

Prediksi Permintaan Barang Berbasis Data Mining Menggunakan XGBoost (Studi Kasus : Puskesmas Pegajahan Serdang Bedagai)

Samuel Bagus Pandiangan¹, Margaretha Yohanna², Yolanda Rumapea³
^{1,2,3}Fakultas Ilmu Komputer, Universitas Methodist Indonesia

Info Artikel

Histori Artikel:

Received, Okt 30, 2025

Revised, Nov 10, 2025

Accepted, Nov 17, 2025

Keywords:

XGBoost,
Prediksi Permintaan Barang,
Data Mining,
Puskesmas.

ABSTRAK

Perkembangan teknologi komputerisasi mendorong transformasi digital di berbagai sektor, termasuk bidang kesehatan. Pusat Kesehatan Masyarakat (Puskesmas) sebagai fasilitas layanan kesehatan tingkat pertama memerlukan sistem prediksi yang akurat untuk mendukung perencanaan kebutuhan barang medis. Penelitian ini menerapkan algoritma *Extreme Gradient Boosting* (XGBoost) untuk memprediksi permintaan barang berdasarkan data historis persediaan, pemakaian, dan sisa stok di Puskesmas Pegajahan Serdang Bedagai. Evaluasi kinerja model dilakukan menggunakan *Mean Squared Error* (MSE). Hasil pengujian menunjukkan bahwa model XGBoost mampu memberikan performa yang baik pada beberapa jenis produk dengan tingkat *error* yang relatif kecil, khususnya Antasida DOEN I tablet kunyah, Antasida DOEN II suspensi, Amoksisilin sirup kering 125 mg/5 mg, Alkohol Swabs, serta alat suntik sekali pakai, yang memiliki selisih prediksi mendekati nilai permintaan aktual. Secara keseluruhan, model menghasilkan nilai MSE sebesar 558.882,1, yang menunjukkan bahwa kesalahan prediksi masih dalam batas yang dapat diterima. Dengan demikian, algoritma XGBoost dapat digunakan sebagai alat bantu pengambilan keputusan pengadaan barang medis guna meminimalkan risiko kelebihan maupun kekurangan stok serta meningkatkan efisiensi pengelolaan logistik di Puskesmas.

This is an open access article under the [CC BY-SA](#) license.



Penulis Koresponden:

Samuel Bagus Pandiangan
Fakultas Ilmu Komputer,
Universitas Methodist Indonesia, Medan,
Jl. Hang Tuah No.8, Medan - Sumatera Utara.
Email: samuelpandiangan21@gmail.com

1. PENDAHULUAN

Perkembangan teknologi komputerisasi telah memberikan kemudahan dalam pengelolaan data di berbagai sektor, termasuk sektor kesehatan. Sistem manual yang dulunya menjadi andalan, kini mulai ditinggalkan dan digantikan oleh sistem berbasis digital yang lebih cepat, akurat, dan efisien. Komputerisasi memungkinkan instansi untuk tidak hanya menyimpan data, tetapi juga mengolah dan menganalisis data tersebut untuk mendukung pengambilan keputusan yang lebih baik.

Salah satu institusi yang sangat membutuhkan dukungan sistem komputerisasi adalah Pusat Kesehatan Masyarakat (Puskesmas). Puskesmas merupakan fasilitas layanan kesehatan tingkat pertama yang memberikan pelayanan langsung kepada masyarakat di wilayah kecamatan. Peran puskesmas sangat penting, terutama dalam upaya promotif dan preventif, serta dalam menangani pelayanan dasar kesehatan.

Data mining adalah proses penggalian informasi atau pola tertentu dari kumpulan data yang besar dengan bantuan teknik statistik, matematika, dan pembelajaran mesin (*machine learning*). Melalui teknik ini, data historis yang ada dapat dianalisis untuk menemukan pola tersembunyi yang

berguna dalam proses prediksi atau klasifikasi. Dalam konteks puskesmas, *data mining* dapat digunakan untuk memprediksi kebutuhan permintaan barang dengan mempertimbangkan berbagai variabel seperti persediaan, pemakaian, sisa stok dan permintaan dalam periode tertentu sehingga dapat mengestimasi kebutuhan di masa mendatang secara lebih akurat.

