

## MODEL KLASIFIKASI PENERIMA PROGRAM KARTU INDONESIA PINTAR MENGUNAKAN METODE XGBOOST

Andi Nurkholis<sup>1\*</sup>, Styawati<sup>2</sup>, Susi<sup>3</sup>, Alifah Chairul Munawar<sup>4</sup>

Department of Informatics<sup>1,4</sup>  
Universitas Pembangunan Nasional Veteran Yogyakarta, Yogyakarta, Indonesia<sup>1,4</sup>  
[www.upnyk.ac.id](http://www.upnyk.ac.id)<sup>1,4</sup>  
[andinurkholis@upnyk.ac.id](mailto:andinurkholis@upnyk.ac.id)<sup>1\*</sup>, [123240234@upnyk.ac.id](mailto:123240234@upnyk.ac.id)<sup>4</sup>

Department of Information Systems<sup>2,3</sup>  
Universitas Teknokrat Indonesia, Bandar Lampung, Indonesia<sup>2,3</sup>  
[www.teknokrat.ac.id](http://www.teknokrat.ac.id)<sup>2,3</sup>  
[styawati@teknokrat.ac.id](mailto:styawati@teknokrat.ac.id)<sup>2</sup>, [susi.mhs@teknokrat.ac.id](mailto:susi.mhs@teknokrat.ac.id)<sup>3</sup>

(\*) Corresponding Author



Ciptaan disebarluaskan di bawah Lisensi Creative Commons Atribusi-NonKomersial 4.0 Internasional.

**Abstract**— Poverty is one of the major factors contributing to the low quality of education in Indonesia. The Smart Indonesia Program (Program Indonesia Pintar) is a cash assistance program distributed through the Smart Indonesia Card (Kartu Indonesia Pintar/KIP) to support students from economically disadvantaged families, ranging from elementary to higher education levels. This study aims to classify students who are eligible to receive the Smart Indonesia Card using the XGBoost method, with a case study conducted at SMPN 02 Kebun Tebu. The dataset used in this study consists of independent and dependent variables. The independent variables include father's age, mother's age, father's education level, mother's education level, father's income, mother's income, number of family dependents, and students' academic average scores. The dependent variable is the eligibility status of KIP recipients as the target class. Two classification models were developed using data split ratios of 70:30 and 80:20. The model with a 70:30 data split achieved an accuracy of 0.9048, a precision of 0.9034, a recall of 0.9072, and an F1-score of 0.9053. Meanwhile, the model with an 80:20 data split demonstrated better performance, with an accuracy of 0.9167, a precision of 0.9149, a recall of 0.9189, and an F1-score of 0.9169. The optimal model obtained from this study can be utilized by schools to support policy decision-making in determining eligible Smart Indonesia Card recipients, ensuring that educational assistance is distributed accurately, adequately, and equitably.

**Keywords:** Classification, Education, Smart Indonesia Card, XGBoost method.

**Abstrak**— Kemiskinan merupakan salah satu dari banyak faktor yang berkontribusi terhadap rendahnya kualitas pendidikan di Indonesia. Program Indonesia Pintar merupakan program bantuan tunai yang disalurkan melalui Kartu Indonesia Pintar (KIP) untuk mendukung perkembangan pendidikan siswa yang kurang mampu secara ekonomi mulai dari jenjang pendidikan dasar hingga perguruan tinggi. Penelitian ini bertujuan untuk mengklasifikasikan siswa yang berhak memperoleh Kartu Indonesia Pintar menggunakan metode XGBoost dengan studi kasus di SMPN 02 Kebun Tebu. *Dataset* yang digunakan terdiri dari dua jenis variabel, yaitu variabel independen dan variabel dependen. Variabel independen meliputi usia ayah, usia ibu, pendidikan ayah, pendidikan ibu, pendapatan ayah, pendapatan ibu, jumlah tanggungan keluarga, dan rata-rata nilai akademik siswa. Variabel dependen adalah status kelayakan penerima KIP sebagai kelas target. Dua model dihasilkan dari pembagian data dengan rasio 70:30 dan 80:20. Model dengan partisi 70:30 menghasilkan akurasi sebesar 0.9048, *precision* sebesar 0.9034, *recall* sebesar 0.9072, dan *F1-Score* sebesar 0.9053. Sementara itu, model dengan partisi 80:20 menghasilkan performa yang lebih baik dengan akurasi sebesar 0.9167, *precision* sebesar 0.9149, *recall* sebesar 0.9189, dan *F1-Score* sebesar 0.9169. Model optimal yang diperoleh dari penelitian ini dapat digunakan oleh pihak sekolah untuk membantu proses

pengambilan kebijakan dalam menentukan penerima bantuan Kartu Indonesia Pintar sehingga pemberian bantuan kepada siswa dapat dilakukan secara tepat sasaran, memadai, dan berkeadilan.

