

Prediksi Kepuasan dan Loyalitas Mahasiswa Menggunakan Random Forest dengan Pendekatan Explainable AI Berbasis SHAP

Indah Kusuma Dewi^{1*}, Muhammad Ropianto², Elsha Dellista Ashofie³

^{1*,2,3} Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Ibnu Sina, Batam, Indonesia

^{1*}indah.kusuma@uis.ac.id, ²ropianto@uis.ac.id, ³241055201069@uis.ac.id

*) indah.kusuma@uis.ac.id

Abstrak-Kepuasan dan loyalitas mahasiswa merupakan dua indikator strategis keberhasilan perguruan tinggi dalam mempertahankan dan meningkatkan mutu layanan pendidikan. Penelitian ini bertujuan membangun model prediksi kepuasan dan loyalitas mahasiswa menggunakan algoritma *Random Forest* serta menginterpretasikan keluaran model secara transparan melalui pendekatan SHapley Additive exPlanations (SHAP). Data diperoleh dari survei terhadap 437 responden mahasiswa yang mencakup delapan dimensi layanan dengan total 25 variabel indikator. Hasil evaluasi menunjukkan model kepuasan mencapai akurasi 94,32% dengan nilai AUC sebesar 0,8819, sedangkan model loyalitas memperoleh akurasi 87,50% dengan AUC 0,5490. Analisis SHAP mengidentifikasi bahwa Solusi kesulitan keuangan mahasiswa, Stabilitas jaringan Wi-Fi kampus, dan Variasi metode pembelajaran dosen merupakan prediktor dominan kepuasan, sedangkan Transparansi beasiswa dan Solusi kesulitan keuangan mahasiswa menjadi faktor utama loyalitas.

Kata Kunci: Random Forest, Kepuasan Mahasiswa, Loyalitas Mahasiswa, Explainable AI, SHAP

Abstract-Student satisfaction and loyalty are two strategic indicators of higher education institutions' success in maintaining educational service quality. This study builds prediction models for student satisfaction and loyalty using the Random Forest algorithm, interpreted transparently through the SHapley Additive exPlanations (SHAP) approach. Data were obtained from 437 student respondents covering eight service dimensions with 25 indicator variables. The satisfaction model achieved 94.32% accuracy (AUC = 0.8819), while the loyalty model obtained 87.50% accuracy (AUC = 0.5490). SHAP analysis identified Student financial difficulty solutions, Campus Wi-Fi stability, and Variation in teaching methods as dominant predictors of satisfaction, while Scholarship transparency is the main driver of loyalty.

Keywords: Random Forest, Student Satisfaction, Student Loyalty, Explainable AI, SHAP

1. PENDAHULUAN

Perguruan tinggi saat ini menghadapi permasalahan yang semakin besar tidak hanya menghasilkan lulusan berkualitas, tetapi juga memastikan bahwa mahasiswa yang terdaftar merasa puas dengan layanan yang diberikan dan memiliki komitmen jangka panjang terhadap institusi. Kepuasan mahasiswa (*student satisfaction*) memiliki peranan penting sebagai prediktor utama untuk melanjutkan studi, promosi dari mulut ke mulut, serta keberhasilan institusi dalam persaingan global [1], [2]. Di sisi lain, loyalitas mahasiswa (*student loyalty*) mencerminkan keterikatan emosional dan perilaku yang lebih dalam, yaitu kecenderungan mahasiswa untuk tetap terdaftar, berpartisipasi aktif, dan merekomendasikan institusi kepada orang lain [3]. Kualitas layanan akademik juga terbukti memiliki pengaruh positif terhadap kepuasan mahasiswa, yang selanjutnya berperan dalam meningkatkan loyalitas mahasiswa terhadap institusi pendidikan [4]. Selain itu, penelitian pada 1.550 mahasiswa di Vietnam mengidentifikasi beberapa dimensi kualitas layanan pendidikan, yaitu aspek akademik, nonakademik, program, fasilitas, dan interaksi industri, yang sebagian besar berpengaruh positif terhadap kepuasan mahasiswa [5].

