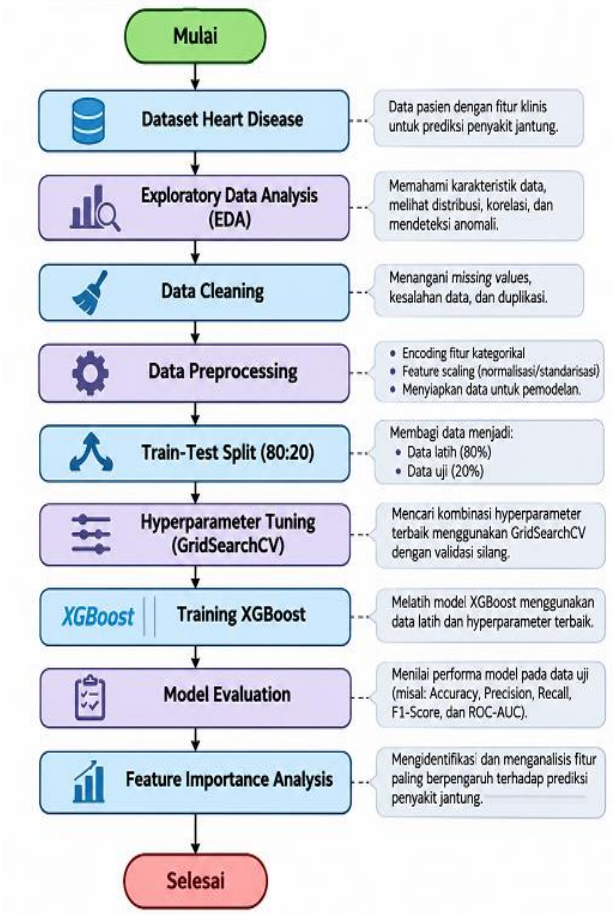
2. Pembahasan

2.1 Desain dan Alur Penelitian

Penelitian ini menerapkan pendekatan kuantitatif dengan metode eksperimen berbasis *machine learning* untuk mengonstruksi model prediktif risiko penyakit jantung. Algoritma XGBoost dipilih sebagai pengklasifikasi utama karena kemampuannya yang unggul dalam mengekstrak pola nonlinier pada data tabular, serta adanya mekanisme regularisasi internal untuk mengendalikan kompleksitas model.[9]

Secara sistematis, tahapan eksperimen dirancang untuk menjamin validitas dan reproduktibilitas hasil prediksi. Kerangka kerja penelitian ini disusun ke dalam delapan tahapan utama yang saling berkesinambungan, dimulai dari akuisisi data hingga interpretasi fitur secara klinis. Arsitektur dan alur pelaksanaan eksperimen secara menyeluruh disajikan pada Gambar 1.

p-issn : 2338-4697
e-issn : 2579-3322



Gambar 1. Diagram Alir Penelitian

2.2 Dataset Penelitian

Eksperimen dilakukan menggunakan *Heart Disease Dataset* publik yang diperoleh dari UCI Machine Learning Repository. Dataset ini mengintegrasikan 1.025 sampel data pasien yang terdiri dari 14 atribut klinis utama, mencakup karakteristik demografis, hasil pemeriksaan fisik, dan indikator laboratorium kardiologi. Variabel target dalam penelitian ini bersifat biner, yang merepresentasikan status diagnosis klinis pasien ke dalam dua kelas terpisah: Kelas 0 untuk kondisi pasien yang tidak terindikasi penyakit jantung, dan Kelas 1 untuk pasien yang terindikasi mengidap penyakit jantung.

2.3 Exploratory Data Analysis (EDA)

Tahap eksplorasi data dilakukan untuk menganalisis karakteristik statistik dan distribusi dari seluruh variabel sebelum memasuki fase pemodelan.[10] Eksplorasi ini berfokus pada empat aspek utama:

1. **Analisis Distribusi Atribut:** Memetakan penyebaran data pada setiap atribut numerik untuk memahami kecenderungan pemusatan data.
2. **Proporsi Kelas Target:** Memeriksa keseimbangan antara jumlah sampel Kelas 0 dan Kelas 1 guna menghindari bias mayoritas saat pelatihan model.
3. **Identifikasi Outlier:** Menggunakan visualisasi *boxplot* untuk mendeteksi nilai-nilai ekstrem pada atribut kontinu yang berpotensi mengganggu performa model.
4. **Matriks Korelasi:** Menghitung koefisien korelasi antar-variabel menggunakan metode *Pearson Correlation* untuk mengidentifikasi dependensi linier atau multikolinearitas antar-fitur klinis.