**Kata kunci:** *Klasifikasi, Pendidikan, Kartu Indonesia Pintar, metode XGBoost.*

## PENDAHULUAN

Pendidikan merupakan fondasi utama dalam pembangunan sumber daya manusia dan pembentukan karakter bangsa (Yuniarto & Yudha, 2021). Hal ini tercantum dalam Pasal 31 Undang-Undang Dasar 1945 yang menyatakan bahwa setiap warga negara berhak mendapatkan pendidikan, dan pemerintah berkewajiban untuk mewujudkan amanat tersebut (Sakhiyya & Rahmawati, 2024). Meskipun demikian, Indonesia masih menghadapi berbagai tantangan di bidang pendidikan, terutama terkait akses dan pemerataan. UNICEF melaporkan bahwa sekitar 4.3 juta anak dan remaja Indonesia berusia 7–18 tahun tidak bersekolah (UNICEF Indonesia, 2023). Salah satu hambatan terbesar dalam memperoleh pendidikan adalah ketimpangan ekonomi. Berdasarkan data Badan Pusat Statistik (BPS) tahun 2023, sekitar 23.4% anak dari keluarga kurang mampu tidak dapat melanjutkan pendidikan ke jenjang menengah karena masalah keuangan (Direktorat Statistik Kesejahteraan Rakyat, 2023). Kondisi ini semakin diperparah oleh pandemi COVID-19 yang meningkatkan angka kemiskinan dan menurunkan kemampuan masyarakat dalam membiayai pendidikan (Ssenyonga, 2021).

Untuk mengatasi tantangan tersebut, pemerintah meluncurkan Program Indonesia Pintar (PIP) berdasarkan Instruksi Presiden Nomor 7 Tahun 2014 dengan Kartu Indonesia Pintar (KIP) sebagai instrumen utamanya (Ridwan & Afriadi, 2023). Program ini merupakan pengembangan dari program Bantuan Siswa Miskin (BSM) yang mencakup siswa dari jenjang pendidikan dasar hingga perguruan tinggi, serta peserta Pusat Kegiatan Belajar Masyarakat (PKBM) (Salsabilah et al., 2024). Pada tahun 2023, pemerintah mengalokasikan anggaran sebesar Rp9,6 triliun untuk PIP guna menjangkau 17,9 juta siswa (Pusat Layanan Pembiayaan Pendidikan, 2024). Namun demikian, pelaksanaan KIP masih menghadapi permasalahan serius terkait ketepatan sasaran. Badan Pemeriksa Keuangan (BPK) melaporkan bahwa pada tahun 2020, dana PIP sebesar Rp2,86 triliun untuk 5,36 juta siswa disalurkan secara tidak tepat kepada penerima yang tidak memenuhi syarat atau tidak diusulkan, sehingga distribusinya tidak tepat sasaran (CNBC Indonesia, 2021). Permasalahan ini menyebabkan efektivitas program dalam mendorong pemerataan akses pendidikan menjadi kurang optimal.

Beberapa penelitian telah membahas metode klasifikasi dalam menentukan penerima Kartu Indonesia Pintar yang tepat sasaran. Penelitian pertama membandingkan metode Naïve Bayes dan K-NN menggunakan validasi holdout. Hasil tanpa validasi menunjukkan Naïve Bayes lebih unggul (Naïve Bayes 85,66% dibanding K-NN 84,89%), namun setelah dilakukan validasi, K-NN menunjukkan hasil yang lebih baik, dimana K-NN 88,7% lebih tinggi dibandingkan Naïve Bayes tanpa validasi yaitu 81,3% (Karo et al., 2021). Penelitian kedua mengkaji pengukuran jarak pada metode K-NN dan melaporkan bahwa jarak Mahalanobis bekerja dengan baik untuk data berdimensi tinggi, sedangkan jarak Manhattan efektif untuk data dengan jumlah variabel yang sedikit. Secara umum, berbagai metode seleksi fitur memberikan peningkatan hasil, kecuali pada K-NN berbasis Mahalanobis (Tempola et al., 2021). Penelitian ketiga membandingkan algoritma C4.5 dan Naïve Bayes dengan kesimpulan bahwa C4.5 lebih efektif digunakan dalam pengambilan keputusan pemilihan penerima KIP (Hidayat et al., 2024).

Berdasarkan tinjauan literatur tersebut, terdapat celah penelitian yang dapat diidentifikasi. Pertama, penelitian sebelumnya mayoritas menggunakan metode klasifikasi tradisional seperti Naïve Bayes, K-NN, dan C4.5 yang kurang optimal dalam menangani interaksi antar variabel prediktor. Kedua, belum ditemukan penelitian yang menerapkan XGBoost untuk klasifikasi penerima KIP. Ketiga, akurasi yang dicapai oleh penelitian terdahulu masih berkisar 80%, sehingga masih terdapat peluang untuk peningkatan performa. Oleh karena itu, penelitian ini hadir untuk mengisi celah tersebut dengan pendekatan yang lebih robust.

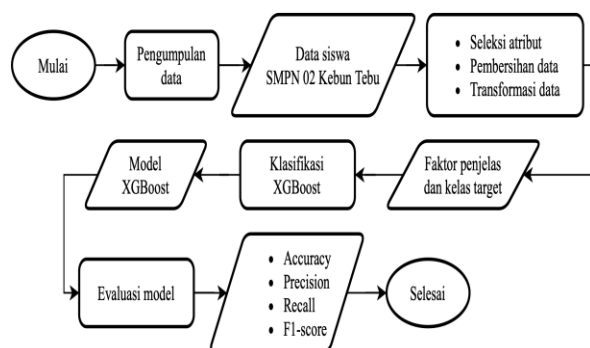
XGBoost (eXtreme Gradient Boosting) sebagai metode klasifikasi yang andal telah banyak diterapkan dan menunjukkan hasil prediksi yang memuaskan pada dataset kompleks dengan banyak prediktor. Penelitian terdahulu menunjukkan bahwa XGBoost memiliki performa yang lebih baik dibandingkan metode tradisional (Asselman et al., 2023). Studi komparatif lainnya menunjukkan bahwa XGBoost memiliki keunggulan dalam kecepatan komputasi dan kemampuan menangani nilai yang hilang (missing values) dibandingkan metode ensemble lainnya (Bentéjac et al., 2021).

