



Explainable AI pada Seleksi Beasiswa KIP Berbasis *Machine Learning* di Universitas Adzkia

Muhammad Thoriq¹, Fajar Maulana², Sakinah Ali Pitchay³, Farida Ridzuan⁴, Wega Ramanda⁵

^{1,2,5}Informatika, Universitas Adzkia

^{1,3,4}Faculty of Science and Technology, Universiti Sains Islam Malaysia, Negeri Sembilan, Malaysia

^{3,4}Cybersecurity & Systems Research Unit, Universiti Sains Islam Malaysia, Negeri Sembilan, Malaysia

¹thoriq.if@adzkia.ac.id, ²fajar@adzkia.ac.id, ³sakinah.ali@usim.edu.my, ⁴farida@usim.edu.my,

⁵ramandawega29@gmail.com.

Abstract

The Kartu Indonesia Pintar Kuliah (KIP-K) scholarship program is designed to expand access to higher education for students from economically disadvantaged families. However, the increasing number of applicants and the complexity of socio-economic verification often make the selection process challenging for universities. This study proposes a machine learning-based approach integrated with Explainable Artificial Intelligence (XAI) to support scholarship eligibility recommendations by using real selection data from Universitas Adzkia. The dataset consists of 829 applicants with socio-economic attributes that include P3KE status, parental income, number of dependents, parents' occupation and school origin. A Random Forest classifier was employed to build the prediction model while validation model was conducted using 5-fold cross-validation and evaluation metrics that include accuracy, precision, recall, F1-score and confusion matrix. Because the dataset is imbalanced, threshold optimization was applied to improve the detection of eligible applicants. To enhance model transparency, SHapley Additive exPlanations (SHAP) were used to interpret model predictions both globally and locally. The results show that socio-economic factors such as P3KE status, number of dependents, parental income and school location significantly influence scholarship eligibility predictions. The integration of machine learning and SHAP enables not only predictive decision support but also transparent explanation of individual predictions. This approach can support more objective, transparent and data-driven scholarship selection processes in higher education institutions.

Keywords: machine learning, scholarship selection, explainable artificial intelligence, random forest, shap

Abstrak

Program Kartu Indonesia Pintar Kuliah (KIP-K) bertujuan memperluas akses pendidikan tinggi bagi mahasiswa dari keluarga kurang mampu. Namun, peningkatan jumlah pendaftar serta kompleksitas verifikasi kondisi sosial ekonomi menimbulkan tantangan dalam menjaga objektivitas dan transparansi proses seleksi. Penelitian ini mengusulkan pendekatan berbasis *machine learning* yang terintegrasi dengan *Explainable Artificial Intelligence* (XAI) untuk mendukung rekomendasi kelayakan penerima beasiswa menggunakan data riil seleksi Universitas Adzkia. Dataset terdiri dari 829 pendaftar dengan variabel sosial ekonomi seperti status P3KE, penghasilan orang tua, jumlah tanggungan keluarga, pekerjaan orang tua serta asal sekolah. Model klasifikasi dibangun menggunakan algoritma *Random Forest* dan divalidasi dengan *5-fold cross validation* menggunakan *accuracy matrix*, *precision*, *recall*, *F1-score* dan *confusion matrix*. Karena dataset tidak seimbang, dilakukan *threshold optimization* yang menghasilkan nilai *F1-score* terbaik sebesar 0,37 pada *threshold* 0,05 dengan akurasi sebesar 0,53. Untuk meningkatkan transparansi model digunakan metode *SHapley Additive exPlanations* (SHAP) untuk interpretasi global dan lokal. Hasil penelitian menunjukkan bahwa faktor sosial ekonomi seperti status P3KE, jumlah tanggungan, penghasilan orang tua serta wilayah asal sekolah merupakan determinan utama dalam prediksi kelayakan penerima beasiswa. Integrasi *machine learning* dan XAI memungkinkan sistem seleksi yang lebih objektif, transparan dan dapat dijelaskan.

Kata kunci: machine learning, seleksi beasiswa, explainable artificial intelligence, random forest, SHAP

© 2026 Author
Creative Commons Attribution 4.0 International License



1. Pendahuluan

Program Kartu Indonesia Pintar Kuliah (KIP-K) merupakan salah satu upaya pemerintah Indonesia untuk memperluas akses pendidikan tinggi bagi mahasiswa dari keluarga kurang mampu. Dalam implementasinya, proses seleksi penerima beasiswa menghadapi tantangan berupa peningkatan jumlah pendaftar, keterbatasan kuota, serta kompleksitas variabel sosial ekonomi yang harus diverifikasi. Kondisi ini menuntut adanya pendekatan berbasis data untuk meningkatkan objektivitas dan efisiensi dalam pengambilan keputusan seleksi [1].

Seiring dengan perkembangan *Educational Data Mining*, berbagai metode *machine learning* telah digunakan dalam seleksi beasiswa untuk meningkatkan akurasi dan konsistensi keputusan. Algoritma seperti *Random Forest*, *Logistic Regression*, *Classification Tree*, dan *XGBoost* telah menunjukkan performa yang baik dalam memodelkan data berbasis variabel sosial ekonomi [1]–[5]. Studi sebelumnya di Universitas Adzkia menunjukkan bahwa *Random Forest* mampu mengungguli *Naïve Bayes* dalam prediksi kelulusan seleksi KIP, terutama pada data yang tidak seimbang (*imbalanced dataset*) [1]. Namun, sebagian besar penelitian masih berfokus pada performa prediktif tanpa memberikan penjelasan yang memadai terhadap hasil keputusan model.