Hubungan antara kualitas layanan, kepuasan, dan loyalitas mahasiswa telah banyak diteliti menggunakan pendekatan statistik konvensional seperti *Structural Equation Modeling* (SEM) dan regresi [2], [6], [7]. Namun, pendekatan tersebut umumnya bersifat linear dan tidak mampu menangkap pola non-linear yang kompleks dalam data survei berskala besar. Seiring berkembangnya bidang *machine learning*, berbagai algoritma *ensemble* seperti *Random Forest* telah terbukti unggul dalam tugas klasifikasi pada data pendidikan [8], [9].

Namun, model *ensemble* seperti *Random Forest* bersifat *black-box*, sehingga mampu menghasilkan prediksi yang akurat, tetapi sulit dipahami oleh pemangku kepentingan institusi [10]. Untuk mengatasi tantangan ini, *Explainable AI* (XAI) muncul sebagai solusi yang menghubungkan perbedaan antara akurasi model dan interpretabilitas hasil. Metode SHAP (*SHapley Additive exPlanations*) memungkinkan interpretasi prediksi model secara lokal maupun global dengan dasar teoritis yang kuat [11].

Transformasi digital pada sektor pendidikan tinggi turut mendorong perguruan tinggi untuk mengadopsi pendekatan berbasis data (*data-driven decision making*) dalam merumuskan kebijakan akademik maupun non-akademik. Persaingan antarperguruan tinggi yang semakin ketat menuntut institusi untuk tidak hanya bereaksi terhadap keluhan mahasiswa secara pasif, tetapi juga mampu mengidentifikasi secara proaktif faktor-faktor yang berpotensi menurunkan tingkat kepuasan maupun loyalitas mahasiswa sebelum berdampak pada angka putus studi atau penurunan reputasi institusi. Pendekatan konvensional seperti survei kepuasan tahunan umumnya bersifat deskriptif dan retrospektif, sehingga kurang mampu memberikan sinyal peringatan dini (*early warning*) bagi pengambil kebijakan. Educational data mining serta penerapan algoritma *machine learning* menawarkan peluang untuk mengubah data survei yang selama ini hanya direkap secara statistik deskriptif menjadi model prediktif yang dapat diperbarui secara berkala dan diintegrasikan ke dalam sistem informasi akademik.

Meskipun pendekatan statistik konvensional seperti SEM telah banyak digunakan untuk memodelkan hubungan antara kualitas layanan, kepuasan, dan loyalitas, metode ini mensyaratkan sejumlah asumsi ketat seperti linearitas hubungan antarvariabel, normalitas distribusi data, serta ukuran sampel yang relatif besar untuk mencapai stabilitas estimasi parameter. Asumsi-asumsi tersebut sering kali sulit dipenuhi pada data survei layanan pendidikan yang bersifat ordinal dan tidak selalu berdistribusi normal. Di sisi lain, penelitian yang menggabungkan prediksi kepuasan dan loyalitas mahasiswa secara simultan menggunakan pendekatan *Explainable AI* masih terbatas jumlahnya, khususnya pada konteks perguruan tinggi di Indonesia. Sebagian besar penelitian terdahulu cenderung berfokus pada salah satu aspek saja, baik prediksi kepuasan [1], [8], [9] maupun prediksi loyalitas [2], [3], tanpa membandingkan karakteristik prediktor keduanya secara komparatif. Penelitian ini berupaya mengisi celah tersebut dengan mengembangkan dua model prediksi secara paralel menggunakan algoritma yang sama, sehingga perbedaan pola prediktor antarkedua konstruk dapat diidentifikasi secara lebih objektif melalui analisis SHAP.