Penelitian ini mengusulkan metode XGBoost untuk mengklasifikasikan penerima KIP berdasarkan delapan atribut, yaitu: usia ayah, usia ibu, tingkat pendidikan ayah, tingkat pendidikan

ibu, pendapatan ayah, pendapatan ibu, jumlah tanggungan keluarga, dan nilai rata-rata akademik. Pemilihan atribut ini didasarkan pada kajian literatur dan masukan dari pemangku kepentingan pendidikan. Model yang dikembangkan diharapkan dapat menjadi alat bantu keputusan yang objektif bagi lembaga pendidikan sekaligus menjadi acuan bagi pembuat kebijakan dalam memperbaiki sistem distribusi bantuan. Dengan demikian, ketepatan sasaran program KIP dapat meningkat dan mendukung pemerataan akses pendidikan berkualitas bagi seluruh warga negara Indonesia.

## BAHAN DAN METODE

Studi kasus penelitian ini dilakukan di SMP Negeri 02 Kebun Tebu, Kecamatan Kebun Tebu, Kabupaten Lampung Barat, Provinsi Lampung, Indonesia. Pemilihan sekolah ini didasarkan pada keberagaman latar belakang sosial-ekonomi siswa serta tingginya kebutuhan penyaluran bantuan KIP yang tepat sasaran di wilayah tersebut. Penelitian ini bertujuan untuk mengembangkan model klasifikasi yang akurat guna meningkatkan ketepatan penentuan penerima KIP, sehingga dapat mendorong pemerataan akses pendidikan. Tahapan metodologi penelitian ditunjukkan pada Gambar 1.



Sumber: (Hasil Penelitian, 2025)

Gambar 1. Tahap penelitian

Gambar 1 menunjukkan empat tahapan utama, yaitu: pengumpulan data, praproses data, klasifikasi model, dan evaluasi. Penjelasan masing-masing tahapan adalah sebagai berikut:

### Pengumpulan Data

Penelitian ini bersifat empiris dengan menggunakan protokol terstruktur untuk mengumpulkan data di SMPN 02 Kebun Tebu, serta mengacu pada paradigma *educational data mining* (Bachhal et al., 2021). Pengumpulan data dilakukan melalui observasi langsung dan wawancara terstruktur dengan pihak terkait di tingkat kecamatan untuk memperoleh data yang lengkap dalam klasifikasi penerima KIP. *Dataset* yang

dihasilkan terdiri dari 418 data siswa dengan 13 variabel prediktor dan satu variabel respons kategoris. Variabel-variabel tersebut mencakup faktor sosial-ekonomi (pendapatan orang tua), tingkat pendidikan orang tua, demografi keluarga, dan prestasi akademik yang menjadi dasar empiris dalam penerapan klasifikasi berbasis XGBoost. Dataset yang digunakan ditunjukkan pada Tabel I.

Tabel 1. Data penelitian

Atribut	Deskripsi
<i>Name</i>	Nama siswa SMPN 01 Kebun Tebu sebagai calon penerima KIP
<i>Father's Name</i>	Nama ayah dari siswa calon penerima KIP
<i>Mother's Name</i>	Nama ibu dari siswa calon penerima KIP
<i>Father's Job</i>	Pekerjaan ayah dari siswa calon penerima KIP
<i>Mother's Job</i>	Pekerjaan ibu dari siswa calon penerima KIP
<i>Father's Age</i>	Usia ayah dari siswa calon penerima KIP
<i>Mother's Age</i>	Usia ibu dari siswa calon penerima KIP
<i>Father's Education</i>	Pendidikan ayah dari siswa calon penerima KIP
<i>Mother's Education</i>	Pendidikan ibu dari siswa calon penerima KIP
<i>Father's Income</i>	Pendapatan ayah dari siswa calon penerima KIP
<i>Mother's Income</i>	Pendapatan ibu dari siswa calon penerima KIP
<i>Dependents</i>	Jumlah tanggungan keluarga dari siswa calon penerima KIP
<i>Academic average</i>	Nilai rata-rata akademik dari siswa calon penerima KIP
<i>Status</i>	Kelas status kelayakan yang terdiri dari Layak atau Tidak Layak

Sumber: (Hasil Penelitian, 2025)

Penentuan label kelayakan KIP mengacu pada kriteria resmi Kementerian Pendidikan dan Kebudayaan. Label "Layak" diberikan kepada siswa dari keluarga pemegang KKS, peserta PKH, yatim piatu, atau keluarga dengan kondisi ekonomi rentan. Validasi label dilakukan melalui triangulasi data administrasi sekolah, wawancara pihak kecamatan, dan data penerima KIP aktual tahun sebelumnya.

### Praproses Data

Praproses merupakan tahapan dasar dalam data mining yang berfungsi mengubah data mentah menjadi struktur yang siap dianalisis (Saraswat & Raj, 2022). Sesuai dengan kerangka kerja preprocessing yang ada (Rahhali et al., 2024), tahapan ini mencakup prosedur optimasi kualitas data untuk menjamin keandalan analisis dalam skenario educational data mining. Proses ini memastikan integritas data sehingga memberikan landasan yang kuat bagi penerapan XGBoost dalam klasifikasi penerima Kartu Indonesia Pintar (KIP) di SMPN 02 Kebun Tebu.