Permasalahan utama dari pendekatan tersebut adalah rendahnya transparansi model, khususnya pada algoritma yang bersifat *black-box* seperti *Random Forest* dan *XGBoost* [8], [9]. Dalam konteks seleksi bantuan pendidikan, transparansi menjadi aspek penting karena setiap keputusan harus dapat dipertanggungjawabkan secara rasional. Selain itu, kesalahan klasifikasi seperti *false negative*, yaitu kandidat yang sebenarnya layak tetapi diprediksi tidak layak, memiliki implikasi sosial yang lebih besar dibandingkan kesalahan sebaliknya. Kondisi ini menunjukkan bahwa evaluasi model tidak hanya harus mempertimbangkan akurasi, tetapi juga sensitivitas terhadap kelas minoritas [7].

Untuk mengatasi keterbatasan tersebut, berkembang pendekatan *Explainable Artificial Intelligence* (XAI) yang bertujuan meningkatkan interpretabilitas model pembelajaran mesin. Salah satu metode yang banyak digunakan adalah *SHapley Additive exPlanations* (SHAP), yang mampu memberikan atribusi kontribusi setiap fitur terhadap hasil prediksi model baik secara global maupun lokal [11], [12]. Penerapan SHAP dalam bidang pendidikan telah menunjukkan kemampuannya dalam menjelaskan determinan keputusan model secara transparan [4], [6]. Namun, penelitian XAI pada seleksi KIP masih terbatas, terutama yang menggunakan data sintetik sehingga belum mencerminkan kondisi data riil [5].

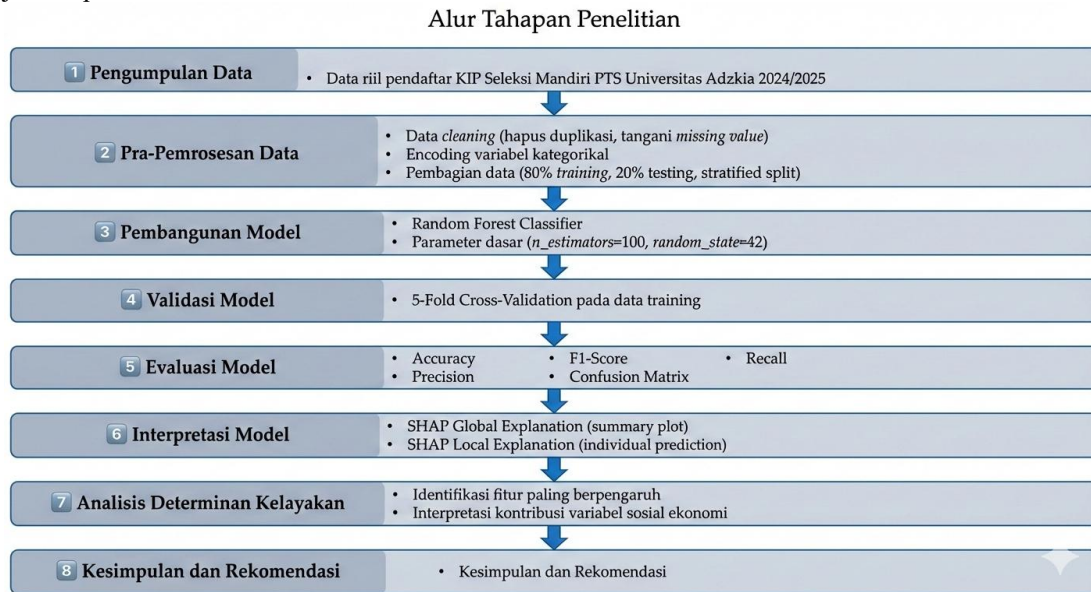
Berdasarkan tinjauan tersebut, terdapat celah penelitian pada integrasi model klasifikasi berbasis data riil dengan pendekatan *explainable machine learning* yang komprehensif. Studi sebelumnya telah mengidentifikasi *Random Forest* sebagai model yang optimal dalam seleksi KIP di Universitas Adzkia [1], namun belum mengimplementasikan metode SHAP untuk menjelaskan keputusan model pada tingkat individu.

Oleh karena itu, penelitian ini mengusulkan integrasi model *Random Forest* dengan metode SHAP pada data riil seleksi KIP Universitas Adzkia. Penelitian ini berkontribusi dalam mengembangkan model seleksi beasiswa yang tidak hanya optimal secara prediktif, tetapi juga transparan dan dapat dijelaskan. Melalui analisis global dan lokal berbasis SHAP, penelitian ini mengidentifikasi determinan utama kelulusan serta menyediakan kerangka kerja seleksi beasiswa berbasis kecerdasan buatan yang lebih objektif, transparan, dan dapat direplikasi.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental untuk membangun model klasifikasi kelayakan penerima beasiswa KIP berbasis machine learning serta menginterpretasikan hasilnya menggunakan pendekatan *Explainable Artificial Intelligence* (XAI). Tahapan penelitian meliputi pengumpulan data, prapemrosesan,

pembangunan model, validasi, evaluasi, dan interpretasi model. Alur tahapan penelitian secara sistematis ditunjukkan pada Gambar 1.



