

Classification Of Eligibility For Prospective Recipients Of The Kip Kuliah Scholarship Using The K-Nearest Neighbor Method At Dehasen University In Bengkulu

Imam Ashari ¹⁾; Herlina Latipa Sari ²⁾; Devi Sartika ³⁾

1) Study Program of Informatics, Faculty of Computer Science, Universitas Dehasen Bengkulu

2,3) Department of Informatics, Faculty of Computer Science, Universitas Dehasen Bengkulu

Email: ¹⁾ imamashari429@gmail.com

How to Cite :

Ashari, I., Sari, H. L., Sartika, D. (2026). Classification of the Eligibility of Prospective Recipients of the Smart Indonesia College Card Scholarship Using K-Nearest Neighbor at Universitas Dehasen Bengkulu. Jurnal Media Computer Science, 5(4).

ARTICLE HISTORY

Received [31 Agustus 2026]

Revised [23 Oktober 2026]

Accepted [25 Oktober 2026]

Keywords

Classification, K-Nearest Neighbor, Kip College Scholarship.

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license



ABSTRAK

Seleksi calon penerima Kartu Indonesia Pintar Kuliah di Universitas Dehasen Bengkulu menghadapi jumlah pendaftar yang besar, kuota terbatas, dan pemeriksaan berkas yang masih dilakukan secara manual sehingga prosesnya memerlukan waktu serta berpotensi menimbulkan ketidakkonsistenan keputusan. Penelitian ini bertujuan menerapkan K-Nearest Neighbor untuk mengklasifikasikan kelayakan calon penerima berdasarkan data sosial ekonomi dan akademik serta mengevaluasi performanya. Dataset berjumlah 665 data tahun 2025 diproses melalui data cleaning, data selection, label encoding, normalisasi Min-Max, dan pembagian 80% data training serta 20% data testing. Klasifikasi menggunakan jarak Euclidean dengan pengujian K=3, 5, 7, dan 9, sedangkan evaluasi menggunakan confusion matrix, accuracy, precision, recall, dan F1-score. Hasil terbaik diperoleh pada K=7 dengan accuracy 63,91%, precision 53,90%, recall 63,91%, dan F1-score 57,61%. Seluruh delapan fungsi sistem yang diuji melalui black-box testing berstatus berhasil. Dataset bersifat tidak seimbang, yaitu 180 data Layak dan 485 Tidak Layak; pada K=7 recall kelas Layak hanya 5%, sedangkan kelas Tidak Layak mencapai 87%. Dengan demikian, K-Nearest Neighbor dapat mendukung seleksi awal secara lebih konsisten, tetapi performa kelas minoritas masih perlu ditingkatkan melalui penanganan imbalance, seleksi fitur, dan evaluasi model yang lebih kuat.

ABSTRACT

The Kartu Indonesia Pintar (KIP) Kuliah program aims to help high-achieving students from low-income backgrounds continue their education at the university level. At Dehasen University in Bengkulu, the high number of applicants far exceeds the available quota, while the selection process is still conducted manually by reviewing applications one by one. This situation results in a slow and inefficient selection process that is prone to human error and potentially introduces subjectivity in determining the eligibility of scholarship candidates. This study aims to apply the K-Nearest Neighbor (KNN) algorithm to classify the eligibility of KIP Kuliah scholarship candidates based on socioeconomic and academic data. The research stages included importing a dataset of 665 records, data cleaning, data selection, data transformation, Min-Max normalization, and splitting the data into training and testing sets, followed by classification by testing values of K = 3, 5, 7, and 9 using Euclidean distance calculations. The research results show that the KNN algorithm was successfully applied in the classification process, with the best accuracy achieved at K=7: 63.91%, Precision 53.90%, Recall 63.91%, and F1-Score

57.61%. Thus, the K-Nearest Neighbor (KNN)-based classification system developed can facilitate the initial selection process for prospective recipients of the KIP Kuliah Scholarship more quickly, consistently, and objectively compared to a manual selection process.