Seleksi atribut dilakukan untuk memilih variabel yang relevan dan berpengaruh terhadap

hasil klasifikasi, sekaligus menghilangkan data yang tidak diperlukan atau mengandung noise. Pemilihan atribut didasarkan pada wawancara dengan pihak sekolah untuk menentukan variabel utama yang memengaruhi klasifikasi penerima KIP. Atribut yang dipilih meliputi: *Father's Age (FA)*, *Mother's Age (MA)*, *Father's Education (FE)*, *Mother's Education (ME)*, *Father's Income (FI)*, *Mother's Income (MI)*, *Number of Dependents (DPE)* and *Academic Average (AA)*, dengan *Status (S)* sebagai kelas target. Setelah seleksi atribut, tahap selanjutnya adalah pembersihan data (*data cleansing*). Proses ini bertujuan mengidentifikasi dan memperbaiki atau menghapus data yang kosong maupun keliru. Teknik yang digunakan meliputi pengisian nilai yang hilang (*missing values*), penghalusan data yang mengandung *noise*, dan penyelesaian inkonsistensi data.

### Klasifikasi XGBoost

XGBoost adalah algoritma *ensemble learning* berbasis *gradient boosting* yang dirancang untuk meningkatkan akurasi dan efisiensi komputasi dalam permasalahan klasifikasi maupun regresi (Sepbriant & Utomo, 2024). Algoritma ini mampu memproses data yang kompleks dan berukuran besar dengan menerapkan prinsip *ensemble learning* dan optimasi gradien. Dibandingkan algoritma klasifikasi tradisional, XGBoost memiliki beberapa keunggulan, antara lain: regularisasi yang kuat untuk mencegah *overfitting*, kemampuan menangani nilai yang hilang, paralelisasi operasi untuk meningkatkan kecepatan komputasi, serta fleksibilitas dalam fungsi objektif dan kriteria evaluasi (Ali et al., 2023). Keunggulan tersebut menjadikan XGBoost cocok untuk menangani data pendidikan yang memiliki variabel beragam dan hubungan antar variabel yang kompleks. Algoritma ini bekerja dengan prinsip boosting, yaitu membangun model secara bertahap untuk mengurangi kesalahan prediksi dari model sebelumnya. Pseudocode algoritma XGBoost ditunjukkan pada Gambar 2 (Li et al., 2025).

#### Inisialisasi:

1. Diberikan data training penerima KIP  $S = \{(x_1, y_1), \dots, (x_m, y_m)\}$  dengan  $x_i \in X$  dan  $y_i \in \{0, 1\}$
2. Inisialisasi prediksi dasar  $F_0(x) = 0$
3. Tentukan *learning rate*  $\eta$  dan jumlah iterasi  $T$

#### Algoritma:

for  $t = 1$  to  $T$  do

1. Hitung gradien negatif (*pseudo-residual*):  
 $r_{it} = -\partial L(y_i, F_{t-1}(x_i)) / \partial F_{t-1}(x_i)$  untuk  $i = 1, \dots, m$
2. Bangun pohon regresi  $h_t(x)$  yang memprediksi  $r_{it}$  dari  $x_i$ :  $h_t(x): X \rightarrow R$  menggunakan  $\{(x_i, r_{it})\}_{i=1}^m$

3. Untuk setiap *leaf*  $j = 1, \dots, J$  pada  $h_t(x)$ : Hitung bobot optimal  $w_{jt} = \operatorname{argmin}_w \sum_{i \in I_j} L(y_i, F_{t-1}(x_i) + w)$  dengan  $I_j = \{i : x_i \text{ masuk ke leaf } j\}$
  4. Perbarui model:  $F_t(x) = F_{t-1}(x) + \eta \cdot h_t(x)$
- end for

Model Akhir:  $F(x) = F_T(x)$

Prediksi:  $\hat{y} = \sigma(F(x))$ , dengan  $\sigma$  adalah fungsi *sigmoid*

Dimana:

X: Ruang input (8 atribut KIP)

y: Output biner  $\{0, 1\}$  (Tidak Layak, Layak)

L: Fungsi *loss* (umumnya logistic loss)

$\eta$ : *Learning rate* (laju pembelajaran)

T: Jumlah iterasi

$h_t$ : Pohon regresi pada iterasi ke- $t$

$F_t$ : Model pada iterasi ke- $t$

### Evaluasi Model

Evaluasi dilakukan menggunakan beberapa metrik pengukuran untuk menilai kemampuan model dalam mengklasifikasikan penerima KIP. Analisis ini bertujuan untuk mengukur kekuatan model XGBoost dalam membedakan siswa yang layak dan tidak layak berdasarkan atribut yang telah ditentukan. Semakin tinggi akurasi, semakin sedikit kesalahan prediksi pada data uji, yang menunjukkan bahwa model memiliki performa baik dan hasil klasifikasi yang andal (Nurkholis et al., 2022). Evaluasi menggunakan confusion matrix dengan empat metrik kinerja utama yang didefinisikan melalui persamaan berikut (Nurkholis et al., 2024):

$$\text{Accuracy} = \frac{TP + TN}{TP + FN + TN + FP} \quad (1)$$

TP (*True Positive*) merupakan siswa layak yang teridentifikasi dengan benar, TN (*True Negative*) merupakan siswa tidak layak yang teridentifikasi dengan benar, FP (*False Positive*) menunjukkan kesalahan klasifikasi sebagai layak, dan FN (*False Negative*) menunjukkan kesalahan klasifikasi sebagai tidak layak.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2)$$

*Precision* mengukur ketepatan prediksi positif, yaitu seberapa banyak siswa yang diklasifikasikan layak memang benar-benar layak.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3)$$

*Recall* mengukur kemampuan model dalam mengidentifikasi seluruh siswa layak dari *dataset*.

$$F_1 \text{ score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

*F1-Score* memberikan ukuran yang seimbang antara *precision* dan *recall* dengan mempertimbangkan *false positive* dan *false negative*.

