

PENERAPAN ALGORITMA XGBOOST UNTUK KLASIFIKASI KELAYAKAN DAN REKOMENDASI PEMILIHAN METODE KONTRASEPSI BERDASARKAN DATA KLINIS PASANGAN USIA SUBUR

Artientin*, La Ode Muhammad Golok Jaya², Andi Tenriawaru³

^{1,2}Informatika, Universitas Halu Oleo; Kampus Hijau Bumi Tridharma Anduonohu, Jalan H.E.A Mokodompit, Kendari 93232; Tlp. (0401) 3194163

³Ilmu Komputer, Universitas Halu Oleo; Kampus Hijau Bumi Tridharma Anduonohu, Jalan H.E.A Mokodompit, Kendari 93232; Tlp. (0401) 3194163

Keywords:

Klasifikasi, Metode Kontrasepsi, Rekomendasi, Pasangan Usia Subur, XGBoost

Correspondent Email:

artientintien@gmail.com

Abstrak. Pemilihan metode kontrasepsi perlu mempertimbangkan kondisi klinis pasangan usia subur (PUS). Namun, keterbatasan waktu konseling dan kurangnya pemahaman PUS terhadap metode kontrasepsi yang sesuai dapat menyebabkan ketidaktepatan dalam pemilihannya. Penelitian ini bertujuan membangun model klasifikasi kelayakan metode kontrasepsi menggunakan algoritma XGBoost serta memberikan rekomendasi berdasarkan data klinis PUS. Model dikembangkan melalui tahapan pengumpulan dan pelabelan data, prapemrosesan, serta proses *hyperparameter tuning* menggunakan *RandomizedSearchCV*, kemudian diimplementasikan ke dalam aplikasi berbasis web menggunakan Streamlit. Kinerja model dievaluasi menggunakan *confusion matrix* dengan metrik akurasi, presisi, *recall*, dan F1-score. Hasil penelitian menunjukkan bahwa model XGBoost memperoleh akurasi 97.73%, dengan nilai presisi 0.93, 0.95, 0.98, 1.00, *recall* 0.90, 0.90, 1.00, 1.00, dan F1-score 0.92, 0.93, 0.99, 1.00 untuk kelas Aman, Berisiko, Sangat Aman, dan Tidak Aman. Hasil tersebut menunjukkan bahwa model XGBoost mampu mengklasifikasikan kelayakan penggunaan metode kontrasepsi dengan performa yang baik serta dapat dimanfaatkan sebagai rekomendasi awal dalam mendukung proses konsultasi dengan tenaga kesehatan.



Copyright © 2026 The Author(s), Published by Jurnal Informatika dan Teknik Elektro Terapan. This is an open-access article distributed under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0).

Abstract. Selecting an appropriate contraceptive method requires consideration of the clinical conditions of couples of reproductive age (CRA). However, limited counseling time and insufficient knowledge of suitable contraceptive methods may lead to inappropriate contraceptive choices. This study aims to develop an eligibility classification model for contraceptive methods using the XGBoost algorithm and provide recommendations based on the clinical data of CRA. The model was developed through data collection, data labeling, preprocessing, and hyperparameter tuning using *RandomizedSearchCV*, and was subsequently implemented in a Streamlit-based web application. Model performance was evaluated using a *confusion matrix* with accuracy, precision, recall, and F1-score metrics. The XGBoost model achieved an accuracy of 97.73%, with precision values of 0.93, 0.95, 0.98, and 1.00, recall values of 0.90, 0.90, 1.00, and 1.00, and F1-scores of 0.92, 0.93, 0.99, and 1.00 for the Eligible, At Risk, Highly Eligible, and Not Eligible classes, respectively. These results indicate that the proposed XGBoost model effectively classifies contraceptive eligibility and can be used

to provide initial contraceptive recommendations to support consultations with healthcare professionals.