2.4 Data Preprocessing dan Validasi Hold-Out

Aktivitas pra-pemrosesan data dilakukan secara rigid untuk memastikan kualitas data masukan (*input data*). Tahapan ini dibagi menjadi tiga sub-proses utama:

1. **Data Cleaning:** Melakukan audit komprehensif terhadap data untuk mendeteksi adanya data duplikat, anomali nilai, atau *missing value*. Hasil pemeriksaan menunjukkan dataset bersih dari nilai kosong (*missing value* = 0), sehingga seluruh 1.025 data pasien dinyatakan layak untuk diproses lebih lanjut.
2. **Train-Test Split:** Untuk menguji kemampuan generalisasi model pada data yang belum pernah dilihat (*unseen data*), dataset dibagi menggunakan metode *hold-out validation* dengan proporsi 80% untuk *training set* (820 sampel) dan 20% untuk *testing set* (205 sampel). Pembagian ini diikat menggunakan parameter random_state yang konsisten demi menjamin reproduktibilitas eksperimen.
3. **Standardisasi Data:** Mengingat atribut numerik memiliki skala satuan yang berbeda (misalnya, kadar kolesterol dalam mg/dl dan usia dalam tahun), dilakukan transformasi menggunakan StandardScaler.

p-issn : 2338-4697
e-issn : 2579-3322

2.5 Optimasi Hyperparameter Menggunakan GridSearchCV

Untuk menghindari penurunan performa akibat penggunaan parameter bawaan (*default*), optimasi dilakukan secara mekanis menggunakan metode *GridSearchCV* dengan teknik *stratified 5-fold cross-validation*. Proses ini mengevaluasi seluruh kombinasi parameter dalam ruang pencarian yang ditentukan untuk meminimalkan nilai *log-loss*. [11]Daftar parameter dan kandidat nilai yang diuji dalam penelitian ini disajikan pada Tabel 1.

Tabel 1. *Ruang Parameter Grid Search*

Hyperparameter	Deskripsi Fungsi	Kandidat Nilai
n_estimators	Jumlah pohon keputusan yang dibangun dalam *ensemble*	50, 100, 200
learning_rate	Faktor pengali untuk mengontrol laju koreksi setiap iterasi	0.01, 0.1, 0.2
max_depth	Batas kedalaman maksimum dari setiap pohon keputusan	3, 5, 7

2.6 Metrik Evaluasi Performa

Evaluasi kinerja model dikuantifikasi secara komprehensif melalui ekstraksi data dari *Confusion Matrix*. [12] Performa model diukur berdasarkan empat metrik standar klasifikasi, yaitu *Accuracy*, *Precision* , *Recall/Sensitivity* , dan *F1-Score*.

2.7 Hasil Pelatihan Model dan Optimasi Parameter

Proses pencarian hyperparameter menggunakan *GridSearchCV* berbasis *stratified 5-fold cross-validation* berhasil menemukan konfigurasi parameter optimal untuk arsitektur XGBoost. Kombinasi terbaik yang menghasilkan nilai *log-loss* terendah adalah n_estimators = 100, learning_rate = 0.1, dan max_depth = 5.

Penerapan *hyperparameter tuning* ini terbukti memberikan dampak signifikan terhadap stabilitas model. Jika dibandingkan dengan penggunaan parameter bawaan (*default*) yang sering kali memicu fenomena *overfitting* pada data tabular medis, pembatasan kedalaman pohon (max_depth = 5) dan pemilihan laju pembelajaran yang moderat (learning_rate = 0.1) berhasil menyeimbangkan aspek bias dan varians model secara optimal selama fase pelatihan.

2.8 Evaluasi Kinerja Klasifikasi

Setelah mengunci konfigurasi parameter terbaik, model diuji menggunakan *testing set* yang berisi 205 data pasien terpisah (data yang belum pernah dilihat oleh model). Performa kuantitatif dari model prediksi diukur secara ketat melalui metrik klasifikasi standar yang disajikan pada Tabel 2.