Metrik evaluasi tersebut digunakan untuk menilai performa model XGBoost dalam klasifikasi penerima KIP. *Accuracy* memberikan gambaran performa secara keseluruhan, *precision* meminimalkan kesalahan penentuan kelayakan, *recall* memastikan tidak ada siswa layak yang terlewat, dan *F1-Score* memberikan penilaian performa yang berimbang. Namun, evaluasi ini memiliki keterbatasan karena hanya menggunakan dataset dari satu sekolah, sehingga generalisasi model belum teruji. Hal ini membuka peluang penelitian selanjutnya untuk memperluas cakupan data.

## HASIL DAN PEMBAHASAN

Hasil praposes data menghasilkan sembilan atribut penjas dan satu atribut kelas dengan total 418 baris data (Tabel 2). Selanjutnya, *dataset* diklasifikasikan menggunakan metode XGBoost untuk menentukan status kelayakan siswa sebagai penerima Kartu Indonesia Pintar.

Tabel 2. Dataset akhir

No	FA	MA	FE	ME	FI	MI	D	AA	S
1	42	39	SMP	SMP	1-2 M	< 1 M	2	< 60	NOT ELIGIBLE
2	58	56	SMA	SMA	1-2 M	< 1 M	1	60-70	NOT ELIGIBLE
3	54	39	SMA	SMP	2-4 M	< 1 M	2	71-80	NOT ELIGIBLE
...	...	...	...	...	...	...	...	...	...
417	49	45	SMA	SMP	1-2 M	2-4 M	3	> 80	ELIGIBLE
418	48	45	SMA	SMP	2-4 M	< 1 M	3	60-70	NOT ELIGIBLE

Sumber: (Hasil Penelitian, 2025)

### Model Klasifikasi XGBoost

Pada tahap klasifikasi XGBoost, data dibagi menjadi data *training* dan data *testing*. Penelitian ini menerapkan dua skema pembagian data: rasio 80:20 dan rasio 70:30. Pada rasio 80:20, model dilatih menggunakan 80% data dan dievaluasi menggunakan 20% sisanya. Pada rasio 70:30, model dilatih dengan 70% data dan diuji dengan 30% sisanya. Penerapan dua skema pembagian ini bertujuan untuk menguji efektivitas model XGBoost pada rasio yang berbeda. Dengan membandingkan hasil kedua variasi tersebut, dapat ditentukan rasio pembagian data yang optimal untuk mencapai

akurasi tertinggi dalam klasifikasi penerima KIP di SMPN 02 Kebun Tebu.

### Model Evaluation

Model XGBoost dievaluasi pada data *testing* berdasarkan dua variasi pembagian data, yaitu 80:20 (variasi pertama) dan 70:30 (variasi kedua). Hasil evaluasi kedua variasi tersebut disajikan pada Tabel 3.

Tabel 3. Hasil evaluasi model

Aspek	Hasil model	
	Variasi 70:30	Variasi 80:20
<i>Accuracy</i>	0.9048	0.9167
<i>Sensitivity/ Recall</i>	0.9074	0.9189
<i>Precision</i>	0.9032	0.9149
<i>F1-Score</i>	0.9053	0.9169

Sumber: (Hasil Penelitian, 2025)

Berdasarkan implementasi model XGBoost dengan dua variasi pembagian *dataset*, hasil penelitian menunjukkan bahwa model dengan rasio 80:20 memiliki performa lebih baik dibandingkan rasio 70:30 dalam klasifikasi penerima KIP. Model 80:20 menghasilkan metrik evaluasi yang sangat baik, yaitu: akurasi 0.9167, *precision* 0.9189, *recall* 0.9149, dan *F1-Score* 0.9169. Seluruh metrik evaluasi secara konsisten berada di atas 0.90, menunjukkan keandalan model dalam mengklasifikasikan kelayakan penerima KIP berdasarkan atribut yang telah ditentukan.

Keunggulan model 80:20 dapat dijelaskan dari beberapa aspek. Dari sisi *volume data training*, penggunaan 334 data (80%) memberikan basis pembelajaran yang lebih kaya bagi model untuk mempelajari pola kompleks dari delapan prediktor, meliputi: demografi orang tua (usia dan pendidikan), ekonomi keluarga (pendapatan orang tua), jumlah tanggungan keluarga, dan prestasi akademik siswa. Data *training* yang lebih banyak memungkinkan model melakukan generalisasi yang lebih baik terhadap berbagai kombinasi karakteristik penerima KIP.