1. PENDAHULUAN

Program Keluarga Berencana (KB) merupakan salah satu upaya untuk mewujudkan keluarga sejahtera melalui pengaturan kelahiran menggunakan metode kontrasepsi. Pemilihan metode kontrasepsi perlu mempertimbangkan kondisi klinis pasangan usia subur (PUS) agar metode yang digunakan sesuai dengan kondisi kesehatan pengguna [1]. Namun, dalam praktiknya masih terdapat berbagai hambatan, seperti keterbatasan waktu konseling oleh tenaga kesehatan dan kurangnya pemahaman PUS mengenai metode kontrasepsi yang sesuai dengan kondisi klinisnya.

Permasalahan tersebut juga ditemukan di Kecamatan Tirawuta, Kabupaten Kolaka Timur, yang menjadi lokasi penelitian ini. Berdasarkan hasil observasi, padatnya jadwal pelayanan keluarga berencana menyebabkan waktu konseling yang tersedia bagi setiap calon akseptor menjadi terbatas. Akibatnya, calon pengguna kontrasepsi belum memperoleh informasi yang memadai mengenai metode kontrasepsi yang sesuai dengan kondisi klinisnya. Selain itu, kekhawatiran terhadap efek samping kontrasepsi juga menyebabkan sebagian pasangan usia subur menunda penggunaan kontrasepsi. Oleh sebab itu, dibutuhkan suatu sistem yang dapat memberikan rekomendasi awal pemilihan metode kontrasepsi berdasarkan kondisi klinis sebagai pendukung proses konsultasi dengan tenaga kesehatan.

Perkembangan *machine learning* telah banyak dimanfaatkan untuk menyelesaikan permasalahan klasifikasi dan sistem rekomendasi. Salah satu algoritma yang memiliki performa baik pada data tabular adalah *Extreme Gradient Boosting* (XGBoost) karena mampu menghasilkan akurasi yang tinggi, menangani hubungan data yang kompleks, serta memiliki mekanisme regularisasi untuk mengurangi *overfitting*[2]. Penelitian oleh Rahman dkk. menunjukkan bahwa XGBoost memperoleh akurasi sebesar 98% pada sistem rekomendasi pemilihan jenis tanaman [3]. Penelitian lain oleh Harahap dkk. juga menunjukkan bahwa XGBoost memiliki

performa yang lebih baik dalam menangani data kompleks dan *overfitting* dibandingkan Random Forest dalam klasifikasi penyakit paru-paru [4]. Sementara itu, penelitian Hadi dkk. mengenai rekomendasi pemilihan metode kontrasepsi menggunakan algoritma K-Nearest Neighbors (KNN) memperoleh akurasi sebesar 76,47%. Meskipun demikian, penelitian tersebut belum mempertimbangkan kondisi klinis pengguna, khususnya riwayat penyakit, dalam proses pemberian rekomendasi.

Berdasarkan penelitian terdahulu, sebagian besar penelitian hanya berfokus pada pemberian rekomendasi atau klasifikasi tanpa mengintegrasikan keduanya dalam satu sistem. Selain itu, penelitian mengenai pemilihan metode kontrasepsi umumnya belum memanfaatkan kondisi klinis pengguna sebagai dasar klasifikasi kelayakan sebelum menghasilkan rekomendasi metode kontrasepsi. Oleh karena itu, penelitian ini mengusulkan penerapan algoritma XGBoost untuk mengklasifikasikan kelayakan metode kontrasepsi berdasarkan data klinis pasangan usia subur, kemudian memberikan rekomendasi metode kontrasepsi yang sesuai dengan hasil klasifikasi tersebut. Model dikembangkan melalui tahap prapemrosesan data dan proses *hyperparameter tuning* menggunakan *RandomizedSearchCV*, kemudian diintegrasikan dalam aplikasi berbasis *web* menggunakan Streamlit. Kinerja model dievaluasi menggunakan *confusion matrix* melalui metrik *accuracy*, *precision*, *recall*, dan *f1-score*. Penelitian ini diharapkan dapat memberikan rekomendasi awal yang mendukung proses konsultasi dengan tenaga kesehatan.

2. TINJAUAN PUSTAKA

2.1. Metode Kontrasepsi

Kontrasepsi berasal dari kata “kontra” dan “konsepsi” yang mana kontra artinya mencegah dan konsepsi artinya pembuahan atau fertilisasi. Kontrasepsi dapat didefinisikan sebagai suatu hal yang digunakan untuk mencegah terjadinya pembuahan. Metode kontrasepsi merupakan metode yang diterapkan

guna mencegah terjadinya kehamilan. Metode ini dapat bersifat sementara maupun permanen [5].