Adapun permasalahan yang terjadi karena perencanaan kebutuhan permintaan barang yang masih dilakukan secara manual dan kurang akurat, sehingga sering terjadi kelebihan atau kekurangan stok. Padahal, data historis mengenai penggunaan barang sebenarnya sudah tersedia namun belum dimanfaatkan secara optimal untuk membuat perkiraan kebutuhan di waktu yang akan datang. Selain itu, permintaan barang yang cenderung fluktuatif, terutama dipengaruhi oleh musim atau kondisi tertentu, membuat proses pengadaan menjadi semakin sulit diprediksi tanpa adanya sistem peramalan yang handal.

Untuk mengatasi permasalahan ini, diperlukan pendekatan yang mampu menganalisis data secara lebih efektif dan menghasilkan prediksi yang lebih akurat untuk kebutuhan masa depan. Salah satu metode yang efektif adalah *XGBoost*, sebuah varian *gradient tree boosting* yang mampu meningkatkan akurasi prediksi dengan mengurangi *overfitting* memiliki *library* yang lengkap sehingga memungkinkan *programmer* untuk membuat program yang mutakhir dengan menggunakan *source code* yang tampak sederhana [1].

XGBoost merupakan algoritma *machine learning* berbasis pohon keputusan yang dikenal dengan kecepatan dan akurasinya dalam melakukan prediksi. Algoritma ini bekerja dengan membangun model *ensemble* dari beberapa pohon keputusan, di mana setiap pohon baru dibuat untuk memperbaiki kesalahan dari pohon sebelumnya [2][3][4]. Dengan mengolah data historis penggunaan barang, algoritma *XGBoost* dapat mempelajari pola konsumsi barang dan memberikan estimasi yang lebih akurat terhadap kebutuhan permintaan barang untuk periode-periode mendatang.

Melalui penerapan *XGBoost*, proses prediksi kebutuhan permintaan barang di Puskesmas Pegajahan Serdang Bedagai dapat dilakukan dengan lebih efisien dalam merencanakan kebutuhan masa depan. Model ini membantu dalam pengambilan keputusan terkait jumlah barang yang perlu disediakan untuk memenuhi kebutuhan yang diprediksi di waktu mendatang, sehingga dapat mengurangi risiko kekurangan maupun kelebihan stok. Dengan demikian, manajemen permintaan barang menjadi lebih optimal, yang pada akhirnya dapat meningkatkan kualitas pelayanan kesehatan bagi masyarakat.

2. METODE PENELITIAN

2.1 Algoritma XGBoost

XGBoost adalah singkatan dari *Extreme Gradient Boosting* [5][6][7], yaitu salah satu algoritma *ensemble machine learning* berbasis pohon keputusan (*decision tree*) yang mengimplementasikan teknik *gradient boosting*[8][9]. Algoritma ini dikembangkan untuk memberikan performa yang tinggi, efisien, dan scalable terhadap berbagai permasalahan *supervised learning* seperti klasifikasi, regresi, hingga ranking [10][11][12].

2.1.1 Langkah-Langkah XGBoost

Adapun langkah-langkah penerapan pada algoritma *XGBoost* adalah sebagai berikut [12]:

1. Model XGBoost

XGBoost (*Extreme Gradient Boosting*) merupakan algoritma *ensemble* berbasis *gradient boosting* yang menggabungkan beberapa model lemah (seperti *decision tree*) secara aditif untuk membentuk model prediktif yang kuat. Secara matematis, model prediksi *XGBoost* dirumuskan sebagai:

$$y^{\wedge}(i) = Y + \sum_{k=1}^K nf_k(x_i) \quad (1)$$

Keterangan:

$y^{\wedge}(i)=Y^-$ adalah prediksi awal

$fk(x_i)$ adalah *output* leaf dari pohon ke-k

2. Fungsi Objektif

Fungsi objektif dalam *XGBoost* terdiri dari dua komponen utama yaitu fungsi *loss*, mengukur selisih antara nilai aktual dan prediksi dan fungsi regularisasi, mengontrol kompleksitas model untuk mencegah *overfitting*

$$L = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

Keterangan:

L : nilai loss (kesalahan total yang dihitung model)

n : jumlah data

y_i : nilai aktual pada data ke-i

$\hat{y}_i$: nilai prediksi pada data ke-i

3. Optimasi Fungsi Dengan *Taylor Expansion*

Karena fungsi *loss* bisa bersifat *non-linear* dan kompleks, *XGBoost* menggunakan pendekatan *Taylor expansion* orde kedua untuk menyederhanakan perhitungan fungsi objektif. Ini memungkinkan proses optimasi dilakukan secara efisien.