PENDAHULUAN

Program Kartu Indonesia Pintar Kuliah ditujukan untuk memperluas akses pendidikan tinggi bagi calon mahasiswa yang memiliki keterbatasan ekonomi dan potensi akademik. Di Universitas Dehasen Bengkulu, jumlah pendaftar yang tinggi dibandingkan kuota membuat proses verifikasi menjadi pekerjaan yang intensif. Pemeriksaan berkas satu per satu membutuhkan waktu, memerlukan ketelitian tinggi, dan berpotensi menghasilkan keputusan yang tidak konsisten ketika atribut sosial ekonomi harus dipertimbangkan secara bersamaan.

Klasifikasi berbasis data dapat digunakan sebagai dukungan seleksi awal dengan mempelajari pola pada data penerima sebelumnya. Suganda et al. (2022) menunjukkan penggunaan metode klasifikasi untuk kasus beasiswa, sedangkan Iskandar (2022) menekankan peran sistem pendukung keputusan dalam mengurangi ketergantungan pada proses manual. Pendekatan semacam ini tidak menghilangkan proses verifikasi administratif, tetapi dapat menyediakan hasil awal yang konsisten berdasarkan atribut yang telah ditentukan.

K-Nearest Neighbor menentukan kelas data baru berdasarkan mayoritas kelas dari sejumlah tetangga yang paling dekat. Purwanto dan Nugroho (2023) melaporkan performa tinggi K-Nearest Neighbor pada data penerima beasiswa, sementara Wijaya et al. (2024) menerapkannya pada penerimaan beasiswa Kartu Indonesia Pintar. Namun, performa algoritma sangat bergantung pada karakteristik dataset, pemilihan atribut, skala data, nilai K, dan distribusi kelas. Hasil pada satu institusi tidak dapat langsung diasumsikan berlaku pada institusi lain.

Gap penelitian ini terletak pada penggunaan dataset aktual Universitas Dehasen Bengkulu dengan label kelayakan yang berasal dari data penerima, pengujian beberapa nilai K, serta evaluasi yang tidak berhenti pada accuracy. Penelitian juga menerapkan normalisasi Min-Max karena K-Nearest Neighbor berbasis jarak sensitif terhadap perbedaan skala atribut; pendekatan ini sejalan dengan Bu'ulolo (2024). Selain itu, confusion matrix digunakan untuk melihat perilaku model pada masing-masing kelas.

Kebaruan analitis penelitian terletak pada pembacaan performa model dalam konteks ketidakseimbangan kelas. Accuracy tertinggi tidak langsung dianggap sebagai bukti bahwa model telah adil mengenali kedua kelompok. Distribusi data Layak dan Tidak Layak serta recall per kelas dianalisis untuk mengidentifikasi bias terhadap kelas mayoritas. Analisis tersebut penting karena kesalahan gagal mengenali calon yang sebenarnya layak memiliki konsekuensi berbeda dari sekadar penurunan accuracy agregat.

Penelitian ini bertujuan menerapkan K-Nearest Neighbor untuk mengklasifikasikan kelayakan calon penerima Kartu Indonesia Pintar Kuliah di Universitas Dehasen Bengkulu, menentukan nilai K dengan performa terbaik pada dataset yang digunakan, mengevaluasi model melalui accuracy, precision, recall, F1-score, dan confusion matrix, serta mengidentifikasi keterbatasan model sebagai dasar pengembangan seleksi berbasis data.

LANDASAN TEORI

Klasifikasi dan K-Nearest Neighbor

Klasifikasi memetakan data ke kelas diskret berdasarkan pola pada data berlabel. Dalam penelitian ini, target terdiri atas dua kelas, yaitu Layak dan Tidak Layak. K-Nearest Neighbor tidak membentuk model parametrik kompleks; kelas data uji ditentukan berdasarkan kedekatan dengan data training. Karena keputusan bergantung pada tetangga terdekat, representasi atribut dan skala data menjadi faktor langsung terhadap hasil klasifikasi (Purwanto & Nugroho, 2023).

$$d(x,y) = \sqrt{\sum_i (x_i - y_i)^2}$$

Jarak Euclidean dihitung pada seluruh atribut yang telah dinormalisasi; nilai yang lebih kecil menunjukkan tingkat kemiripan yang lebih tinggi.