Umumnya metode kontrasepsi dibedakan menjadi metode kontrasepsi tradisional dan modern. Metode kontrasepsi tradisional terdiri dari metode alamiah yang mencakup metode kalender, pantang berkala, metode suhu basal, metode lender serviks, metode symptothermal, dan senggama terputus. Metode non-alamiah mencakup kondom, barrier intravaginal, dan spermasida. Metode kontrasepsi modern dibedakan menjadi kontrasepsi hormonal dan non-hormonal. Kontrasepsi hormonal meliputi pil, suntik, alat kontrasepsi bawah kulit (AKBK), serta alat kontrasepsi dalam rahim (AKDR). Kontrasepsi non-hormonal meliputi tindakan operasi vasektomi dan tubektomi [6].

2.2. Klinis Pasangan Usia Subur

Pasangan usia subur merupakan pasangan yang usia wanitanya mampu untuk hamil dan melahirkan, umumnya antara 15 hingga 49 tahun. Kondisi klinis pasangan usia subur umumnya merujuk pada kondisi kesehatan serta riwayat medis dari pasangan di usia reproduktif. Hal ini mencakup beberapa aspek seperti usia, jumlah anak, serta riwayat penyakit yang sedang atau pernah dialami. Selain itu, kondisi klinis dapat mengacu pada kondisi Kesehatan umum dan potensi efek samping terhadap metode kontrasepsi [7].

2.3. Machine Learning

Machine learning merupakan cabang ilmu komputer yang berkembang dalam kecerdasan buatan yang bertujuan pada pengelolaan data serta pengembangan algoritma dengan meniru cara manusia belajar. Hal ini akan memungkinkan komputer untuk bekerja dan berperilaku seperti manusia [8]. *Machine learning* membantu komputer untuk dapat belajar tanpa harus diprogram secara eksplisit oleh manusia. *Machine learning* termasuk bidang keilmuan yang menganalisis cara program dalam menciptakan pengetahuan baru dari data yang ada [9]. *Machine learning* melatih komputer untuk mengenali pola dan menghasilkan analisis dari data yang telah dipelajari.

2.4. Klasifikasi

Klasifikasi berarti pengelompokan data yang mana data yang dikelompokkan memiliki label atau target [10]. Kelas dan variabel dependen merupakan hal yang mendasari proses klasifikasi. Klasifikasi merupakan salah satu pembelajaran yang disupervisi yang mana memerlukan data latih berlabel untuk mengklasifikasikan data uji ke dalam kelas tertentu [11].


2.5. XGBoost

XGBoost adalah algoritma *ensemble learning* yang memanfaatkan Teknik *boosting*, yang mana *ensemble learning* didefinisikan sebagai paradigma *machine learning* yang memuat beberapa model pelatihan untuk memecahkan masalah yang kemudian digabungkan agar hasil menjadi lebih baik [12]. XGBoost merupakan algoritma yang dapat menemukan solusi optimal untuk berbagai masalah, khususnya klasifikasi dan regresi. XGBoost merupakan implementasi dari metode *gradient boosting* yang mengadopsi formula model yang lebih terstruktur untuk mengatasi *overfitting* [13].

Kinerja model XGBoost tidak hanya ditetapkan oleh kualitas data, tetapi juga oleh kombinasi *hyperparameter* yang digunakan selama proses pelatihan [14]. Pemilihan nilai *hyperparameter* yang sesuai mampu menaikkan performa model dalam mempelajari pola pada data, menghasilkan prediksi yang lebih akurat, serta menurunkan risiko terjadinya *overfitting*. Beberapa *hyperparameter* utama yang umum digunakan meliputi *n_estimators*, *max_depth*, *learning_rate*, *subsample*, dan *colsample_bytree* [15].