Pembeda utama penelitian ini dibandingkan penelitian terdahulu dapat diringkas dalam tiga hal. Pertama, penelitian prediktif berbasis *Random Forest* pada bidang kepuasan [13] dan loyalitas mahasiswa [1] dilakukan secara terpisah, sedangkan penelitian ini memodelkan kedua konstruk secara simultan pada satu populasi responden dengan satu algoritma yang sama, sehingga perbedaan prediktornya dapat dibandingkan secara langsung. Kedua, penerapan *Explainable AI* pada bidang pendidikan sebagian besar difokuskan pada prediksi prestasi akademik dan putus studi [15], [20], sedangkan penelitian ini mengarahkannya pada kualitas layanan institusi sebagai determinan kepuasan dan loyalitas. Ketiga, interpretasi tidak berhenti pada peringkat kepentingan fitur, tetapi mencakup *beeswarm plot*, *dependence plot* untuk mendeteksi interaksi antarfitur, dan *waterfall plot* untuk prediksi individual, dengan delapan dimensi layanan dan 25 indikator pada konteks perguruan tinggi di Indonesia, yang kemudian diterjemahkan menjadi rekomendasi manajerial.

Secara garis besar, penelitian ini memberikan tiga kontribusi utama. Pertama, penelitian ini mengembangkan model prediksi kepuasan dan loyalitas mahasiswa secara paralel pada satu populasi data yang sama, sehingga memungkinkan perbandingan langsung karakteristik prediktor kedua konstruk tersebut. Kedua, penelitian ini menerapkan pendekatan *Explainable AI* berbasis SHAP untuk menjembatani kebutuhan akurasi prediksi dengan kebutuhan interpretabilitas hasil bagi pemangku kepentingan non-teknis di lingkungan perguruan tinggi. Ketiga, hasil interpretasi model diterjemahkan menjadi rekomendasi manajerial yang bersifat aplikatif, sehingga temuan penelitian tidak berhenti pada tahap evaluasi teknis semata, melainkan dapat langsung ditindaklanjuti oleh pengelola institusi dalam merumuskan kebijakan peningkatan mutu layanan.


Penelitian ini bertujuan untuk (1) membangun model prediksi kepuasan dan loyalitas mahasiswa menggunakan *Random Forest* yang dioptimalkan melalui *hyperparameter tuning*, (2) mengevaluasi performa model secara komprehensif menggunakan akurasi, F1-score, dan AUC-ROC, serta (3) menginterpretasikan hasil prediksi secara transparan menggunakan SHAP. Penelitian ini menghasilkan pendekatan analisis berbasis *Explainable Artificial Intelligence* (XAI) untuk mendukung pengambilan keputusan manajemen perguruan tinggi terkait peningkatan kepuasan dan loyalitas mahasiswa.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif berbasis survei dengan metodologi *educational data mining*. Gambar 1 menyajikan kerangka penelitian secara keseluruhan yang mencakup enam tahapan utama: pengumpulan data, prapemrosesan, pemodelan *Random Forest*, evaluasi model, analisis SHAP, dan perumusan rekomendasi manajerial.

Pemilihan *Random Forest* sebagai algoritma utama didasarkan pada kemampuannya menangani data dengan campuran skala pengukuran (kategorikal dan ordinal), ketahanannya terhadap *outlier*, serta ketersediaan mekanisme pengukuran kepentingan fitur bawaan yang dapat dipadukan dengan analisis SHAP untuk interpretasi

yang lebih mendalam, dibandingkan algoritma *black-box* lain seperti jaringan saraf tiruan yang umumnya memerlukan volume data jauh lebih besar untuk mencapai performa yang stabil.



Gambar 1. Kerangka Penelitian

2.1 Pengumpulan Data dan Instrumen

Data dikumpulkan melalui survei daring menggunakan kuesioner terstruktur yang disebar kepada mahasiswa aktif di seluruh program studi. Instrumen survei dikembangkan berdasarkan kajian literatur terkait kualitas layanan perguruan tinggi [2], [3], [12] dengan total 25 variabel indikator yang diukur menggunakan skala Likert 5 poin (1 = Sangat Tidak Setuju, 5 = Sangat Setuju). Kuesioner juga memuat dua pertanyaan target yang kemudian dikonversi menjadi variabel biner: Kepuasan (Puas: skor ≥ 4 ; Tidak Puas: skor < 4) dan Loyalitas (Loyal: skor ≥ 4 ; Tidak Loyal: skor < 4) [1], [13]. Dataset yang digunakan dalam penelitian ini disajikan secara ringkas pada Gambar 2.