$$g_i = \hat{y}_i - y_i \quad (3)$$

$$h_i = 1$$

Keterangan:

g_i Turunan pertama (*gradient*)

h_i Turunan kedua (*hessian*)

4. Bobot Optimal *Leaf Node*

Setelah struktur pohon ditentukan, langkah selanjutnya adalah menentukan nilai *output* (bobot) dari masing-masing *leaf* yang meminimalkan *loss*.

$$w_j^* = -\frac{G_j}{H_j + \lambda} \quad (4)$$

Keterangan:

w_j Bobot optimal

g_j nilai *gradient*

h_j nilai *hessian*

5. Perbarui Model

Model diperbarui dengan menambahkan *output* dari pohon baru ke dalam prediksi sebelumnya.

$$y_i^{(1)} = y_i^{(0)} + \eta \times W_{node} \quad (5)$$

Keterangan:

$y_i^{(1)}$ = prediksi baru

$y_i^{(0)}$ = prediksi awal

η = *learning rate*

W_{node} = bobot optimal di *leaf node*

2.1.2 Mean Squared Error (MSE)

Mean Squared Error (MSE) merupakan salah satu metode yang digunakan untuk mengukur tingkat kesalahan hasil peramalan dengan menghitung rata-rata kuadrat selisih antara nilai aktual dan nilai prediksi. Metode MSE banyak digunakan dalam evaluasi model peramalan dan analisis prediksi karena mampu menggambarkan tingkat kesalahan secara kuantitatif (Mustafidah & Rohman, 2023). Rumus MSE dapat dituliskan sebagai berikut:

$$MSE = \frac{1}{n} \sum_{i=1}^n (A_i - F_i)^2 \quad (6)$$

Keterangan :

MSE = *Mean Squared Error*


n = Jumlah data hasil peramalan

A_i = Nilai aktual ke-i

F_i = Nilai peramalan ke- i .

2.2 Framework Penelitian

Dalam penelitian ini kerangka kerja digunakan dalam menjelaskan seluruh langkah-langkah aktifitas yang dikerjakan saat penelitian sehingga sesuai dengan tujuan yang telah ditentukan. Kerangka kerja dapat dilihat pada Gambar 1.



Gambar 1. *Framework* Penelitian

2.3 Pengumpulan Data

Pengumpulan data bertujuan untuk memperoleh informasi akurat mengenai riwayat penggunaan dan pengadaan barang di Puskesmas Pegajahan, Kabupaten Serdang Bedagai, selama periode Januari 2019 – Januari 2025. Data yang dikumpulkan meliputi nama barang, stok awal, penerimaan, persediaan, pemakaian, sisa stok, dan permintaan barang. Data tersebut digunakan sebagai dasar analisis dan pelatihan model prediksi menggunakan algoritma XGBoost.

Teknik pengumpulan data yang digunakan meliputi: wawancara, observasi, dokumentasi, dan studi pustaka. Wawancara dilakukan dengan petugas farmasi dan pengelola gudang untuk memahami proses perencanaan dan kendala pengelolaan stok. Observasi dilakukan untuk mengamati secara langsung proses pendistribusian, pencatatan, dan pelaporan stok barang. Dokumentasi dilakukan dengan mengumpulkan data historis dari arsip internal Puskesmas dalam bentuk basis data MySQL. Studi pustaka digunakan untuk mendukung landasan teori dan metodologi penelitian, khususnya terkait prediksi permintaan dan algoritma XGBoost. Adapun data yang digunakan dapat diamati pada tabel 1.


Tabel 1. Data Kebutuhan Barang Puskesmas Pegajahan Tahun Januari 2019 s/d Januari 2025

No	Bulan	Nama Barang	Persediaan	Pemakaian	Sisa Stok	Pemintaan
1	Jan-2019	Alat Suntik Sekali Pakai 1 ml	333	100	233	100
2	Jan-2019	Alat Suntik Sekali Pakai 3 ml	662	390	272	200
3	Jan-2019	Alkohol Swabs	270	70	200	0
4	Jan-2019	Antasida DOEN I tablet kunyah,kombinasi: Aluminium hidroksida + Magnesium hidroksida	0	0	0	4,000
5	Jan-2019	Antasida DOEN II suspensi,kombinasi: Magnesium hidroksida, Aluminium hidroksida	109	81	28	100
6	Jan-2019	Amoksilin kaplet 500 mg	4,493	2,843	1,650	4,000
7	Jan-2019	Amoksilin sirup kering 125 mg/5 mg	28	9	19	50