Gambar 1. Alur Tahapan Penelitian

2.1 Pengumpulan dan Deskripsi Data

Data yang digunakan merupakan data riil pendaftar KIP Seleksi Mandiri PTS Universitas Adzkia Tahun Akademik 2024/2025. Dataset memuat variabel sosial ekonomi dan akademik yang digunakan sebagai dasar pengambilan keputusan seleksi.

Variabel yang dianalisis meliputi Status DTKS, Status P3KE (desil kesejahteraan), Kab/Kota Sekolah, Jenis Kelamin, Pekerjaan Ayah dan Ibu, Penghasilan Ayah dan Ibu, Status Orang Tua, Jumlah Tanggungan, Pilihan Program Studi, serta Status Diterima/Tidak Diterima sebagai variabel target.

Penggunaan variabel sosial ekonomi dalam pemodelan seleksi bantuan pendidikan sejalan dengan pendekatan *Educational Data Mining* yang memanfaatkan data administratif untuk mendukung pengambilan keputusan pendidikan [13]. Studi klasifikasi seleksi KIP sebelumnya juga menunjukkan bahwa pendekatan machine learning efektif dalam meningkatkan objektivitas seleksi dibandingkan dengan metode manual [1], [3].

Tabel 1. Deskripsi Variabel Penelitian

Variabel	Tipe Data	Keterangan
Status P3KE	Kategorikal	Desil kesejahteraan
Penghasilan Ayah	Numerik	Pendapatan bulanan (Rp)
Penghasilan Ibu	Numerik	Pendapatan bulanan (Rp)
Jumlah Tanggungan	Numerik	Jumlah anggota keluarga
Kab/Kota Sekolah	Kategorikal	Lokasi asal sekolah
Pilihan Prodi	Kategorikal	Program studi yang dipilih
Diterima/Tidak Diterima	Biner	Target klasifikasi

2.2 Pra-Pemrosesan Data

Tahap pra-pemrosesan data dilakukan untuk memastikan kualitas data sebelum digunakan dalam proses pemodelan *machine learning*. Proses ini meliputi pembersihan data, transformasi variabel serta pembagian dataset menjadi data pelatihan dan data pengujian.

Pada tahap awal dilakukan pembersihan data (*data cleaning*) untuk menghilangkan nilai yang tidak konsisten serta menyesuaikan format variabel numerik dan kategorikal. Variabel penghasilan orang tua yang sebelumnya

berbentuk rentang nilai diubah menjadi nilai numerik agar dapat diproses oleh algoritma pembelajaran mesin. Nilai yang tidak tersedia juga disesuaikan agar tetap konsisten dengan distribusi data yang ada [14].

Selanjutnya, variabel kategorikal seperti Status P3KE, Status DTKS, Kab/Kota Sekolah, Jenis Kelamin, serta pilihan program studi dikonversi menggunakan teknik *One-Hot Encoding* sehingga dapat direpresentasikan dalam bentuk numerik. Transformasi ini diperlukan karena sebagian besar algoritma *machine learning* hanya dapat memproses input dalam bentuk numerik.

Setelah proses transformasi selesai, dataset dibagi menjadi dua bagian, yaitu data pelatihan (*training set*) sebesar 80% dan data pengujian (*test set*) sebesar 20%. Pembagian data dilakukan menggunakan pendekatan *stratified split* untuk menjaga proporsi distribusi kelas tetap seimbang antara data pelatihan dan data pengujian. Pendekatan ini umumnya digunakan dalam penelitian prediksi berbasis data pendidikan untuk menjaga stabilitas model yang dihasilkan [15].

2.3 Pembangunan Model

Model klasifikasi yang digunakan dalam penelitian ini adalah *Random Forest Classifier*. *Random Forest* merupakan metode *ensemble learning* yang menggabungkan banyak pohon keputusan (*decision tree*) untuk menghasilkan prediksi yang lebih stabil dan akurat. Metode ini dikenal memiliki kemampuan yang baik dalam menangani data dengan dimensi yang tinggi serta mampu mengurangi risiko *overfitting* dibandingkan dengan model pohon keputusan tunggal.

Pemilihan *Random Forest* dalam penelitian ini didasarkan pada hasil penelitian sebelumnya yang menunjukkan bahwa metode ini mampu memberikan performa klasifikasi yang lebih baik dibandingkan dengan metode *Naive Bayes* dalam seleksi penerima KIP di Universitas Adzkia [1]. Selain itu, *Random Forest* juga relatif robust terhadap data yang tidak seimbang dan dapat menangani kombinasi variabel numerik dan kategorikal secara efektif.

Dalam penelitian ini, model *Random Forest* dibangun menggunakan parameter utama berupa jumlah pohon keputusan ($n_{estimators}$) sebanyak 100 serta random state sebesar 42 untuk memastikan reproduktibilitas eksperimen. Proses pelatihan model dilakukan menggunakan data training yang telah melalui tahap prapemrosesan sebelumnya.

2.4 Validasi Model

Untuk memastikan stabilitas model yang dihasilkan, proses validasi dilakukan menggunakan teknik *k-Fold Cross Validation* dengan nilai $k = 5$. Metode ini bekerja dengan membagi data pelatihan menjadi lima bagian, di mana empat bagian digunakan untuk melatih model dan satu bagian digunakan untuk proses validasi. Proses ini dilakukan secara bergantian hingga seluruh bagian data digunakan sebagai data validasi.