Instrumen survei terdiri atas delapan dimensi layanan, meliputi layanan akademik, layanan administrasi, fasilitas kampus, teknologi informasi, dukungan finansial, bimbingan karir, lingkungan sosial, dan reputasi institusi, dengan total 25 item indikator yang telah diuji validitas dan reliabilitasnya pada studi pendahuluan sebelum digunakan pada pengumpulan data utama.

		1. Dosen menyampaikan materi dengan jelas, menarik, dan mudah dipahami	2. Dosen terbuka untuk konsultasi dan memberikan umpan balik yang membangun	3. Dosen menggunakan metode pembelajaran yang variatif dan relevan dengan kebutuhan praktik nyata	4. Kurikulum program studi saya relevan dengan industri dan dunia kerja.	5. Beban studi (SKS) setiap semester terasa proporsional dan tidak memberatkan.	6. Program studi menyediakan praktik / magang yang bermakna	7. Ruang kelas dan laboratorium nyaman, bersih, dan peralatannya memadai	23. Kampus memberikan kemudahan / solusi bagi mahasiswa yang mengalami kesulitan keuangan, dijangkau.	24. Terdapat pilihan atau keringanan biaya yang cukup dan mudah.	25. Secara keseluruhan, saya puas dengan kualitas pendidikan dan layanan kampus ini.	26. Harapan saya ketika pertama kali masuk ke kampus ini telah terpenuhi dengan baik.	27. Saya merasa mendapat manfaat nyata yang sepadan dengan pengorbanan (waktu, biaya) saya.	28. Saya berencana menyelesaikan studi di kampus ini hingga lulus (tidak berniat pindah).	29. Saya akan merekomendasikan kampus ini kepada keluarga, teman, atau kenalan saya
0	Teknik Perkapalan Laki - Laki Mandiri	5	5	4	4	3	4	4	5	5	4	5	5	5	
1	K3 Perempuan Mandiri	4	4	4	4	4	4	4	4	4	4	4	4	4	4
2	Logistik Perempuan Mandiri	4	5	3	5	5	4	4	5	3	4	3	4	5	

3 rows × 36 columns

Gambar 2. Dataset Kepuasan dan Loyalitas Mahasiswa

2.2 Pra-Pemrosesan Data

Tahap prapemrosesan meliputi: (1) pengecekan nilai hilang (*missing value*) — tidak ditemukan nilai hilang dari 437 respons; (2) pengecekan *outlier* menggunakan metode Interquartile Range (IQR); (3) konversi variabel target ke label biner; (4) pembagian data latih-uji dengan rasio 80:20 menggunakan *stratified split* (349 data latih, 88 data uji); dan (5) penerapan teknik SMOTE pada data latih untuk menangani ketidakseimbangan kelas (87,2% Puas vs 12,8% Tidak Puas) tanpa kebocoran data [13], [14].

Seluruh tahapan prapemrosesan dilakukan secara terpisah pada data latih dan data uji untuk mencegah kebocoran informasi (*data leakage*), khususnya pada tahap penerapan SMOTE yang hanya dilakukan pada data latih agar distribusi data uji tetap merepresentasikan kondisi populasi yang sebenarnya.

2.3 Pemodelan Random Forest

Hasil cross-validation menunjukkan bahwa model kepuasan memperoleh nilai rata-rata F1-weighted sebesar 0,9174 dengan standar deviasi $\pm 0,0208$. Sementara itu, model loyalitas memperoleh nilai rata-rata F1-weighted sebesar 0,8620 dengan standar deviasi $\pm 0,0348$. Nilai standar deviasi yang relatif kecil menunjukkan bahwa model *Random Forest* memiliki performa yang stabil pada setiap fold pengujian.

Proses *hyperparameter tuning* dilakukan melalui *grid search* dengan validasi silang 5-fold pada beberapa parameter kunci, meliputi jumlah pohon (*n_estimators*), kedalaman maksimum pohon (*max_depth*), jumlah minimum sampel untuk membagi node (*min_samples_split*), serta jumlah minimum sampel pada setiap daun (*min_samples_leaf*), guna memperoleh kombinasi parameter yang meminimalkan risiko *overfitting* sekaligus menjaga kemampuan generalisasi model pada data uji.