No	Bulan	Nama Barang	Persediaan	Pemakaian	Sisa Stok	Pemintaan
8	Jan-2019	Asam askorbat (Vitamin C) tablet 50 mg	4,239	2,000	2,239	2,000
9	Jan-2019	Asam folat tablet 0,4 mg	2,480	910	1,570	2,000
10	Jan-2019	Asam mefenamat kaplet 500 mg	0	0	0	3,000
...	...	...	...	...	...	...
730	Jan-2025	Asam mefenamat kaplet 500 mg	2,152	1,392	760	3,000

2.5 Tahapan Random Forest

Data yang digunakan dalam penelitian ini merupakan data historis pengadaan dan pemakaian barang selama periode tahun 2019 hingga 2025, yang terdiri dari atribut seperti persediaan, pemakaian, sisa stok, dan permintaan. *Flowchart* tahapan metode *XGBoost* yang digunakan dalam penelitian ini, sebagaimana ditunjukkan pada Gambar 2.



Gambar 2. *Flowchart* Algoritma *XGBoost*

1. Persiapan Data Historis

Data historis yang digunakan dalam penelitian ini telah disajikan pada Tabel 1.

Barang: Amoksilin kaplet 500 mg

Variabel input (fitur): Pemakaian (X),

Target: Permintaan (Y)

Tabel 2. Data Sampel Amoksilin kaplet 500 mg		
Bulan	Pemakaian (X)	Permintaan (Y)
Sep-24	1085	4000
Okt-24	1347	4000
Nov-24	1580	4000
Des-24	373	5000
Jan-25	1500	5000
Rata-Rata	1177	4400

Mencari rata-rata X = $(1085+1347+1580+373+1500) / 5 = 1177$

Mencari rata-rata Y = $(4000+4000+4000+5000+5000) / 5 = 4400$

2. Preprocessing Data

Pada tahap ini, data tidak memerlukan proses pembersihan karena seluruh data historis sudah dalam kondisi bersih dan lengkap, tanpa adanya nilai kosong maupun duplikat.

3. Bangun Model Awal *XGBoost*

XGBoost memulai dari prediksi awal (bias), biasanya rata-rata target:

$$y^{\wedge}(i) = Y + \sum_{k=1}^K nfk(xi)$$

$y^{\wedge}(i)=Y^-$ adalah prediksi awal

$fk(xi)$ adalah *output* leaf dari pohon ke-k

$$y^{\wedge}(0) = Y^- = \frac{4000 + 4000 + 4000 + 5000 + 5000}{5} = 4400$$

Prediksi awal = 4400

4. Hitung *Loss Function* (MSE)

Fungsi *loss* (*Mean Squared Error*):

$$L = (4000-4400)^2 + (4000-4400)^2 + (4000-4400)^2 + (5000-4400)^2 + (5000-4400)^2$$

$$L = 1200000 / 5 = 240000$$

5. Optimasi dengan *Taylor Expansion*

Tabel 3. Optimasi dengan *Taylor Expansion*

Bulan	yi	$y^{\wedge}i(0)$	$gi=y^{\wedge}i-yi$	hi
Sep-24	4000	4400	400	1
Okt-24	4000	4400	400	1
Nov-24	4000	4400	400	1
Des-24	5000	4400	-600	1
Jan-25	5000	4400	-600	1

6. Struktur dan *Split* Pohon

split berdasar Pemakaian (X):

Jika $X < 1177 \rightarrow$ kiri (Sep-Des)

Jika $X \geq 1177 \rightarrow$ kanan (Okt-Nov-Jan)

Hitung:

$$\sum gL = 400 - (-600), \sum hL = 2$$

$$\sum gR = 400 - 400 - (-600) = 0, \sum hR = 3$$

$$\sum gR = 600, \sum hT = 1$$

$$\text{Gain} = \frac{1}{2} \left[\frac{1000000}{3} + \frac{360000}{4} \right] = \frac{1}{2} (333333 + 90000) = 211667$$

split gain positif (211667) hasilnya bagus dan pohon disetujui.