Evaluasi performa model dilakukan menggunakan beberapa metrik klasifikasi yang umum digunakan dalam penelitian *machine learning*, yaitu *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Selain itu, digunakan juga *Confusion Matrix* untuk menganalisis distribusi kesalahan klasifikasi antara kelas yang diprediksi dan kelas sebenarnya.

Dalam konteks seleksi bantuan pendidikan, perhatian khusus diberikan pada metrik *recall* pada kelas penerima beasiswa. Hal ini disebabkan oleh kesalahan klasifikasi yang menyebabkan kandidat yang sebenarnya layak tidak terpilih (*false negative*) dapat memiliki implikasi sosial yang lebih besar dibandingkan dengan kesalahan sebaliknya [16].

Selain evaluasi menggunakan threshold standar, penelitian ini juga melakukan penyesuaian threshold probabilitas untuk meningkatkan sensitivitas model terhadap kelas minoritas. Pendekatan ini bertujuan untuk meningkatkan keseimbangan antara *precision* dan *recall* dalam proses klasifikasi.

2.5 Interpretasi SHAP

Meskipun *Random Forest* mampu memberikan performa prediksi yang baik, model ini termasuk dalam kategori *black-box* model karena proses pengambilan keputusan di dalamnya tidak mudah diinterpretasikan secara langsung. Oleh karena itu, penelitian ini menggunakan pendekatan *Explainable Artificial Intelligence* (XAI) untuk meningkatkan transparansi model.

Metode interpretasi yang digunakan adalah *SHapley Additive exPlanations* (SHAP). SHAP merupakan metode interpretasi berbasis teori permainan kooperatif yang menghitung kontribusi setiap fitur terhadap hasil prediksi model. Pendekatan ini memungkinkan analisis yang lebih transparan mengenai faktor-faktor yang memengaruhi keputusan model [11].

Dalam penelitian ini, analisis SHAP dilakukan pada dua tingkat interpretasi. Pertama adalah analisis global, yaitu untuk mengidentifikasi fitur-fitur yang paling berpengaruh terhadap keputusan model secara keseluruhan. Kedua adalah analisis lokal, yaitu untuk menjelaskan kontribusi masing-masing variabel terhadap prediksi pada individu tertentu.

Pendekatan ini memungkinkan proses seleksi penerima beasiswa tidak hanya menghasilkan prediksi klasifikasi, tetapi juga memberikan penjelasan mengenai faktor-faktor yang memengaruhi keputusan tersebut. Penggunaan metode interpretasi seperti SHAP semakin banyak digunakan dalam penelitian pendidikan berbasis machine learning untuk meningkatkan transparansi dan akuntabilitas sistem pengambilan keputusan [8].

3. Hasil dan Pembahasan

3.1 Deskripsi Dataset

Dataset yang digunakan dalam penelitian ini merupakan data riil pendaftar program Kartu Indonesia Pintar Kuliah (KIP-K) pada seleksi mandiri Perguruan Tinggi Swasta Universitas Adzka tahun akademik 2024/2025. Dataset memuat informasi sosial ekonomi dan latar belakang pendidikan calon mahasiswa yang digunakan sebagai dasar dalam proses seleksi penerima beasiswa.

Setelah proses pra-pemrosesan data dilakukan, dataset yang digunakan dalam penelitian ini terdiri dari 829 data pendaftar. Variabel target dalam penelitian ini adalah status kelulusan seleksi yang terdiri dari dua kelas, yaitu diterima dan tidak diterima sebagai penerima beasiswa KIP. Distribusi kelas pada dataset ditunjukkan pada Tabel 2.

Tabel 2. Distribusi Kelas Dataset

Status Seleksi	Jumlah Data
Tidak diterima	634
Diterima	195
Total	829


Berdasarkan distribusi tersebut terlihat bahwa jumlah data pada kedua kelas tidak seimbang, dimana jumlah kandidat yang tidak diterima lebih besar dibandingkan kandidat yang diterima. Kondisi ini menunjukkan bahwa dataset memiliki karakteristik *imbalanced dataset*, yaitu distribusi kelas yang tidak merata.

Dalam konteks klasifikasi *machine learning*, ketidakseimbangan distribusi kelas dapat memengaruhi performa model, terutama dalam kemampuan model untuk mendeteksi kelas minoritas. Model klasifikasi cenderung lebih mudah memprediksi kelas mayoritas dibandingkan dengan kelas minoritas, sehingga diperlukan evaluasi model yang tidak hanya berfokus pada akurasi, tetapi juga mempertimbangkan metrik lain seperti *precision*, *recall*, dan *F1-score* [7].

Distribusi kelas seperti ini juga umum ditemukan dalam penelitian yang berkaitan dengan seleksi bantuan pendidikan atau prediksi kinerja akademik, di mana jumlah individu yang memenuhi kriteria tertentu sering kali lebih sedikit dibandingkan populasi secara keseluruhan [2].

3.2 Evaluasi Model Random Forest

Kinerja model *Random Forest* dievaluasi menggunakan *confusion matrix* untuk menganalisis distribusi hasil klasifikasi antara prediksi model dan label sebenarnya. *Confusion matrix* dari model yang dihasilkan ditunjukkan pada Gambar 2.



Gambar 2. *Confusion Matrix* Model Random Forest

Berdasarkan *confusion matrix* tersebut, model berhasil mengklasifikasikan 124 data secara benar sebagai tidak diterima (*true negative*) dan 2 data secara benar sebagai diterima (*true positive*). Namun demikian, terdapat 37 data yang sebenarnya diterima tetapi diprediksi tidak diterima (*false negative*) serta 3 data yang sebenarnya tidak diterima tetapi diprediksi diterima (*false positive*).