Hyperparameter *n_estimators* menentukan jumlah pohon yang dibangun selama proses *boosting*, sedangkan *max_depth* mengatur kedalaman maksimum setiap pohon keputusan. *Hyperparameter* *learning_rate* mengontrol laju pembelajaran model dalam memperbarui bobot pada setiap iterasi sehingga membantu mengurangi risiko *overfitting*. Sementara itu, *subsample* menentukan proporsi data latih yang digunakan untuk membangun setiap pohon dan *colsample_bytree* menentukan proporsi fitur yang digunakan pada masing-masing pohon [16].

3. METODE PENELITIAN



Gambar 1. Alur metode penelitian

3.1. *Collecting Data*

Tahap pertama adalah pengumpulan data pasangan usia subur yang diperoleh dari Kecamatan Tirawuta. Dataset awal terdiri atas 101 data dengan atribut yang meliputi usia ibu, jumlah anak, usia anak terakhir, status menyusui, riwayat hipertensi, diabetes, sakit kuning, pendarahan vagina, keputihan lama, tumor payudara, tumor rahim, tumor indung telur, kanker serviks, radang panggul, dan metode kontrasepsi yang digunakan. Untuk memperoleh variasi kondisi klinis yang lebih representatif, ditambahkan 92 data hasil pengembangan berdasarkan pedoman *medical eligibility criteria for contraceptive use* dari *World Health Organization* (WHO) melalui konsultasi dengan Penelaah Teknis Kebijakan BKKBN, sehingga diperoleh 193 variasi kondisi klinis.

0	nama	1544	non-null	object
1	usia_ibu	1544	non-null	int64
2	jumlah_anak	1544	non-null	int64
3	usia_anakterakhir	1544	non-null	object
4	menyusui	1544	non-null	object
5	hipertensi	1544	non-null	object
6	diabetes	1544	non-null	object
7	sakit_kuning	1544	non-null	object
8	pendarahan_vagina	1544	non-null	object
9	keputihan_lama	1544	non-null	object
10	tumor_payudara	1544	non-null	object
11	tumor_rahim	1544	non-null	object
12	tumor_indungtelur	1544	non-null	object
13	kanker_serviks	1544	non-null	object
14	radang_panggul	1544	non-null	object
15	jenis_kb	1544	non-null	object
16	kategori	1544	non-null	object

dtypes: int64(2), object(15)

Gambar 2. Atribut data

Setiap variasi kondisi klinis tersebut kemudian dipasangkan dengan delapan metode kontrasepsi meliputi suntik 3 bulan progestin, suntik 3 bulan kombinasi, pil progestin, pil kombinasi, implan 1 batang, implan 2 batang, kondom dan IUD yang menjadi objek penelitian sehingga menghasilkan total 1.544 data yang digunakan dalam proses pelatihan model.

3.2. *Labelling Data*

Setelah proses pengumpulan data, setiap data diberi label kategori kelayakan penggunaan metode kontrasepsi. Proses pelabelan dilakukan bersama Penelaah Teknis dan Kebijakan BKKBN berdasarkan kondisi klinis pasangan usia subur serta mengacu pada pedoman WHO. Hasil pelabelan menghasilkan empat kategori, yaitu Sangat Aman, Aman, Berisiko, dan Tidak Aman.

3.3. *Preprocessing Data*

Tahap *preprocessing* dilakukan untuk mempersiapkan data sebelum proses pelatihan model. Proses ini mencakup menghapus kolom yang tidak digunakan, transformasi data kategorikal menjadi numerik menggunakan *One Hot Encoding* dan *Label Encoding*, pembagian atribut berdasarkan tipe data, normalisasi atribut numerik dengan *StandardScaler*, serta membagi data menjadi 80% data latih dan 20% data uji. Selanjutnya, ketidakseimbangan distribusi kelas pada data latih ditangani menggunakan metode *Borderline-Synthetic Minority Over-sampling Technique* (*Borderline-SMOTE*) untuk

menaikkan representasi kelas minoritas sebelum pelatihan model.

3.4. Modelling

Tahap pemodelan, model klasifikasi dibangun menggunakan algoritma XGBoost. Untuk memperoleh kombinasi parameter yang optimal, dilakukan *hyperparameter tuning* menggunakan *RandomizedSearchCV*. Model terbaik selanjutnya digunakan untuk mengklasifikasikan kelayakan penggunaan metode kontrasepsi dan menghasilkan rekomendasi metode kontrasepsi yang sesuai berdasarkan kondisi klinis pengguna.