2.4 Evaluasi Model

Performa model dievaluasi menggunakan: Akurasi, Presisi, Recall, F1-score per kelas, *Confusion Matrix*, dan AUC-ROC. Metrik AUC-ROC digunakan sebagai metrik utama karena lebih informatif untuk kasus ketidakseimbangan kelas [13], [15].

2.5 Analisis SHAP

Interpretasi model dilakukan menggunakan TreeSHAP, khususnya melalui empat jenis visualisasi: (1) *Feature Importance Plot*, (2) Beeswarm Plot, (3) Dependence Plot, dan (4) Waterfall Plot untuk prediksi individual. Nilai SHAP positif menunjukkan dorongan prediksi menuju kelas positif (Puas/Loyal), sedangkan nilai negatif mengindikasikan sebaliknya [10], [16].


3. HASIL DAN PEMBAHASAN

3.1 Evaluasi Model Random Forest

Tabel 1 menyajikan hasil evaluasi komprehensif kedua model. Gambar 3 menunjukkan confusion matrix dan kurva ROC. Perbedaan performa yang cukup signifikan antara model kepuasan dan model loyalitas pada Tabel 1 mengindikasikan bahwa kedua konstruk tersebut, meskipun berkaitan secara konseptual, memiliki karakteristik prediktabilitas yang berbeda. Model kepuasan cenderung lebih mudah diprediksi karena umumnya dibentuk oleh pengalaman layanan yang bersifat langsung dan dapat diobservasi, sedangkan model loyalitas dipengaruhi oleh proses kognitif dan afektif jangka panjang yang lebih sulit direpresentasikan hanya melalui indikator survei satu waktu.

Tabel 1. Hasil Evaluasi Model Random Forest pada Data Uji (n = 88)

Variabel	Kelas	Precision	Recall	F1 Score	Support	Akurasi	AUC-ROC
Kepuasan	Puas	0.950	0.987	0.968	77	0.9432	0.8819
	Tidak Puas	0.875	0.636	0.737	11		
Loyalitas	Loyal	0.884	0.987	0.933	77	0.8750	0.5490
	Tidak Loyal	0.500	0.091	0.154	11		




Gambar 3. Confusion Matrix dan ROC Curve Model Random Forest

Model kepuasan mencapai AUC-ROC 0,8819, berada di atas ambang batas 0,80 yang dianggap memuaskan dalam literatur [15], [17]. Sebaliknya, AUC-ROC model loyalitas sebesar 0,5490 hanya sedikit di atas nilai random (0,50) mengindikasikan kemampuan diskriminasi yang sangat terbatas. Hal ini disebabkan oleh: (1) loyalitas sebagai konstruk yang lebih kompleks dan multidimensional [3]; (2) sinyal kelas minoritas yang sangat lemah ($n=57$) meskipun telah diterapkan SMOTE; dan (3) perbedaan penentu loyalitas yang bersifat jangka panjang dibandingkan kepuasan yang bersifat transaksional [13].

Dari sisi kelas per kategori, model kepuasan menunjukkan *recall* yang sangat tinggi untuk kelas Puas (0,987) namun *recall* yang jauh lebih rendah untuk kelas Tidak Puas (0,636), meskipun teknik SMOTE telah diterapkan pada data latih. Pola serupa terlihat lebih ekstrem pada model loyalitas, di mana *recall* kelas Tidak Loyal hanya sebesar 0,091, mengindikasikan bahwa model masih kesulitan mengenali pola pada kelas minoritas akibat jumlah sampel yang sangat terbatas ($n = 11$ pada data uji). Kondisi ini merupakan tantangan umum dalam klasifikasi data tidak seimbang, di mana teknik *oversampling* seperti SMOTE efektif memperbaiki keseimbangan pada data latih tetapi tidak serta-merta menjamin generalisasi yang baik pada data uji yang tetap mencerminkan distribusi populasi asli [13], [14]. Implikasinya, model saat ini lebih andal digunakan sebagai alat skrining awal untuk mengidentifikasi mahasiswa berisiko tinggi mengalami ketidakpuasan atau ketidakloyalan, dan bukan sebagai alat keputusan tunggal yang bersifat final.