Hasil ini menunjukkan bahwa model memiliki kemampuan yang cukup baik dalam mengenali kelas mayoritas, yaitu kandidat yang tidak diterima. Namun, kemampuan model dalam mendeteksi kandidat yang diterima masih relatif rendah, yang terlihat dari jumlah *false negative* yang cukup besar. Kondisi ini umumnya terjadi pada dataset yang memiliki distribusi kelas tidak seimbang (*imbalanced dataset*), di mana jumlah data pada kelas mayoritas jauh lebih besar dibandingkan kelas minoritas.

Dalam konteks seleksi bantuan pendidikan, kesalahan klasifikasi berupa *false negative* memiliki implikasi yang penting karena berpotensi menyebabkan kandidat yang sebenarnya layak menerima bantuan tidak terpilih oleh model. Oleh karena itu, evaluasi model tidak hanya mempertimbangkan nilai akurasi, tetapi juga metrik lain seperti *precision*, *recall*, dan *F1-score* untuk memperoleh gambaran performa model secara lebih komprehensif.

3.3 Threshold Optimization

Pada model klasifikasi berbasis probabilitas seperti *Random Forest*, keputusan klasifikasi umumnya menggunakan nilai ambang batas (*threshold*) default sebesar 0,5. Artinya, suatu data akan diklasifikasikan sebagai kelas positif apabila probabilitas prediksi lebih besar atau sama dengan 0,5. Namun, pada dataset dengan

distribusi kelas yang tidak seimbang, penggunaan *threshold* default sering kali menyebabkan model lebih cenderung memprediksi kelas mayoritas dibandingkan kelas minoritas.

Dalam penelitian ini, distribusi kelas menunjukkan ketidakseimbangan antara jumlah kandidat yang diterima dan tidak diterima sebagai penerima beasiswa KIP. Kondisi ini menyebabkan model lebih sering memprediksi kelas mayoritas, yaitu kandidat yang tidak diterima. Akibatnya, kemampuan model dalam mendeteksi kandidat yang benar-benar layak menerima beasiswa menjadi relatif rendah.

Untuk mengatasi permasalahan tersebut, dilakukan proses *threshold optimization*, yaitu dengan menguji beberapa nilai *threshold* probabilitas yang berbeda untuk menentukan nilai ambang yang dapat menghasilkan keseimbangan terbaik antara *precision* dan *recall*. Nilai *threshold* yang diuji berada pada rentang 0,05 hingga 0,50 dengan interval tertentu.

Hasil eksperimen menunjukkan bahwa penggunaan *threshold* yang lebih rendah dibandingkan dengan *threshold* standar mampu meningkatkan kemampuan model dalam mendeteksi kelas minoritas. Berdasarkan pengujian yang dilakukan, nilai *threshold* sebesar 0,05 menghasilkan nilai *F1-score* tertinggi sebesar 0,371 dibandingkan dengan *threshold* lainnya. Hal ini menunjukkan bahwa penyesuaian *threshold* dapat meningkatkan keseimbangan antara *precision* dan *recall* dalam proses klasifikasi.

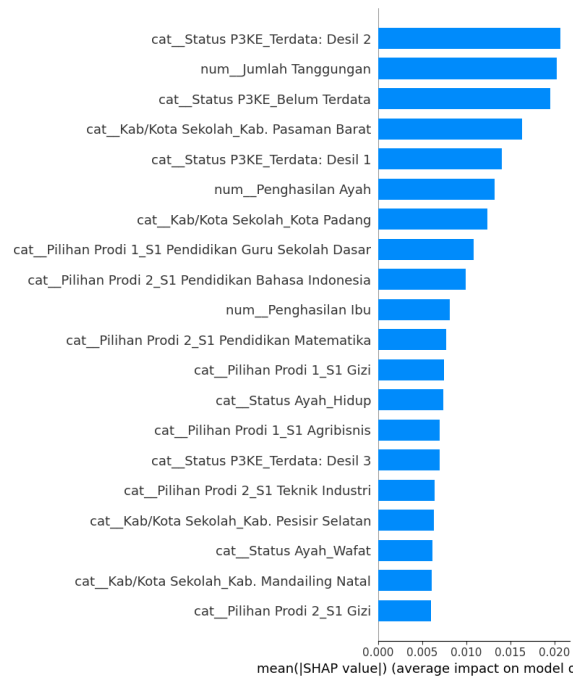
Meskipun penggunaan *threshold* yang lebih rendah menyebabkan penurunan nilai akurasi secara keseluruhan, pendekatan ini dinilai lebih sesuai dalam konteks seleksi bantuan pendidikan. Hal ini disebabkan oleh kesalahan klasifikasi berupa *false negative*, yaitu kandidat yang sebenarnya layak tetapi diprediksi tidak layak, memiliki implikasi sosial yang lebih besar dibandingkan dengan kesalahan klasifikasi sebaliknya.

Pendekatan penyesuaian *threshold* seperti ini juga banyak digunakan dalam penelitian klasifikasi pada dataset tidak seimbang untuk meningkatkan sensitivitas model terhadap kelas minoritas tanpa harus melakukan perubahan pada struktur algoritma yang digunakan. Oleh karena itu, dalam penelitian ini *threshold* yang digunakan pada tahap analisis selanjutnya disesuaikan berdasarkan hasil eksperimen tersebut.