3.5. Model Evaluation

Tahap evaluasi kinerja model menggunakan *confusion matrix* dengan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Metrik tersebut berguna untuk mengukur performa model dalam mengklasifikasikan setiap kategori kelayakan metode kontrasepsi secara tepat.

4. HASIL DAN PEMBAHASAN

4.1. Hyperparameter Tuning XGBoost

Hyperparameter tuning dilakukan dengan metode *RandomizedSearchCV* untuk memperoleh kombinasi parameter yang menghasilkan performa terbaik pada model XGBoost. Metode ini bekerja dengan memilih sejumlah kombinasi *hyperparameter* secara acak dari *search space* yang telah ditentukan, sehingga proses pencarian kombinasi *hyperparameter* menjadi lebih efisien. *Hyperparameter* yang digunakan dalam proses pencarian meliputi *n_estimators*, *max_depth*, *learning_rate*, *subsample*, dan *colsample_bytree*. Rentang nilai masing-masing parameter ditunjukkan pada Tabel 1.

Tabel 1. Rentang nilai *hyperparameter tuning*

<i>Hyperparameter</i>	Nilai yang diuji
<i>n_estimators</i>	[200, 300, 400, 500]
<i>max_depth</i>	[5, 7, 9]
<i>learning_rate</i>	[0.01, 0.05, 0.1, 0.2]
<i>subsample</i>	[0.6, 0.8, 1.0]
<i>colsample_bytree</i>	[0.6, 0.8, 1.0]

Hasil *hyperparameter tuning* menunjukkan bahwa kombinasi


hyperparameter terbaik diperoleh seperti pada Tabel 2.

Tabel 2. Nilai *hyperparameter* terbaik

<i>Hyperparameter</i>	Nilai terbaik
<i>n_estimators</i>	200
<i>max_depth</i>	9
<i>learning_rate</i>	0.2
<i>subsample</i>	0.8
<i>colsample_bytree</i>	1.0

Kombinasi *hyperparameter* tersebut selanjutnya digunakan pada proses pelatihan model XGBoost. Nilai *n_estimators* sebanyak 200 menunjukkan jumlah pohon keputusan yang dibangun selama proses *boosting*. Nilai *max_depth* sebesar 9 memungkinkan model mempelajari pola data yang lebih kompleks. *Learning_rate* sebesar 0,2 mengatur besarnya kontribusi setiap pohon terhadap model secara keseluruhan, sedangkan *subsample* sebesar 0,8 menunjukkan bahwa 80% data latih digunakan pada setiap iterasi untuk mengurangi risiko *overfitting*. Selain itu, *colsample_bytree* sebesar 1,0 menunjukkan bahwa seluruh atribut digunakan dalam pembentukan setiap pohon keputusan.

4.2. Hasil Evaluasi Model



Gambar 3. *Confusion matrix*

Gambar 3. menunjukkan *confusion matrix* hasil pengujian model XGBoost. Sebagian besar data pada setiap kelas berhasil diklasifikasikan dengan benar sehingga jumlah prediksi yang sesuai dengan kelas sebenarnya

lebih dominan dibandingkan kesalahan klasifikasi. Hal ini menunjukkan bahwa model mampu mengenali pola data dengan baik pada keempat kategori kelayakan metode kontrasepsi.

Tabel 3. *Classification report*

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
Aman	0.93	0.90	0.92
Berisiko	0.95	0.90	0.93
Sangat Aman	0.98	1.00	0.99
Tidak Aman	1.00	1.00	1.00
Accuracy	97.73%		

Model memperoleh akurasi sebesar 97.73%, dengan nilai presisi masing-masing sebesar 0.93 pada kelas Aman, 0.95 pada kelas Berisiko, 0.98 pada kelas Sangat Aman, dan 1.00 pada kelas Tidak Aman. Nilai *recall* yang diperoleh masing-masing berturut-turut adalah 0.90, 0.90, 1.00, dan 1.00, sedangkan nilai *F1-score* masing-masing kelas sebesar 0.92, 0.93, 0.99, dan 1.00. Hasil tersebut menunjukkan bahwa model mampu memberikan performa klasifikasi yang baik pada seluruh kategori kelayakan metode kontrasepsi