Tabel 2. *Hasil Evaluasi Performa Model*

Metrik Klasifikasi	Nilai Capaian Eksperimen
Accuracy	98,54%
Precision	100,00%
Recall / Sensitivity	97,09%
F1-Score	98,52%

Model prediktif yang dikembangkan berhasil mencapai tingkat *Accuracy* sebesar 98,54%, sebuah angka yang merepresentasikan kemampuan diskriminasi global yang sangat andal dalam memisahkan kelompok berisiko tinggi dan kelompok sehat. Nilai *Precision* yang menyentuh angka mutlak 100% menunjukkan bahwa dari seluruh pasien yang diprediksi oleh model akan menderita penyakit jantung, tidak ada satu pun yang meleset (*zero false positive*). Sementara itu, nilai *Recall* sebesar 97,09% mengonfirmasi bahwa model mampu menyarian dan menemukan hampir seluruh pasien yang secara aktual memang mengidap gangguan jantung di lapangan.

Untuk memetakan detail kesalahan prediksi secara granular, hasil ekstraksi *testing set* disajikan ke dalam bentuk matriks kontingensi pada Tabel 3.

Tabel 3. *Confusion Matrix Hasil Pengujian*

Aktual / Prediksi	Terprediksi Tidak Sakit (Kelas 0)	Terprediksi Sakit (Kelas 1)
Aktual Tidak Sakit (Kelas 0)	102 (TN)	0 (FP)
Aktual Sakit (Kelas 1)	3 (FN)	100 (TP)

Berdasarkan Tabel 4, dari total 205 data acak yang diuji, model hanya melakukan tiga kesalahan klasifikasi (*misclassification rate* = 1,46%). Ketiga kesalahan tersebut murni berada pada kuadran *False Negative* (FN), di mana terdapat 3 pasien yang

p-issn : 2338-4697
e-issn : 2579-3322

secara aktual sakit namun salah teridentifikasi sebagai individu yang sehat.
Dalam konteks manajemen risiko medis, kemunculan kasus *False Negative* jauh lebih berbahaya dibandingkan *False Positive*. Kegagalan sistem dalam mendeteksi keberadaan penyakit jantung berpotensi mengakibatkan keterlambatan penanganan klinis fatal bagi pasien. Meskipun angka 3 kasus ini relatif sangat kecil, aspek ini menjadi catatan kritis bagi pengembangan sistem di masa depan untuk terus memperketat ambang batas (*threshold*) probabilitas klasifikasi model.

2.9 Analisis Feature Importance dan Relevansi Klinis

Salah satu nilai kebaruan (*novelty*) utama dari penelitian ini adalah mereduksi sifat pemodelan *black-box* pada algoritma *ensemble* dengan melakukan ekstraksi nilai *feature importance*.[11] Langkah ini bertujuan untuk mengidentifikasi variabel mana saja yang memiliki kontribusi paling dominan dalam memengaruhi arah keputusan klasifikasi model. Peringkat faktor kesehatan yang paling berpengaruh disajikan pada Tabel 4.

Tabel 4. *Peringkat Faktor Dominan Prediksi Penyakit Jantung*

Peringkat Kontribusi	Nama Atribut Medis	Deskripsi Indikator Fisiologis
Peringkat 1	*thalach*	Denyut jantung maksimum yang dicapai (*maximum heart rate achieved*)
Peringkat 2	*cp*	Karakteristik tipe nyeri dada (*chest pain type*)
Peringkat 3	*ca*	Jumlah pembuluh darah utama yang diwarnai dengan fluoroskopi

Hasil penentuan peringkat fitur pada Tabel 5 menunjukkan keselarasan yang sangat tinggi (*high interpretability*) dengan patofisiologi medis di bidang kardiologi:

1. ***thalach* (Maximum Heart Rate):** Indikator ini mencerminkan kapasitas fungsional dan efisiensi kardiovaskular pasien saat beraktivitas. Penurunan dramatis pada batas denyut jantung maksimum secara klinis sering kali menjadi penanda awal adanya iskemia miokard atau pelemahan otot jantung.
2. ***cp* (Chest Pain Type):** Angina atau nyeri dada merupakan manifestasi klinis paling klasik akibat penyempitan arteri koroner. Model berhasil menangkap parameter ini sebagai fitur krusial karena sifatnya yang sangat sensitif dalam mendiagnosis penyakit jantung koroner secara langsung.
3. ***ca* (Number of Major Vessels):** Jumlah pembuluh darah utama yang mengalami penyumbatan atau penyempitan (terdeteksi lewat teknik fluoroskopi) berkorelasi linear dengan tingkat keparahan sumbatan sirkulasi darah. Semakin tinggi jumlah pembuluh darah yang bermasalah, semakin besar risiko terjadinya serangan jantung.

Kesesuaian empiris antara penemuan algoritma XGBoost dan teori medis kardiologi konvensional ini membuktikan bahwa model yang dibangun tidak hanya unggul secara matematis, melainkan memiliki akuntabilitas logis yang kuat untuk diterapkan di lingkungan klinis riil.

3. Kesimpulan

Penelitian ini berhasil mengembangkan model prediktif risiko penyakit jantung yang anda dan terinterpretasi secara klinis melalui integrasi algoritma *Extreme Gradient Boosting* (XGBoost) dan optimasi hyperparameter berbasis *GridSearchCV*. Berdasarkan hasil eksperimen menggunakan *Heart Disease Dataset* dengan 1.025 data pasien, penerapan konfigurasi parameter optimal (n_estimators = 100, learning_rate = 0.1, dan max_depth = 5) terbukti secara signifikan mampu mendongkrak performa klasifikasi model. Model usulan sukses mencatatkan tingkat akurasi global yang superior sebesar 98,54%, dengan capaian metrik *Precision* sebesar 100,00%, *Recall* sebesar 97,09%, dan *F1-Score* sebesar 98,52%.
Melalui ekstraksi nilai *feature importance*, penelitian ini berhasil mengidentifikasi bahwa variabel *thalach* (denyut jantung maksimum yang dicapai), *cp* (karakteristik tipe nyeri dada), dan *ca* (jumlah pembuluh darah utama) merupakan tiga indikator klinis paling dominan dalam proses pengambilan keputusan klasifikasi model. Keselarasan yang tinggi antara temuan komputasional algoritma dan patofisiologi kardiologi medis ini membuktikan bahwa model yang dibangun memiliki tingkat interpretabilitas

p-issn : 2338-4697
e-issn : 2579-3322

logis yang kuat dan tidak bersifat *black-box*. Temuan ini mengonfirmasi potensi besar algoritma XGBoost yang dioptimasi sebagai instrumen pendukung keputusan klinis (*Clinical Decision Support System*) yang konsisten untuk membantu tenaga kesehatan dalam melakukan skrining dan deteksi dini risiko penyakit jantung secara lebih cepat, akurat, dan transparan.

Meskipun menunjukkan kinerja yang sangat memuaskan, model ini masih memiliki keterbatasan karena pembelajarannya yang berbasis pada satu sumber dataset publik, belum diuji dengan metrik kurva ROC-AUC, serta belum dievaluasi menggunakan data eksternal riil dari institusi rumah sakit. Oleh karena itu, agenda riset masa depan (*future work*) direkomendasikan untuk berfokus pada:

1. Melakukan validasi silang eksternal (*external cross-validation*) menggunakan data rekam medis multi-pusat kesehatan (*multi-center clinical data*) guna menguji daya generalisasi dan resiliensi model pada populasi pasien yang lebih heterogen.

2. Mengintegrasikan kerangka kerja *Explainable Artificial Intelligence* (XAI) yang lebih mahir, seperti pendekatan SHAP (*Shapley Additive exPlanations*) atau LIME, untuk memetakan visualisasi kontribusi fitur secara individual dan mendalam pada setiap pasien.

3. Melakukan eksperimen komparatif multi-algoritma secara masif dengan melibatkan model arsitektur *Deep Learning* dan arsitektur *ensemble* modern lainnya untuk memetakan batas performa komputasional pada domain informatika medis.