3.4 SHAP Global Explanation

Untuk meningkatkan transparansi model Random Forest, penelitian ini menggunakan pendekatan *Explainable Artificial Intelligence* (XAI) dengan metode *SHapley Additive exPlanations* (SHAP). Metode SHAP memungkinkan interpretasi kontribusi setiap fitur terhadap hasil prediksi model dengan mengukur nilai kontribusi fitur berdasarkan konsep nilai Shapley dari teori permainan kooperatif [11].

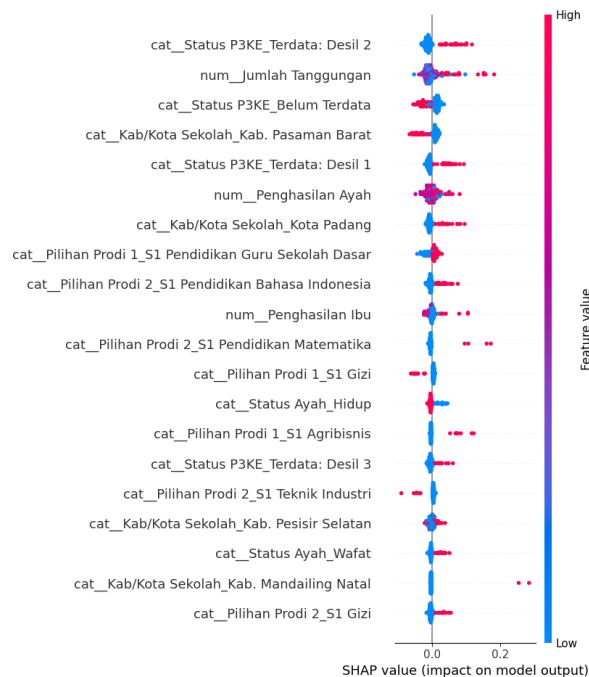
Analisis global dilakukan untuk mengidentifikasi fitur-fitur yang paling berpengaruh terhadap keputusan model secara keseluruhan. Visualisasi hasil interpretasi global menggunakan SHAP *summary plot* ditunjukkan pada Gambar 3.



Gambar 3. SHAP Summary Plot Model Random Forest

Pada SHAP *summary plot*, setiap titik merepresentasikan satu observasi data. Posisi horizontal menunjukkan besarnya kontribusi fitur terhadap prediksi model, sedangkan warna menunjukkan nilai fitur tersebut. Warna merah merepresentasikan nilai fitur yang tinggi, sedangkan warna biru menunjukkan nilai fitur yang rendah. Nilai SHAP positif menunjukkan bahwa fitur tersebut meningkatkan probabilitas prediksi kelas penerima beasiswa, sedangkan nilai negatif menunjukkan kontribusi terhadap kelas tidak diterima.

Berdasarkan hasil visualisasi tersebut, terlihat bahwa beberapa variabel memiliki pengaruh yang lebih dominan terhadap keputusan model dibandingkan variabel lainnya. Untuk mengidentifikasi tingkat kepentingan fitur secara lebih jelas, dilakukan analisis mean absolute SHAP value yang ditunjukkan pada Gambar 4.



Gambar 4. SHAP Feature Importance Model Random Forest

Berdasarkan analisis nilai rata-rata absolut SHAP, fitur yang paling berpengaruh terhadap keputusan model antara lain Status P3KE, Jumlah Tanggungan, Status P3KE Belum Terdata, Kab/Kota Sekolah, serta Penghasilan


Ayah. Hal ini menunjukkan bahwa faktor sosial ekonomi keluarga memiliki kontribusi yang signifikan dalam menentukan kelayakan penerima beasiswa KIP.

Selain faktor ekonomi keluarga, beberapa variabel lain seperti pilihan program studi dan lokasi sekolah asal juga menunjukkan pengaruh terhadap keputusan model. Hal ini mengindikasikan bahwa model tidak hanya mempertimbangkan kondisi ekonomi, tetapi juga karakteristik latar belakang pendidikan calon mahasiswa.

Temuan ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa variabel sosial ekonomi dan kondisi keluarga merupakan determinan penting dalam analisis bantuan pendidikan berbasis data [2], [4]. Dengan menggunakan pendekatan SHAP, kontribusi masing-masing fitur terhadap keputusan model dapat dijelaskan secara transparan sehingga meningkatkan akuntabilitas sistem seleksi berbasis kecerdasan buatan.