Normalisasi Min-Max

Normalisasi Min-Max mengubah setiap atribut ke rentang 0–1 agar variabel dengan nilai numerik besar tidak mendominasi jarak. Hal ini sangat penting pada data sosial ekonomi karena atribut dapat memiliki skala yang berbeda. Bu'ulolo (2024) menggunakan normalisasi dalam penerapan K-Nearest Neighbor untuk calon penerima Kartu Indonesia Pintar Kuliah, dan pendekatan tersebut diadopsi dalam penelitian ini.

$$x' = (x - x_{min}) / (x_{max} - x_{min})$$

Transformasi diterapkan pada atribut prediktor sebelum data dibagi dan digunakan pada perhitungan jarak.

Confusion Matrix dan Metrik Evaluasi

Confusion matrix mencatat prediksi benar dan salah pada masing-masing kelas. Dari matriks ini dihitung accuracy, precision, recall, dan F1-score. Accuracy menyatakan proporsi prediksi benar secara keseluruhan, tetapi pada dataset tidak seimbang metrik tersebut perlu dibaca bersama recall setiap kelas. Iskandar (2022) menempatkan evaluasi model sebagai bagian penting agar sistem pendukung keputusan tidak hanya menghasilkan label, tetapi juga dapat dinilai reliabilitasnya.

METODE PENELITIAN

Penelitian menggunakan data pendaftar Kartu Indonesia Pintar Kuliah Universitas Dehasen Bengkulu tahun 2025 sebanyak 665 record. Data mencakup atribut sosial ekonomi dan akademik, seperti keterdaftaran pada basis bantuan, pekerjaan dan penghasilan orang tua, jumlah tanggungan, kondisi rumah, listrik, tanah, air, prestasi, serta label status kelayakan. Implementasi dilakukan menggunakan Python pada Google Colaboratory dengan pustaka Pandas dan Scikit-Learn.

Tabel 1. Atribut Prediktor yang Digunakan

No	Atribut	Kelompok Informasi
1	dtks	Status basis bantuan
2	p3ke	Kondisi ekonomi
3	pekerjaan_ayah	Pekerjaan orang tua
4	penghasilan_ayah	Pendapatan orang tua
5	pekerjaan_ibu	Pekerjaan orang tua
6	penghasilan_ibu	Pendapatan orang tua
7	tanggungan	Beban keluarga
8	rumah	Kondisi tempat tinggal
9	listrik	Fasilitas rumah tangga
10	tanah	Kepemilikan/aset
11	air	Fasilitas dasar
12	prestasi	Data akademik/nonakademik

Tabel 2. Pipeline Pengolahan Data dan Klasifikasi

Tahap	Fungsi
Import dataset	Membaca 665 data dari berkas Excel
Data cleaning	Memeriksa missing value dan duplikasi
Data selection	Menghapus atribut identitas yang tidak relevan
Transformation	Mengubah data kategorikal menjadi numerik
Normalisasi	Menyetarakan skala atribut ke rentang 0–1
Pembagian data	532 training dan 133 testing
Klasifikasi	Menguji K=3, 5, 7, dan 9
Evaluasi	Menghitung accuracy, precision, recall, dan F1-score

Tahap preprocessing dimulai dari pemeriksaan missing value dan duplikasi. Atribut identitas yang tidak relevan terhadap proses klasifikasi dihapus pada data selection. Data kategorikal selanjutnya diubah menjadi numerik melalui label encoding. Seluruh atribut prediktor dinormalisasi menggunakan Min-Max agar perhitungan jarak Euclidean tidak didominasi oleh atribut dengan rentang nilai yang lebih besar.

Dataset kemudian dibagi menjadi data training 80% atau 532 record dan data testing 20% atau 133 record menggunakan random_state=42. Pada data yang telah diproses, K-Nearest Neighbor diuji dengan K=3, K=5, K=7, dan K=9. Untuk setiap data testing, sistem menghitung jarak Euclidean terhadap data training, mengurutkan jarak, mengambil K tetangga terdekat, dan menentukan kelas berdasarkan voting mayoritas.

Evaluasi model menggunakan confusion matrix untuk setiap nilai K. Metrik weighted accuracy, precision, recall, dan F1-score dihitung untuk membandingkan performa antar-K. Nilai K dengan accuracy tertinggi dipilih sebagai konfigurasi terbaik pada eksperimen ini, tetapi analisis tambahan dilakukan terhadap distribusi kelas dan recall kelas Layak untuk menghindari interpretasi yang terlalu bergantung pada accuracy agregat.