Daftar Pustaka

[1] P. Rani, R. Kumar, N. M. O. S. Ahmed, and A. Jain, “A decision support system for heart disease prediction based upon machine learning,” *J. Reliab. Intell. Environ.*, vol. 7, no. 3, pp. 263–275, 2021, doi: 10.1007/s40860-021-00133-6.

[2] S. K. Kiangala and Z. Wang, “An effective adaptive customization framework for small manufacturing plants using extreme gradient boosting-XGBoost and random forest ensemble learning algorithms in an Industry 4.0 environment[Formula presented],” *Mach. Learn. with Appl.*, vol. 4, no. December 2020, p. 100024, 2021, doi: 10.1016/j.mlwa.2021.100024.

[3] S. A. Naghibi, H. Hashemi, R. Berndtsson, and S. Lee, “Application of extreme gradient boosting and parallel random forest algorithms for assessing groundwater spring potential using DEM-derived factors,” *J. Hydrol.*, vol. 589, p. 125197, 2020, doi: 10.1016/j.jhydrol.2020.125197.

[4] P. H. V. Sesha Talpa Sai *et al.*, “Cardiovascular Disease Prediction Using Machine Learning,” *Lect. Notes Networks Syst.*, vol. 1107 LNNS, pp. 443–453, 2024, doi: 10.1007/978-981-97-6581-2_36.

[5] E. T. Kimchi, M. Nikfarjam, N. J. Gusani, D. M. Avella, and K. F. Staveley-O’Carroll, “Combined pancreaticoduodenectomy and extended right hemicolectomy: Outcomes and indications,” *Hpb*, vol. 11, no. 7, pp. 559–564, 2009, doi: 10.1111/j.1477-2574.2009.00087.x.

[6] M. Niang, M. Ndong, I. Dioum, I. Diop, M. Mashaly, and M. A. A. El Ghany, “Comparison of Random Forest and Extreme Gradient Boosting Fingerprints to Enhance an indoor Wifi Localization System,” *2021 Int. Mobile, Intelligent, Ubiquitous Comput. Conf. MIUCC 2021*, no. 4, pp. 143–148, 2021, doi: 10.1109/MIUCC52538.2021.9447676.

[7] E. Casiraghi *et al.*, “Explainable Machine Learning for Early Assessment of COVID-19 Risk Prediction in Emergency Departments,” *IEEE Access*, vol. 8, no. December 2019, pp. 196299–196325, 2020, doi: 10.1109/ACCESS.2020.3034032.

[8] K. Yuan, L. Yang, Y. Huang, and Z. Li, “Heart Disease Prediction Algorithm Based on Ensemble Learning,” *Proc. - 2020 7th Int. Conf. Dependable Syst. Their Appl. DSA 2020*, pp. 293–298, 2020, doi: 10.1109/DSA51864.2020.00052.

[9] A. C. Dimopoulos *et al.*, “Machine learning methodologies versus cardiovascular risk scores, in predicting disease risk,” *BMC Med. Res. Methodol.*, vol. 18, no. 1, pp. 1–11, 2018, doi: 10.1186/s12874-018-0644-1.

[10] M. L. Dobias, M. B. Sugarman, M. C. Mullarkey, and J. L. Schleider, “Predicting Mental Health Treatment Access Among Adolescents With Elevated Depressive Symptoms: Machine Learning Approaches,” *Adm. Policy Ment. Heal. Ment. Heal. Serv. Res.*, vol. 49, no. 1, pp. 88–103, 2022, doi: 10.1007/s10488-021-01146-2.

[11] W. Zhang, C. Wu, H. Zhong, Y. Li, and L. Wang, “Prediction of undrained shear strength

p-issn : 2338-4697
e-issn : 2579-3322

using extreme gradient boosting and random forest based on Bayesian optimization," *Geosci. Front.*, vol. 12, no. 1, pp. 469–477, 2021, doi: 10.1016/j.gsf.2020.03.007.
[12] S. Meacham, G. Isaac, D. Nauck, and B. Virginas, "Towards Explainable AI: Design and Development for Explanation of Machine Learning Predictions for a Patient Readmittance Medical Application," *Adv. Intell. Syst. Comput.*, vol. 997, pp. 939–955, 2019, doi: 10.1007/978-3-030-22871-2_67.