3.5 SHAP Local Explanation

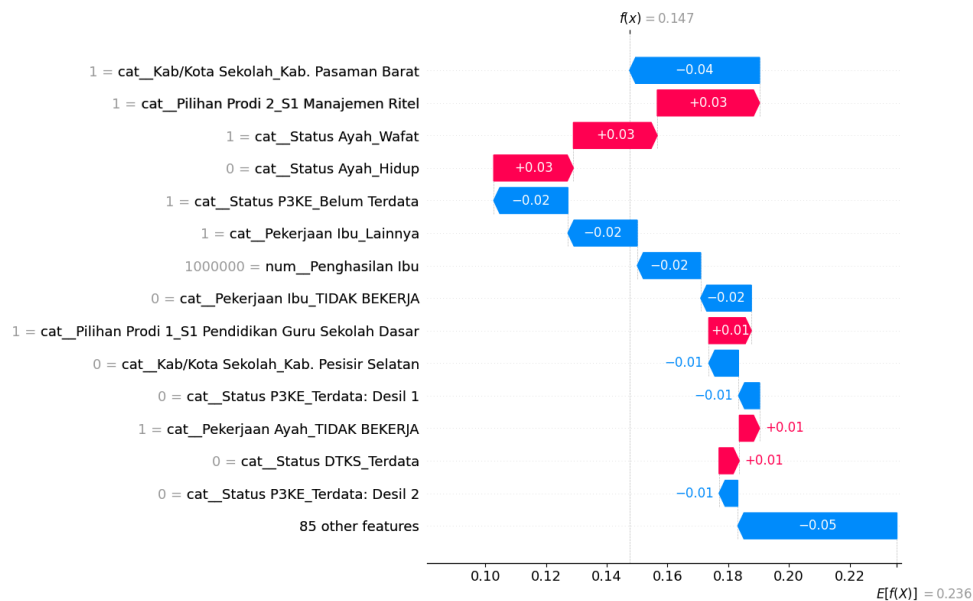
Selain analisis global, penelitian ini juga melakukan interpretasi model pada tingkat individu menggunakan pendekatan SHAP *local explanation*. Analisis ini bertujuan untuk menjelaskan bagaimana setiap fitur memberikan kontribusi terhadap keputusan model pada satu observasi data tertentu. Gambar 5 menunjukkan visualisasi SHAP waterfall plot untuk salah satu mahasiswa yang diprediksi diterima oleh model.



Gambar 5. SHAP Local Explanation pada Kasus Mahasiswa yang Diprediksi Diterima

Pada visualisasi tersebut, nilai $E[f(x)]$ menunjukkan nilai prediksi dasar model sebelum mempertimbangkan kontribusi fitur. Setiap fitur kemudian memberikan kontribusi positif maupun negatif terhadap nilai prediksi akhir $f(x)$. Fitur yang berwarna merah menunjukkan kontribusi yang meningkatkan probabilitas prediksi terhadap kelas tertentu, sedangkan fitur berwarna biru menunjukkan kontribusi yang menurunkan probabilitas prediksi.

Pada kasus ini, beberapa fitur memberikan kontribusi positif terhadap keputusan model, seperti Kab/Kota Sekolah Kota Padang, Penghasilan Ayah, serta Jenis Kelamin. Sebaliknya, fitur seperti Status P3KE Terdata Desil 2 dan Pilihan Program Studi tertentu memberikan kontribusi negatif terhadap probabilitas prediksi. Untuk memberikan gambaran yang lebih komprehensif, Gambar 6 menampilkan contoh interpretasi lokal pada kasus mahasiswa yang diprediksi tidak diterima oleh model.



Gambar 6. SHAP Local Explanation pada Kasus Mahasiswa yang Diprediksi Tidak Diterima

Pada kasus ini terlihat bahwa beberapa fitur memberikan kontribusi negatif yang lebih dominan terhadap nilai prediksi model. Misalnya, fitur Kab/Kota Sekolah Kabupaten Pasaman Barat, Penghasilan Ibu, serta pekerjaan orang tua memberikan kontribusi yang menurunkan probabilitas mahasiswa untuk diklasifikasikan sebagai penerima beasiswa. Sementara itu, beberapa fitur lain seperti Pilihan Program Studi memberikan kontribusi positif namun tidak cukup kuat untuk meningkatkan probabilitas prediksi secara signifikan.

Hasil analisis ini menunjukkan bahwa keputusan model tidak hanya dipengaruhi oleh satu variabel tertentu, tetapi merupakan kombinasi kontribusi dari berbagai fitur sosial ekonomi dan latar belakang calon mahasiswa. Dengan menggunakan pendekatan SHAP, setiap keputusan klasifikasi yang dihasilkan oleh model dapat dijelaskan secara transparan pada tingkat individu, sehingga meningkatkan akuntabilitas sistem pendukung keputusan berbasis machine learning dalam proses seleksi beasiswa.

4. Kesimpulan

Penelitian ini mengusulkan pendekatan berbasis *machine learning* yang terintegrasi dengan *Explainable Artificial Intelligence* (XAI) untuk mendukung rekomendasi kelayakan penerima beasiswa KIP di Universitas Adzkia. Model Random Forest yang digunakan mampu melakukan klasifikasi dengan akurasi sebesar 0,53 serta menghasilkan nilai F1-score terbaik sebesar 0,37 setelah dilakukan *threshold optimization* pada nilai 0,05 untuk meningkatkan sensitivitas terhadap kelas penerima beasiswa. Hasil analisis menunjukkan bahwa model masih dipengaruhi oleh ketidakseimbangan data, namun penyesuaian *threshold* mampu meningkatkan kemampuan deteksi kandidat yang layak. Selain itu, penerapan metode SHAP memungkinkan interpretasi model secara transparan baik secara global maupun lokal, dimana variabel Status P3KE, jumlah tanggungan keluarga, penghasilan orang tua, serta wilayah asal sekolah menjadi faktor utama yang memengaruhi keputusan model. Dengan demikian, pendekatan yang diusulkan tidak hanya memberikan performa prediksi yang memadai, tetapi juga meningkatkan transparansi dan akuntabilitas dalam sistem seleksi beasiswa berbasis data.