Pembagian data menggunakan random_state=42 agar eksperimen dapat direproduksi. Namun, pembagian tidak menggunakan stratifikasi kelas. Karena proporsi kelas Layak lebih kecil, komposisi kelas pada data testing berpotensi berbeda dari proporsi populasi dan dapat memengaruhi stabilitas estimasi performa. Keterbatasan ini dipertimbangkan pada pembahasan dan menjadi dasar rekomendasi penggunaan stratified split serta cross-validation pada penelitian lanjutan.

Pengujian fungsional dilakukan dengan black-box testing terhadap delapan tahap sistem: import dataset, data cleaning, data selection, transformasi data, normalisasi, pembagian data, klasifikasi K-Nearest Neighbor, dan evaluasi model. Setiap tahap dinilai berhasil apabila keluaran yang dihasilkan sesuai dengan tujuan proses yang telah dirancang.

HASIL DAN PEMBAHASAN

Hasil

Sistem berhasil membaca 665 data, menjalankan preprocessing, membagi data menjadi 532 training dan 133 testing, serta menghasilkan klasifikasi untuk empat nilai K. Seluruh delapan fungsi yang diuji melalui black-box testing memperoleh status berhasil, yang berarti pipeline dapat dijalankan dari import dataset hingga penyajian metrik evaluasi.


Tabel 3. Hasil Pengujian Black-Box Pipeline

No	Fitur	Status
1	Import dataset	Berhasil
2	Data cleaning	Berhasil
3	Data selection	Berhasil
4	Data transformation	Berhasil
5	Normalisasi data	Berhasil
6	Pembagian data	Berhasil
7	Klasifikasi K-Nearest Neighbor	Berhasil
8	Evaluasi model	Berhasil

Distribusi target menunjukkan ketidakseimbangan yang jelas. Dari 665 data, 180 record atau 27,07% berstatus Layak, sedangkan 485 record atau 72,93% berstatus Tidak Layak.

Gambar 1. Distribusi Kelas Kelayakan pada Dataset

Diagram Donat Status Kelayakan Calon Penerima KIP Kuliah


Tabel 4. Distribusi Status Kelayakan

Status	Jumlah	Persentase
Layak	180	27,07%
Tidak Layak	485	72,93%
Total	665	100%


Hasil pengujian menunjukkan bahwa accuracy meningkat dari K=3 ke K=7, kemudian sedikit turun pada K=9. Nilai tertinggi diperoleh pada K=7 dengan accuracy 63,91%. Namun, precision weighted pada konfigurasi ini 53,90% dan F1-score 57,61%, sehingga peningkatan accuracy tidak diikuti peningkatan seluruh metrik.

Tabel 5. Perbandingan Performa K-Nearest Neighbor

K	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
3	60,15	57,79	60,15	58,84
5	61,65	57,12	61,65	58,93
7	63,91	53,90	63,91	57,61
9	63,16	53,45	63,16	57,15

Tabel 6. Ringkasan Confusion Matrix untuk Seluruh Nilai K

K	Layak→Layak	Layak→Tidak Layak	Tidak Layak→Layak	Tidak Layak→Tidak Layak
3	8	30	23	72
5	6	32	19	76
7	2	36	12	83
9	2	36	13	82

Gambar 2. Perbandingan Accuracy Berdasarkan Nilai K

Confusion matrix K=7 menunjukkan hanya 2 dari 38 data aktual Layak pada data testing yang diprediksi Layak, sedangkan 36 diprediksi Tidak Layak. Pada kelas aktual Tidak Layak, 83 dari 95 data diprediksi benar dan 12 diprediksi Layak. Pola ini menghasilkan recall kelas Layak sekitar 5% dan recall kelas Tidak Layak sekitar 87%.

Tabel 7. Confusion Matrix pada K = 7

Status Aktual	Prediksi Layak	Prediksi Tidak Layak
Layak	2	36
Tidak Layak	12	83

Pembahasan

Accuracy terbaik pada $K=7$ menunjukkan bahwa penambahan jumlah tetangga dari $K=3$ dan $K=5$ membantu menstabilkan keputusan terhadap noise lokal. Ketika K dinaikkan menjadi 9, accuracy sedikit menurun menjadi 63,16%, yang menandakan bahwa tetangga yang terlalu banyak mulai membuat keputusan menjadi lebih umum. Pola ini konsisten dengan karakteristik K-Nearest Neighbor: nilai K kecil lebih sensitif terhadap variasi lokal, sedangkan K terlalu besar dapat mengurangi kemampuan menangkap struktur spesifik data.