Nilai *precision* sebesar 0.9189 menunjukkan kemampuan model yang baik dalam meminimalkan *false positive*, yaitu kesalahan mengklasifikasikan siswa tidak layak sebagai layak KIP. Hal ini sangat penting mengingat keterbatasan kuota dan anggaran program KIP, sehingga identifikasi siswa yang benar-benar berhak menjadi prioritas utama. Di sisi lain, nilai *recall* yang tinggi (0.9149) menunjukkan bahwa sebagian besar siswa yang layak KIP berhasil diidentifikasi oleh model, sehingga kemungkinan terlewatnya siswa yang berhak menjadi sangat kecil.

*F1-Score* sebesar 0.9169 menunjukkan bahwa model mencapai keseimbangan yang baik

antara precision dan recall, yaitu mampu mengidentifikasi penerima yang layak secara tepat sekaligus menjangkau sebanyak mungkin siswa yang memenuhi syarat. Keseimbangan ini sangat penting dalam program berbasis sosial-ekonomi seperti KIP, di mana akses pendidikan bagi siswa dari keluarga kurang mampu harus dikelola dengan baik tanpa mengorbankan efektivitas penargetan program.

Dari aspek validasi model, meskipun hanya menggunakan 84 data testing (20%), jumlah tersebut cukup memadai untuk menguji apakah model mengalami overfitting. Hal ini tercermin dari performa yang konsisten pada seluruh metrik evaluasi. Mengingat SMPN 02 Kebun Tebu merupakan sekolah dengan skala kecil, volume data testing ini dianggap cukup untuk menguji ketangguhan model dalam implementasi nyata.

Performa prediktor yang relatif stabil menunjukkan bahwa variabel-variabel yang dipilih memiliki korelasi kuat dengan kelayakan penerima KIP. Model juga mampu menangani kombinasi data dengan baik, di mana kombinasi tertentu dari pendapatan orang tua, jumlah tanggungan keluarga, dan nilai akademik siswa secara bersama-sama berkontribusi dalam menentukan kelayakan penerima KIP. Hal ini membenarkan pemilihan variabel-variabel tersebut sebagai penentu dalam tugas klasifikasi.


Performa model 80:20 yang lebih tinggi dibandingkan model 70:30 (akurasi 0.9048, *precision* 0.9074, *recall* 0.9032, dan *F1-Score* 0.9040) dapat dijelaskan melalui *trade-off* antara *volume training* dan *testing*. Meskipun model 70:30 memiliki data testing yang lebih besar (125 data), pengurangan data training menjadi 293 data sedikit menurunkan kemampuan model dalam menggeneralisasi pola yang lebih kompleks. Hasil akurasi 0.9167 atau 91.67% pada penelitian ini juga lebih tinggi dibandingkan metode K-NN (88.7%), Naïve Bayes (81.3%), dan C4.5 pada penelitian terdahulu (Hidayat et al., 2024; Karo et al., 2021). Namun, perbandingan ini hanya bersifat indikatif mengingat perbedaan *dataset* yang digunakan pada masing-masing penelitian.

Berdasarkan analisis di atas, model XGBoost dengan variasi pembagian data 80:20 merupakan model terbaik dalam penelitian ini untuk mengklasifikasikan siswa penerima KIP di SMPN 02 Kebun Tebu. Model ini menunjukkan performa yang lebih baik pada seluruh aspek evaluasi dibandingkan model 70:30 tanpa menunjukkan tanda-tanda *overfitting*.

### Feature Importance

Analisis skor *feature importance* dari model XGBoost mengungkapkan struktur dan hierarki

antar variabel prediktor dalam menentukan kelayakan penerima KIP. Distribusi *feature importance* menunjukkan adanya interaksi antara fitur sosial-ekonomi, pendidikan, dan demografi, dengan indikator ekonomi sebagai faktor dominan dalam klasifikasi sebagaimana ditunjukkan pada Gambar 3.



Sumber: (Hasil Penelitian, 2025)

Gambar 3. *Feature importance*

Hasil analisis menunjukkan bahwa variabel pendapatan orang tua memiliki kontribusi total sebesar 53.7% terhadap struktur keputusan model. Dalam kategori ini, pendapatan ayah memiliki kekuatan prediktif sedikit lebih tinggi (28.4%) dibandingkan pendapatan ibu (25.3%). Distribusi ini sesuai dengan tujuan utama program KIP untuk menjangkau dan membantu siswa dari keluarga kurang mampu secara ekonomi, serta mencerminkan kondisi sosial di lingkungan SMPN 02 Kebun Tebu.

Prediktor penting berikutnya adalah prestasi akademik dengan kontribusi sebesar 18,6% terhadap model klasifikasi. Penekanan pada aspek akademik ini menunjukkan bahwa model mampu menyeimbangkan antara urgensi ekonomi dan pencapaian akademik, yang sejalan dengan misi ganda program KIP untuk memfasilitasi akses pendidikan bagi siswa kurang mampu sekaligus mempertahankan standar kualitas. Penyertaan variabel prestasi akademik memastikan bahwa sistem klasifikasi mempertimbangkan kebutuhan finansial dan potensi akademik secara bersamaan.

Jumlah tanggungan keluarga memiliki bobot signifikan sebesar 11.2%, menunjukkan pentingnya variabel ini dalam memprediksi beban ekonomi rumah tangga. Pembobotan ini mencerminkan asumsi model bahwa ukuran keluarga merupakan indikator kapasitas finansial dan distribusi sumber daya, sesuai dengan praktik penilaian kesejahteraan yang mempertimbangkan ketersediaan sumber daya per kapita rumah tangga.