3.2 Analisis Feature Importance

Gambar 4 menampilkan peringkat 15 fitur teratas berbasis Gini importance untuk kedua model. Untuk model kepuasan: Solusi kesulitan keuangan mahasiswa (0,0873), Stabilitas jaringan Wi-Fi kampus (0,0826), dan Variasi metode pembelajaran dosen (0,0800). Untuk model loyalitas: Solusi kesulitan keuangan mahasiswa (0,0657), Transparansi beasiswa (0,0612), dan Kejelasan penyampaian materi dosen (0,0579). Dominannya faktor finansial pada kedua model mengindikasikan bahwa kondisi ekonomi mahasiswa merupakan titik kritis yang harus diprioritaskan institusi [1].




Gambar 4. Feature Importance Top 15 Fitur (Kepuasan & Loyalitas)

Selain tiga prediktor teratas yang telah disebutkan, fitur-fitur lain seperti Kesesuaian UKT dengan layanan, Koleksi dan akses perpustakaan, serta Budaya akademik positif juga memberikan kontribusi yang cukup berarti terhadap model kepuasan, meskipun dengan skor *Gini importance* yang lebih rendah dibandingkan tiga fitur utama. Pola ini menunjukkan bahwa kepuasan mahasiswa bersifat multidimensional dan dipengaruhi oleh kombinasi faktor teknis, pedagogis, dan finansial secara bersamaan. Sementara itu, pada model loyalitas, dominasi faktor finansial dan administratif mengindikasikan bahwa loyalitas mahasiswa, yang mencerminkan komitmen jangka panjang, lebih dipengaruhi oleh persepsi keadilan dan transparansi institusional dibandingkan aspek teknis operasional sehari-hari. Temuan ini sejalan dengan penelitian [3] dan [6] yang menekankan peran kepercayaan institusional sebagai determinan utama loyalitas, berbeda dengan kepuasan yang lebih bersifat transaksional dan berorientasi pada pengalaman layanan langsung.

3.3 Analisis SHAP

Gambar 5 menyajikan beeswarm plot SHAP untuk kedua model. Pada model kepuasan, fitur Stabilitas Wi-Fi menunjukkan pola yang jelas: nilai tinggi (merah) berkumpul di sisi positif SHAP, sedangkan nilai rendah (biru) tersebar jauh ke sisi negatif (hingga -0,17), mengindikasikan efek asimetris di mana Wi-Fi buruk memiliki dampak negatif lebih besar daripada dampak positif Wi-Fi baik.

Pada model loyalitas, Transparansi beasiswa menunjukkan rentang SHAP paling dramatis: dari -0,10 (nilai rendah) hingga +0,22 (nilai tinggi). Ini mengimplikasikan bahwa mahasiswa yang mempersepsikan transparansi beasiswa rendah memiliki probabilitas Tidak Loyal yang sangat tinggi. Fitur Efisiensi prosedur administrasi juga menunjukkan pengaruh negatif yang kuat (SHAP hingga -0,10) pada skor rendah, mempertegas pentingnya digitalisasi layanan administrasi [18]. Temuan tersebut sejalan dengan penelitian sebelumnya yang menunjukkan bahwa persepsi transparansi dan kepercayaan terhadap institusi merupakan faktor yang signifikan dalam membentuk kepuasan mahasiswa [19].




Gambar 5. SHAP Beeswarm Plot Model Kepuasan dan Model Loyalitas

Perbandingan pola SHAP antara kedua model juga mengungkapkan perbedaan arah pengaruh yang menarik. Pada model kepuasan, sebagian besar fitur teknologi dan pedagogis menunjukkan hubungan yang relatif konsisten dan searah dengan nilai SHAP, sedangkan pada model loyalitas, beberapa fitur administratif seperti Kejelasan prosedur administrasi menunjukkan sebaran nilai SHAP yang lebih heterogen, mengindikasikan adanya efek interaksi dengan variabel lain yang tidak tertangkap sepenuhnya melalui visualisasi satu dimensi. Heterogenitas ini memperkuat argumen bahwa loyalitas mahasiswa merupakan konstruk yang lebih kompleks dan multifaktorial dibandingkan kepuasan, sehingga memerlukan strategi intervensi yang lebih terintegrasi dan tidak dapat didekati hanya dari satu aspek layanan saja.