4.3. Implementasi Sistem

Model XGBoost yang telah dilatih selanjutnya diimplementasikan ke dalam aplikasi berbasis *web* menggunakan Streamlit. Aplikasi ini memungkinkan pengguna memasukkan data klinis pasangan usia subur untuk memperoleh hasil klasifikasi tingkat kelayakan serta rekomendasi metode kontrasepsi sebagai pendukung konsultasi dengan tenaga kesehatan.

Gambar 4. Halaman cek kontrasepsi

Halaman cek kontrasepsi digunakan untuk memasukkan data klinis pasangan usia subur

sebagai masukan bagi model XGBoost. Data yang menjadi masukan meliputi usia ibu, jumlah anak, usia anak terakhir, status menyusui, riwayat penyakit yang terdiri atas hipertensi, diabetes, sakit kuning, pendarahan vagina, keputihan lama, tumor payudara, tumor rahim, tumor indung telur, kanker serviks, dan radang panggul. Setelah seluruh data diisi, pengguna dapat menjalankan proses klasifikasi dan rekomendasi dengan menekan tombol cek metode kontrasepsi.

Gambar 5. Halaman hasil klasifikasi dan rekomendasi

Setelah proses klasifikasi selesai, sistem menampilkan kategori kelayakan penggunaan metode kontrasepsi berdasarkan hasil prediksi model XGBoost, yaitu Sangat Aman, Aman, Berisiko, atau Tidak Aman. Selain itu, sistem juga menampilkan rekomendasi metode kontrasepsi yang sesuai berdasarkan kondisi klinis pengguna. Hasil yang ditampilkan dapat dimanfaatkan sebagai rekomendasi awal dalam mendukung proses konsultasi dengan tenaga kesehatan.

5. KESIMPULAN

Berdasarkan hasil penelitian, implementasi sistem, dan pengujian yang telah dilakukan, maka dapat diambil beberapa kesimpulan sebagai berikut.

1. Model XGBoost yang dibangun mampu mengklasifikasikan kelayakan penggunaan metode kontrasepsi berdasarkan data klinis pasangan usia subur serta memberikan rekomendasi awal metode kontrasepsi melalui aplikasi berbasis *web* Streamlit.
2. Hasil evaluasi menunjukkan bahwa model XGBoost memperoleh nilai *accuracy* sebesar 97.73%, yang menunjukkan bahwa model memiliki performa yang baik dalam

mengklasifikasikan kelayakan penggunaan metode kontrasepsi berdasarkan kondisi klinis pasangan usia subur.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Penelaah Teknis dan Kebijakan BKKBN, Penyuluh KB Kecamatan Tirawuta, serta seluruh pihak yang telah memberikan dukungan, masukan, dan bantuan dalam proses pengumpulan data, pelabelan data, dan penyelesaian penelitian ini.