7. Hitung Bobot Optimal di *Leaf Node*

Node kiri:

$$w_L = -\frac{1000}{2+1} = -333$$

Node kanan:

$$w_R = -\frac{600}{3+1} = -150$$

8. Perbarui Model

learning rate ($\eta=0.1$):

Tabel 4. Hasil Model Prediksi *XGBoost*

Bulan	Node	wj	Prediksi baru
Sep-24	Kiri	-333	$4400 + 0.1(-333) = 4367$
Okt-24	Kanan	-150	$4400 + 0.1(-150) = 4385$
Nov-24	Kanan	-150	$4400 + 0.1(-150) = 4385$
Des-24	Kiri	-333	$4400 + 0.1(-333) = 4367$
Jan-25	Kanan	-150	$4400 + 0.1(-150) = 4385$

9. Konvergen


Setiap iterasi melakukan perhitungan gradien, menghitung bobot optimal leaf berdasarkan nilai G (*gradient*) dan H (*hessian*), kemudian memperbarui prediksi menggunakan *learning rate* 0,1.

3. HASIL DAN PEMBAHASAN

3.1 Pengujian Sistem

1. Implementasi *Open Data*

adapun tampilan dalam hasil pengujiannya seperti pada Gambar 3.



Gambar 3. Hasil Implementasi *Script Open Data*

2. Implementasi Prediksi Kebutuhan

tampilan dalam hasil pengujiannya seperti pada Gambar 4.



Gambar 4. Informasi Data Bulan Terakhir Barang Diprediksi

Masukkan data kondisi terbaru:

Persediaan Bulan Ini: 1500 Pemakaian Bulan Ini: 1500 Sisa Stok Bulan Ini: 0

Prediksi kebutuhan Amoksilin kaplet 500 mg bulan berikutnya: 4401 unit


Rekomendasi: Siapkan stok sekitar 4401 unit untuk bulan depan

Gambar 5. Hasil Implementasi *Script* Prediksi Kebutuhan

Berdasarkan pada Gambar 5, diketahui bahwa prediksi kebutuhan barang Alat Amoksilin kaplet 500 mg pada bulan berikutnya adalah 4401 Unit. Untuk produk yang lain dilakukan dengan cara yang sama.

3.2 Hasil Pengujian

Pengujian sistem dilakukan untuk mengevaluasi performa model *XGBoost* dalam memprediksi kebutuhan permintaan barang di Puskesmas Pegajahan. Berdasarkan hasil pengujian yang dilakukan, model *XGBoost* berhasil diterapkan untuk seluruh barang. Adapun hasil prediksi kebutuhan untuk seluruh barang seperti pada Gambar 6.



Gambar 6. Hasil Prediksi Kebutuhan Seluruh Barang

Berdasarkan hasil pengujian, model *XGBoost* menghasilkan prediksi permintaan untuk sepuluh jenis barang dengan tingkat kesalahan yang bervariasi. Beberapa produk menunjukkan error relatif kecil, menandakan bahwa model mampu memprediksi permintaan dengan baik pada barang yang memiliki pola permintaan stabil. Sebaliknya, produk dengan pola permintaan fluktuatif menunjukkan error yang cukup besar, mengindikasikan keterbatasan model dalam menangkap perubahan permintaan yang tajam.

Secara keseluruhan, evaluasi menggunakan *Mean Squared Error* (MSE) menghasilkan nilai sebesar 558.882,1. Nilai ini menunjukkan bahwa meskipun model *XGBoost* cukup efektif dalam memprediksi sebagian barang, masih diperlukan pengembangan lebih lanjut, seperti penambahan data historis, penanganan outlier, dan optimasi parameter, untuk meningkatkan akurasi prediksi terutama pada barang dengan variasi permintaan yang tinggi.

4. KESIMPULAN

Hasil pengujian sistem prediksi permintaan obat menggunakan algoritma XGBoost menghasilkan prediksi untuk sepuluh jenis obat, yaitu Amoksilin kaplet 500 mg (4.401 unit), Antasida DOEN I tablet kunyah (3.953 unit), Asam mefenamat kaplet 500 mg (3.884 unit), Asam askorbat 50 mg (3.713 unit), Asam folat 0,4 mg (3.084 unit), Alkohol Swabs (536 unit), Alat Suntik Sekali Pakai 3 ml (160 unit), Antasida DOEN II suspensi (105 unit), Amoksilin sirup kering 125 mg/5 mg (103 unit), dan Alat Suntik Sekali Pakai 1 ml (0 unit). Perbandingan dengan permintaan terakhir menunjukkan bahwa beberapa obat memiliki *error* kecil, seperti Antasida DOEN I, Antasida DOEN II, Amoksilin sirup, Alkohol Swabs, dan Alat Suntik 1 ml, sedangkan *error* yang cukup besar terjadi pada Asam mefenamat dan Asam folat. Nilai *Mean Squared Error* (MSE) keseluruhan sebesar 558.882,1 menunjukkan bahwa masih terdapat selisih antara nilai prediksi dan aktual, terutama dipengaruhi oleh obat dengan perbedaan permintaan yang besar. Secara umum, model XGBoost mampu memberikan prediksi yang cukup baik pada obat dengan pola permintaan stabil, namun perlu pengembangan lebih lanjut untuk obat dengan pola permintaan yang fluktuatif.