Indikator tingkat pendidikan orang tua secara keseluruhan hanya menyumbang 12.1% dalam model, dengan pendidikan ayah (6.7%) sedikit lebih berpengaruh dibandingkan

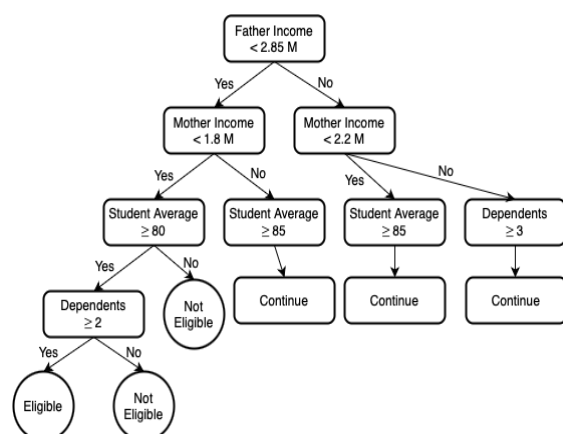
pendidikan ibu (5.4%). Variabel latar belakang pendidikan ini berfungsi sebagai proksi untuk pendapatan permanen atau nilai-nilai keluarga terkait pendidikan. Penekanan yang moderat pada variabel ini menunjukkan perannya sebagai faktor pendukung konteks, bukan sebagai penentu utama.

Faktor demografi berupa usia orang tua memiliki tingkat kepentingan paling rendah, yaitu 4.4% secara keseluruhan (usia ayah 2.3% dan usia ibu 2.1%). Distribusi ini menunjukkan bahwa faktor demografi hanya memberikan konteks tambahan dalam model klasifikasi, bukan sebagai penentu kelayakan utama.

Karakterisasi distribusi feature importance ini memberikan wawasan yang berguna untuk perencanaan kebijakan dan optimasi program. Hasil penelitian mengarahkan program untuk menargetkan intervensi yang mengakui kompleksitas hambatan akses pendidikan dengan tetap memprioritaskan faktor ekonomi utama. Selain itu, hierarki feature importance dalam model ini menyediakan referensi berbasis data untuk menyempurnakan kriteria kelayakan dan meningkatkan akurasi proses identifikasi penerima manfaat dalam implementasi program KIP di SMPN 02 Kebun Tebu maupun institusi lainnya.

### Model Visualization

Model terbaik menghasilkan struktur pohon keputusan hierarkis yang terdiri dari beberapa tingkat simpul klasifikasi. Pohon tersebut menunjukkan pola percabangan sistematis berdasarkan nilai ambang batas yang telah ditentukan untuk berbagai parameter sosial-ekonomi dan akademik. Contoh visualisasi pohon XGBoost dapat dilihat pada Gambar 4.



Sumber: (Hasil Penelitian, 2025)

Gambar 4. Hasil pohon keputusan

Visualisasi parsial struktur pohon keputusan XGBoost menunjukkan sifat hierarkis dari proses klasifikasi. Dari kumpulan aturan yang dihasilkan

model, dapat diekstraksi lima contoh aturan keputusan representatif:

1. *IF father\_income < 2.85M AND mother\_income < 1.8M AND student\_average ≥ 80 AND dependents ≥ 2 THEN Status = Eligible*
2. *IF father\_income < 2.85M AND mother\_income ≥ 1.8M AND student\_average ≥ 85 THEN Status = Eligible*
3. *IF father\_income ≥ 2.85M AND mother\_income < 2.2M AND student\_average ≥ 85 AND dependents ≥ 3 THEN Status = Eligible*
4. *IF father\_income ≥ 2.85M AND mother\_income ≥ 2.2M AND student\_average ≥ 90 AND dependents ≥ 3 THEN Status = Eligible*
5. *IF father\_income < 2.85M AND mother\_income < 1.8M AND student\_average < 80 THEN Status = Not Eligible*

Aturan-aturan tersebut menunjukkan bagaimana model mengintegrasikan faktor ekonomi (pendapatan orang tua), prestasi akademik (rata-rata nilai siswa), dan status keluarga (jumlah tanggungan) dalam menentukan kelayakan penerima KIP di SMPN 02 Kebun Tebu. Kontribusi metodologis penelitian ini tidak hanya terbatas pada hasil klasifikasi, tetapi juga pada perancangan kerangka kerja sistematis untuk alokasi bantuan pendidikan yang mencakup kriteria klasifikasi objektif berdasarkan karakteristik sosial-ekonomi, pertimbangan prestasi akademik, serta mekanisme pengambilan keputusan yang transparan.

### KESIMPULAN

Penelitian ini menggunakan XGBoost untuk mengklasifikasikan penerima bantuan pendidikan Kartu Indonesia Pintar di SMPN 02 Kebun Tebu. Model optimal diperoleh dengan pembagian data 80:20, menghasilkan akurasi 0.9167, precision 0.9189, recall 0.9141, dan F1-Score 0.9169. Hasil ini menunjukkan efektivitas machine learning dalam optimasi alokasi bantuan pendidikan. Analisis feature importance menunjukkan bahwa faktor ekonomi memiliki kontribusi tertinggi (53.7%), diikuti prestasi akademik (18.6%), pendidikan orang tua (12.1%), dan demografi keluarga (11.2%). Model menetapkan nilai ambang batas tertentu, seperti pendapatan ayah sebesar 2.85 juta rupiah. Penelitian ini menyediakan model berbasis data yang mempertimbangkan status sosial, prestasi akademik, dan kondisi keluarga untuk mengalokasikan bantuan pendidikan secara efisien kepada siswa yang paling membutuhkan. Penelitian selanjutnya dapat melibatkan variabel tambahan dan perbandingan dengan algoritma alternatif. Hasil penelitian ini menunjukkan potensi machine



learning dalam meningkatkan efektivitas alokasi bantuan pendidikan.