Namun, temuan paling penting bukan angka accuracy 63,91%, melainkan ketimpangan performa antar-kelas. Karena kelas Tidak Layak mendominasi 72,93% dataset, voting tetangga lebih sering dikelilingi contoh kelas mayoritas. Akibatnya, model memperoleh banyak prediksi benar pada kelas Tidak Layak tetapi gagal mengenali sebagian besar calon yang benar-benar Layak. Situasi ini menjelaskan mengapa accuracy masih berada di atas 60% sementara recall kelas Layak hanya sekitar 5%.

Perbandingan dengan Purwanto dan Nugroho (2023), yang melaporkan accuracy sangat tinggi pada dataset penerima beasiswa, memperlihatkan bahwa performa K-Nearest Neighbor sangat kontekstual. Perbedaan kualitas atribut, jumlah data, distribusi kelas, dan aturan label dapat menghasilkan performa yang jauh berbeda. Karena itu, penelitian ini memberikan nilai ilmiah justru melalui pelaporan keterbatasan dan tidak menggeneralisasikan hasil dari studi sebelumnya ke data Universitas Dehasen Bengkulu.

Normalisasi Min-Max diperlukan agar atribut beragam memiliki kontribusi jarak yang sebanding, sejalan dengan Bu'ulolo (2024). Namun, normalisasi tidak menyelesaikan masalah ketidakseimbangan kelas. Model masih menggunakan mayoritas tetangga tanpa bobot atau mekanisme kompensasi kelas, sehingga representasi kelas Layak yang lebih sedikit tetap menjadi kendala utama.

Kebaruan logis penelitian ini adalah menunjukkan bahwa sistem seleksi berbasis K-Nearest Neighbor dapat berjalan secara otomatis dan konsisten, tetapi accuracy agregat tidak cukup untuk menilai kelayakannya sebagai alat seleksi. Dalam konteks bantuan pendidikan, false negative pada kelas Layak perlu mendapat perhatian khusus karena dapat menyisihkan kandidat yang sebenarnya memenuhi kriteria. Oleh sebab itu, sistem lebih aman digunakan untuk penyaringan awal yang diikuti verifikasi manusia, bukan sebagai keputusan final otomatis.

Pada $K=3$, model menghasilkan 8 prediksi benar untuk kelas Layak dan 72 prediksi benar untuk kelas Tidak Layak, tetapi masih terdapat 30 data Layak yang bergeser ke kelas Tidak Layak serta 23 data Tidak Layak yang diprediksi Layak. Ketika K dinaikkan menjadi 5, jumlah prediksi benar kelas Tidak Layak meningkat menjadi 76, sedangkan prediksi benar kelas Layak turun menjadi 6. Pola tersebut menunjukkan bahwa kenaikan K mulai memperkuat dominasi kelas mayoritas meskipun accuracy agregat meningkat dari 60,15% menjadi 61,65%.

Pada $K=7$, accuracy mencapai titik tertinggi 63,91% karena prediksi benar kelas Tidak Layak meningkat menjadi 83. Namun, hanya 2 data Layak yang dikenali dengan benar. Pada $K=9$, jumlah prediksi benar kelas Layak tetap 2 dan prediksi benar kelas Tidak Layak sedikit turun menjadi 82, sehingga accuracy menjadi 63,16%. Perubahan ini memperlihatkan trade-off antara stabilitas keputusan dan kemampuan mempertahankan sensitivitas terhadap pola kelas minoritas. K yang lebih besar tidak otomatis meningkatkan kemampuan mengenali calon yang layak.

Dari perspektif seleksi beasiswa, kesalahan klasifikasi memiliki makna operasional yang tidak simetris. False negative pada kelas Layak dapat menyebabkan calon yang seharusnya diprioritaskan tidak masuk ke daftar pemeriksaan awal, sedangkan false positive dapat menambah beban verifikasi lanjutan. Karena itu, evaluasi model sebaiknya memberi perhatian pada recall kelas Layak dan bukan hanya weighted average. Penggunaan threshold atau pembobotan kelas pada algoritma lain dapat menjadi alternatif untuk mengendalikan risiko tersebut.