REFERENSI

- [1] Dava Maulana, M., Id Hadiana, A., & Rakhmat Umbara, F. (2023). ALGORITMA XGBOOST UNTUK KLASIFIKASI KUALITAS AIR MINUM. In *Jurnal Mahasiswa Teknik Informatika* (Vol. 7, Issue 5). <https://www.kaggle.com/datasets/adityak>
- [2] Dzul Asmi Alhamdi, M., Herman, & Astuti, W. (2023). Peramalan Kebutuhan Obat Menggunakan XGBoost Studi Kasus pada Rumah Sakit XYZ. *Indonesian Journal of Computer Science Attribution*, 12(5), 2023–2757.
- [3] Gunawan, R., Erik Suanda Handika, & Edi Ismanto. (2022). Pendekatan Machine Learning Dengan Menggunakan Algoritma Xgboost (Extreme Gradient Boosting) Untuk Peningkatan Kinerja Klasifikasi Serangan Syn. *Jurnal CoSciTech (Computer Science and Information Technology)*, 3(3), 453–463. <https://doi.org/10.37859/coscitech.v3i3.4356>
- [4] Alkaff, M., Rizky Baskara, A., & Ainiyyah. (2023). Penerapan Metode XGBoost Untuk Memprediksi Jumlah Kejadian Kecelakaan Lalu Lintas di Kota Banjarmasin. In *Generation Journal* (Vol. 7, Issue 1).
- [5] Afisyah, A., Winata, H., & Syahputra, Y. H. (2021). Implementasi Data Mining Dengan Metode FP-Growth Untuk Strategi Promosi Pada Toko Cool Kids Plaza Medan Fair. In *Jurnal CyberTech*. <https://ojs.trigunadharma.ac.id/>
- [6] Gunawan, R., Erik Suanda Handika, & Edi Ismanto. (2022). Pendekatan Machine Learning Dengan Menggunakan Algoritma Xgboost (Extreme Gradient Boosting) Untuk Peningkatan Kinerja Klasifikasi Serangan Syn. *Jurnal CoSciTech (Computer Science and Information Technology)*, 3(3), 453–463. <https://doi.org/10.37859/coscitech.v3i3.4356>
- [7] Kurniawan, W., & Indahyanti, U. (2024). Prediksi Angka Harapan Hidup Penduduk Menggunakan Metode XGBoost. *Indonesian Journal of Applied Technology*, 1(2), 18. <https://doi.org/10.47134/ijat.v1i2.3045>
- [8] Kusnadi, I. T., Supiandi, A., Rifa, & Oktaviani, R. (2020). *Pemodelan Sistem Berbasis Objek with UML*. Graha Ilmu.
- [9] Prameswari, S. A., & Kusriani, K. (2024). Analisis Perbandingan Kinerja DWT dan SWT dalam Pengenalan Emosi Berbasis EEG Menggunakan XGBoost. In *Oktober* (Vol. 5, Issue 4).
- [10] Saputra, A. A., Sari, B. N., & Rozikin, C. (2024). Penerapan Algoritma Extreme Gradient Boosting (Xgboost) Untuk Analisis Risiko Kredit. *Jurnal Ilmiah Wahana Pendidikan*, 10(7), 27–36. <https://doi.org/10.5281/zenodo.10960080>
- [11] Sudarsono, B. G., Leo, M. I., Santoso, A., & Hendrawan, F. (2021). ANALISIS DATA MINING DATA NETFLIX MENGGUNAKAN APLIKASI RAPID MINER. *JBASE - Journal of Business and Audit Information Systems*, 4(1). <https://doi.org/10.30813/jbase.v4i1.2729>
- [12] XGBoost Developers. (2025). *xgboost Release 3.1.0-dev xgboost developers*.