Ucapan Terima Kasih [jika ada]

Penulis mengucapkan terima kasih kepada Universitas Adzkia atas dukungan akademik serta pemberian akses terhadap data seleksi Kartu Indonesia Pintar Kuliah (KIP-K) yang digunakan dalam penelitian ini. Dukungan tersebut memungkinkan penelitian ini dilakukan menggunakan data riil sehingga hasil yang diperoleh dapat memberikan kontribusi dalam pengembangan sistem seleksi beasiswa berbasis data di lingkungan perguruan tinggi.

Daftar Rujukan

- [1] M. Thoriq, F. Maulana, and A. Q. Ayun, “Perbandingan Naïve Bayes dan Random Forest pada Seleksi KIP di Universitas Adzka,” *J. Pustaka AI (Pusat Akses Kaji. Teknol. Artif. Intell.*, vol. 5, no. 3, pp. 602–610, 2025.
- [2] H. Aldowah, H. Al-Samarraie, and W. M. Fauzy, “Educational Data Mining for Student Learning Outcomes: A Systematic Review of Machine Learning Applications,” *Comput. Educ.*, vol. 173, p. 104297, 2021.
- [3] U. A. Wizsa and A. Rahmi, “Classification Of KIP-K Scholarship Using Logistic Regression, Classification Trees, and Boosting Based On Decision Support System,” *Mathline J. Mat. dan Pendidik. Mat.*, vol. 10, no. 1, pp. 221–235, 2025.
- [4] M. W. P. Dananjaya, N. N. K. Krisnawijaya, G. H. Prathama, I. G. N. D. Paramartha, and A. W. O. Gama, “Analisis Determinan Karakter Siswa Menggunakan Explainable Machine Learning (SHAP) dan Klasterisasi Profil Sekolah Studi Kasus Rapor Pendidikan Provinsi Bali,” *J. Kridatama Sains dan Teknol.*, vol. 7, no. 02, pp. 936–948, 2025.
- [5] Zulkifli, Rizky Maulana, Muhammad Yasar Al Wafi, and Imam Muslem, “Prediction of KIP Scholarship Eligibility at Universitas Almuslim Using an Explainable Artificial Intelligence – Based XGBoost Algorithm,” *J. Multimed. Dan Teknol. Inf.*, vol. 07, no. 04, pp. 893–902, 2025.
- [6] A. Arpan and Mohammad Yusup, “Sistem Peringatan Dini Penurunan Prestasi dan Minat Belajar pada Siswa Sekolah Menengah di Medan: Pendekatan Explainable Machine Learning,” *J. Komput. Teknol. Inf. Sist. Inf.*, vol. 4, no. 2, pp. 1423–1431, 2025.
- [7] B. A. Alnasyan, M. Basher, and M. O. Alassafi, “A Comprehensive Comparative Analysis of Deep Learning Models for Student Performance Prediction in Virtual Learning Environments: Leveraging the OULA Dataset and Advanced Resampling Techniques,” *IEEE Access*, vol. 13, pp. 75953–75972, 2025.
- [8] E. Ben George, R. Senthilkumar, F. Al-Junaibi, and Z. Al-Shuaibi, “Explainable AI Methods for Predicting Student Grades and Improving Academic Success,” 2024.
- [9] J. B. M. B. SANFO, “Application of explainable artificial intelligence approach to predict student learning outcomes,” *J. Comput. Soc. Sci.*, vol. 8, no. 1, Feb. 2025.
- [10] S. R. A. Parisineni and M. Pal, “Enhancing trust and interpretability of complex machine learning models using local interpretable model agnostic shap explanations,” *Int. J. Data Sci. Anal.*, vol. 18, no. 4, pp. 457–466, 2024.
- [11] E. Albini, J. Long, D. Dervovic, and D. Magazzeni, “Counterfactual Shapley Additive Explanations,” *ACM Int. Conf. Proceeding Ser.*, no. February, pp. 1054–1070, 2022.
- [12] I. Syahputra Ritonga, M. Rahfiqa Zainal, and A. Zaki, “Predicting Employment Status 6 Months After Graduation with Machine Learning Learning : A Comparative Study of 3,945 Indonesian Graduates,” *Intellect Int. J. Innov. Learn. Technol.*, vol. 04, no. 02, pp. 194–205, 2025.
- [13] S. Alturki, N. Alturki, and H. Stuckenschmidt, “Using Educational Data Mining To Predict Students’ Academic Performance For Applying Early Interventions,” *J. Inf. Technol. Educ. Innov. Pract.*, vol. 20, pp. 121–137, 2021.
- [14] V. M. Putri, B. A. Wisesa, I. A. Edyyul, and S. A. Darma, “Sistem Pakar Deteksi Keterlambatan Bicara Anak Menggunakan Forward Chaining dan Naïve Bayes,” *J. Pustaka AI (Pusat Akses Kaji. Teknol. Artif. Intell.*, vol. 5, no. 2, pp. 7–12, 2025.
- [15] A. Asriyanik and A. Pambudi, “Machine Learning-Based Classification for Scholarship Selection,” *PIKSEL Penelit. Ilmu Komput. Sist. Embed. Log.*, vol. 11, no. 2, pp. 447–460, 2023.
- [16] K. Kesgin, S. Kiraz, S. Kosunalp, and B. Stoycheva, “Beyond Performance: Explaining and Ensuring Fairness in Student Academic Performance Prediction with Machine Learning,” *Appl. Sci.*, vol. 15, no. 15, Aug. 2025.