DAFTAR PUSTAKA

- [1] K. Kelurahan Sagatani, K. Barat, Z. Hasan Gaffar, and A. Sasap Abao, "Partisipasi Pasangan Usia Subur (PUS) dalam program Keluarga Berencana di Kampung Participation of Couples of Childbearing Age (PUS) in the Family Planning Program in KB Village, Sagatani Village, Singkawang, West Kalimantan," *online) Socia: Jurnal Ilmu-ilmu Sosial*, vol. 18, no. 2, 2021.
- [2] M. Alkaff, A. R. Baskara, and Ainiyyah, "Penerapan Metode XGBoost Untuk Memprediksi Jumlah Kejadian Kecelakaan Lalu Lintas di Kota Banjarmasin," *Generation Journal*, vol. 7, no. 1, pp. 61–69, Mar. 2023.
- [3] A. Rahman, D. Udjulawa, and Mulyati, "Rekomendasi Pemilihan Jenis Tanaman Menggunakan Algoritma Random Forest dan XGBoost Regressor," *Computer Science (CO-SCIENCE)*, vol. 4, no. 2, pp. 119–126, Jul. 2024.
- [4] R. Harahap, M. Irpan, M. Azzuhri Dinata, L. Efrizoni, and Rahmadden, "Perbandingan Algoritma Random Forest dan XGBoost untuk Klasifikasi Penyakit Paru-paru Berdasarkan Data Demografi Pasien," *Jurnal Ilmiah Betrik*, vol. 15, no. 02, pp. 130–141, Aug. 2024.
- [5] Ikhtiyaruddin, N. P. Sari, A. Alamsyah, and E. Kursani, *Metode Kontrasepsi Jangka Panjang (MKJP)*, 1st ed. Jawa Timur: CV. Global Aksara Pers, 2021.
- [6] F. A. Nurullah, "Perkembangan Metode Kontrasepsi di Indonesia," *Cermin Dunia Kedokteran*, vol. 48, no. 3, pp. 166–172, Mar. 2021.
- [7] R. C. Muawanah, M. Ita, and V. Caroline, "Pemanfaatan Data Rekam Medis untuk Analisis Karakteristik Pasangan Usia Subur (PUS) dalam Pemilihan Kontrasepsi Tubektomi di RS Bhayangkara Anton Soedjarwo Pontianak," *Jurnal Administrasi dan Sistem Informasi Kesehatan*, vol. 1, no. 1, pp. 1–6, Aug. 2024.
- [8] M. A. M. Setiawan, Kusri, and A. D. Hartono, "Menggunakan Metode Machine Learning Untuk Memprediksi Nilai Mahasiswa Dengan Model Prediksi Multiclass," *Jurnal Informatika: Jurnal pengembangan IT*, vol. 10, no. 1, pp. 190–204, Jan. 2025.
- [9] M. S. Melaku, L. Yohannes, B. Sharew, M. H. Derseh, and E. A. Taye, "Application of machine learning algorithms to model predictors of informed contraceptive choice among reproductive age women in six high fertility rate sub Sahara Africa countries," *BMC Public Health*, vol. 25, no. 1, Dec. 2025.
- [10] N. B. Putri and A. W. Wijayanto, "Analisis Komparasi Algoritma Klasifikasi Data Mining Dalam Klasifikasi Website Phishing," *Komputika : Jurnal Sistem Komputer*, vol. 11, no. 1, pp. 59–66, Apr. 2022.
- [11] M. Napiah and S. Heristian, "Perbandingan Algoritma Machine Learning pada Klasifikasi Penyakit Jantung," *Jurnal Infortech*, vol. 6, no. 1, pp. 46–51, Jun. 2024.
- [12] W. A. Wahyuni, M. N. Karim, and Z. Muahidin, "Penerapan Algoritma XGBoost dalam Penentuan Potensi Sektor Wisata Lokal di Lombok Timur," *SAINTEKES: Jurnal Sains, Teknologi dan Kesehatan*, vol. 4, no. 3, pp. 155–160, Jul. 2025.
- [13] N. M. Suryanooradja, A. D. Rahajoe, and Acghmad Junaidi, "Hybrid MobileNetV2 dan Extreme Gradient Boosting Untuk Klasifikasi Kerusakan Bangunan," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 13, no. 3, pp. 402–412, Jul. 2025.
- [14] A. A. Syahputra and R. E. Saputro, "Application of the XGBoost Model with Hyperparameter Tuning for Industry Classification for Job Applicants," *sinkron*, vol. 8, no. 3, pp. 1920–1931, Jul. 2024.
- [15] E. A. Firdaus, J. Manurung, H. Saragih, and M. A. Prabukusumo, "Optimization of XGBoost hyperparameters using grid search and random search for credit card default prediction," *Jurnal Mandiri IT*, vol. 14, no. 2, pp. 269–280, Oct. 2025.
- [16] A. Mehdary, A. Chehri, A. Jakimi, and R. Saadane, "Hyperparameter Optimization with Genetic Algorithms and XGBoost: A Step Forward in Smart Grid Fraud Detection," *Sensors*, vol. 24, no. 4, pp. 1–24, Feb. 2024.