Peningkatan performa dapat diarahkan pada penanganan imbalance menggunakan oversampling seperti Synthetic Minority Over-sampling Technique atau undersampling, pembagian data secara stratified, seleksi fitur, dan cross-validation.

Selain itu, perbandingan dengan Naive Bayes, Decision Tree, atau Support Vector Machine diperlukan untuk mengetahui apakah struktur data lebih sesuai dengan algoritma lain. Rekomendasi tersebut tetap mempertahankan prinsip bahwa hasil model harus dinilai berdasarkan kemampuan mengenali kedua kelas, bukan hanya accuracy keseluruhan.

KESIMPULAN DAN SARAN

Kesimpulan

K-Nearest Neighbor berhasil diterapkan pada 665 data calon penerima Kartu Indonesia Pintar Kuliah melalui tahapan cleaning, selection, label encoding, normalisasi Min-Max, pembagian 532 data training dan 133 data testing, serta pengujian K=3, 5, 7, dan 9 dengan jarak Euclidean. Accuracy tertinggi diperoleh pada K=7 sebesar 63,91%, dengan precision 53,90%, recall 63,91%, dan F1-score 57,61%. Seluruh delapan fungsi pipeline lulus black-box testing. Meskipun demikian, dataset yang tidak seimbang menyebabkan model sangat bias terhadap kelas Tidak Layak; recall kelas Layak pada K=7 hanya sekitar 5%. Oleh karena itu, sistem dapat membantu seleksi awal secara lebih cepat dan konsisten, tetapi hasilnya belum memadai sebagai dasar keputusan final tanpa verifikasi tambahan. Keterbatasan utama penelitian terletak pada imbalance kelas, penggunaan satu pembagian train-test, dan belum dilakukannya seleksi fitur maupun perbandingan algoritma.

Saran

Penelitian berikutnya disarankan menerapkan teknik oversampling atau undersampling, stratified split, cross-validation, dan seleksi fitur untuk meningkatkan kemampuan model mengenali kelas Layak. Pengujian metrik jarak lain serta perbandingan dengan Naive Bayes, Decision Tree, dan Support Vector Machine juga perlu dilakukan. Jumlah dan cakupan data sebaiknya diperluas ke beberapa tahun agar model lebih representatif. Untuk implementasi operasional, keluaran klasifikasi sebaiknya digunakan sebagai rekomendasi penyaringan awal yang tetap dikonfirmasi oleh tim seleksi berdasarkan dokumen dan kebijakan resmi.

DAFTAR PUSTAKA

- Arfyanti, I., et al. (2022). Analisis penentuan penerima bantuan sosial menggunakan metode klasifikasi. *Jurnal Sistem Informasi dan Teknologi*, 5(2), 101–110.
- Astuti, R. (2023). Implementasi kebijakan pendidikan tinggi dalam meningkatkan akses masyarakat kurang mampu. *Jurnal Pendidikan Indonesia*, 12(1), 45–53.
- Bu'ulolo, E. (2024). Algoritma K-Nearest Neighbor dengan normalisasi min-max untuk menentukan calon penerima KIP Kuliah. *Jurnal Teknologi Informasi*, 8(1), 15–23.
- Iskandar, D. (2022). Sistem pendukung keputusan dalam seleksi penerima bantuan sosial. *Jurnal Komputer dan Aplikasi*, 6(1), 21–29.
- Purwanto, A., & Nugroho, H. W. (2023). Analisa perbandingan kinerja algoritma C4.5 dan K-Nearest Neighbor untuk klasifikasi penerima beasiswa. *Jurnal Ilmu Komputer*, 9(2), 88–96.
- Romadhon, A., dkk. (2023). Evaluasi program bantuan pendidikan tinggi di Indonesia. *Jurnal Kebijakan Pendidikan*, 11(2), 120–128.
- Suganda, G., dkk. (2022). Penentuan penerima beasiswa KIP Kuliah menggunakan metode klasifikasi. *Jurnal Sistem Cerdas*, 4(1), 55–63.
- Wijaya, A. S., dkk. (2024). Implementation of the Smart Indonesia Card scholarship acceptance using the K-Nearest Neighbor method. *International Journal of Computer Science*, 15(1), 10–18