### REFERENSI

- Ali, Z. A., Abduljabbar, Z. H., Tahir, H. A., Sallow, A. B., & Almufti, S. M. (2023). eXtreme gradient boosting algorithm with machine learning: A review. *Academic Journal of Nawroz University*, 12(2), 320–334.
- Asselman, A., Khaldi, M., & Aammou, S. (2023). Enhancing the prediction of student performance based on the machine learning XGBoost algorithm. *Interactive Learning Environments*, 31(6), 3360–3379.
- Bachhal, P., Ahuja, S., & Gargrish, S. (2021). Educational data mining: A review. *Journal of Physics: Conference Series*, 1950(1), 012022.
- Bentéjac, C., Csörgő, A., & Martínez-Muñoz, G. (2021). A comparative analysis of gradient boosting algorithms. *Artificial Intelligence Review*, 54, 1937–1967.
- CNBC Indonesia. (2021, June 22). *Program Indonesia Pintar Rp2,8 T Tak Tepat Sasaran*. CNBC Indonesia.
- Direktorat Statistik Kesejahteraan Rakyat. (2023). *Kesejahteraan Anak Indonesia: Analisis Kemiskinan Anak Moneter 2022* (4103025th ed.). Badan Pusat Statistik.
- Hidayat, R., Huda, M., & Pradita, N. (2024). Comparison Of The C4. 5 And Naïve Bayes Algorithm For Recommendations For Aid Recipients For The Smart Indonesian Program. *Kesatria: Jurnal Penerapan Sistem Informasi (Komputer Dan Manajemen)*, 5(1), 345–358.
- Karo, I. M. K., Khosuri, A., & Setiawan, R. (2021). Effects of Distance Measurement Methods in K-Nearest Neighbor Algorithm to Select Indonesia Smart Card Recipient. *2021 International Conference on Data Science and Its Applications (ICoDSA)*, 209–214.
- Li, J., Gao, X., & Dong, R. (2025). XGBoost-SHAP-IPA: An explainable algorithm for influencing factors on resident willingness to pay for recycled water. *Alexandria Engineering Journal*, 131, 383–397.
- Nurkholis, A., Alim, S., Samsugi, S., & Asyad, C. (2024). Predictive Analysis of Toddler Nutrition Using C5. 0 Decision Tree Method. *2024 International Conference on Information Technology Research and Innovation (ICITRI)*, 88–92.
- Nurkholis, A., Purwayoga, V., Lukmana, H. H., Prihandono, A., & Koswara, W. (2022). Analysis of Weather Data for Rainfall Prediction using C5. 0 Decision Tree Algorithm. *2022 2nd International Seminar on Machine Learning, Optimization, and Data Science (ISMODE)*, 551–555.
- Pusat Layanan Pembiayaan Pendidikan. (2024, January 23). *Pemerintah Tingkatkan Bantuan PIP Bagi Siswa SMA dan SMK*. Kementerian Pendidikan Dasar Dan Menengah Republik Indonesia.
- Rahhali, M., Oughdir, L., Lahmadi, Y., & El Khatlab, M. Z. (2024). The Impact of Data Preprocessing on the Quality and Effectiveness of E-Learning. *International Journal of Intelligent Systems and Applications in Engineering*, 12, 59–65.
- Ridwan, A., & Afriadi, B. (2023). Review Study Evaluation Of Smart Indonesia Card Implementation Through Smart Indonesia Program. *International Education Trend Issues*, 1(2), 98–105.
- Sakhiyya, Z., & Rahmawati, Y. (2024). Overview of education in Indonesia. In *International Handbook on Education in Southeast Asia* (pp. 277–301). Springer.
- Salsabilah, W. S., Wahyudin, A., & Hidayati, S. (2024). Rethinking the Indonesia Smart Program (PIP): A Policy Review and Solutions for Better Student Outcomes. *Nidhomul Haq: Jurnal Manajemen Pendidikan Islam*, 9(3), 769–780.
- Saraswat, P., & Raj, S. (2022). Data pre-processing techniques in data mining: A Review. *International Journal of Innovative Research in Computer Science &amp*, 122–125.
- Sepbriant, G. D., & Utomo, D. W. (2024). Ensemble Learning pada Kategorisasi Produk E-Commerce menggunakan Teknik Boosting. *JISKA (Jurnal Informatika Sunan Kalijaga)*, 9(2), 123–133.
- Ssenyonga, M. (2021). Imperatives for post COVID-19 recovery of Indonesia's education, labor, and SME sectors. *Cogent Economics & Finance*, 9(1), 1911439.
- Tempola, F., Rosihan, R., & Adawiyah, R. (2021). Holdout validation for comparison classification naïve bayes and KNN of recipient kartu Indonesia pintar. *IOP Conference Series: Materials Science and Engineering*, 1125(1), 012041.
- UNICEF Indonesia. (2023). *Education and Adolescents in Indonesia 2023*. UNICEF Indonesia.
- Yuniarto, B., & Yudha, R. P. (2021). Citizenship Education in The Character Building of The Nation. *International Journal of Education and Humanities*, 1(3), 162–170.