3.4 Analisis SHAP Dependence Plot

Gambar 6 menyajikan dependence plot untuk fitur Stabilitas Wi-Fi (kepuasan) dan Transparansi beasiswa (loyalitas). Kedua plot menunjukkan hubungan monoton positif antara nilai fitur dan nilai SHAP. Pada plot loyalitas, interaksi dengan Efisiensi prosedur administrasi menunjukkan efek sinergis: pada Transparansi beasiswa tinggi (4–5), mahasiswa dengan administrasi efisien (merah) memiliki SHAP lebih tinggi dibandingkan yang tidak — suatu interaksi yang tidak dapat dideteksi oleh model linear konvensional [10], [11].




Gambar 6. SHAP Dependence Plot Kepuasan (Stabilitas Wi-Fi) & Loyalitas (Transparansi Beasiswa)

Efek sinergis yang teridentifikasi antara Transparansi beasiswa dan Efisiensi prosedur administrasi pada model loyalitas mengindikasikan bahwa peningkatan pada satu aspek saja, misalnya transparansi informasi beasiswa tanpa disertai perbaikan efisiensi birokrasi pengajuannya, berpotensi tidak memberikan dampak optimal terhadap loyalitas mahasiswa secara keseluruhan. Temuan berbasis *dependence plot* semacam ini sulit diperoleh melalui pendekatan regresi linear konvensional yang mengasumsikan efek aditif antarvariabel, sehingga menegaskan nilai tambah pendekatan berbasis pohon keputusan yang dipadukan dengan SHAP dalam mengungkap pola interaksi non-linear pada data layanan pendidikan [11].

3.5 SHAP Waterfall Plot (Prediksi Individual)

Gambar 7 menyajikan SHAP waterfall plot untuk empat prediksi individual. Waterfall plot memperlihatkan kontribusi per fitur terhadap prediksi individu tertentu dengan baseline $E[f(X)] \approx 0,504$ (kepuasan) dan $\approx 0,503$ (loyalitas). Pada skenario Puas, Keterbukaan dosen untuk konsultasi (skor=5) memberikan kontribusi positif (+0,01), sedangkan Kejelasan penyampaian materi dosen (skor=3) menurunkan probabilitas (-0,01). Skenario Tidak Loyal menunjukkan kontribusi yang hampir nol untuk kedua fitur utama, mencerminkan ambiguitas prediksi pada kasus batas.



Gambar 7. SHAP Waterfall Plot Prediksi Individual Kepuasan dan Loyalitas

Kemampuan *waterfall plot* dalam menjabarkan kontribusi setiap fitur terhadap prediksi individual membuka peluang penerapan praktis berupa sistem peringatan dini (*early warning system*) tingkat mahasiswa, di mana staf akademik atau bimbingan konseling dapat memperoleh gambaran spesifik mengenai faktor apa yang paling memengaruhi risiko ketidakpuasan atau ketidakloyalan seorang mahasiswa tertentu, alih-alih hanya mengetahui skor prediksi agregat semata. Pendekatan interpretasi pada tingkat individual juga telah ditunjukkan

dapat mendukung intervensi yang lebih personal, karena pemangku kepentingan pendidikan dapat memahami faktor yang berkontribusi terhadap prediksi masing-masing mahasiswa [20]. Pendekatan berbasis individu semacam ini sejalan dengan prinsip *Explainable AI* yang menekankan pentingnya transparansi pada level keputusan personal, khususnya dalam konteks pendidikan yang menyangkut kesejahteraan mahasiswa secara langsung [16]. Dengan mengetahui kontribusi fitur pada level individu, pihak institusi juga dapat merancang intervensi yang lebih personal dan tepat sasaran, alih-alih menerapkan kebijakan generik yang berlaku sama untuk seluruh mahasiswa tanpa mempertimbangkan perbedaan konteks masing-masing individu.

3.6 Implikasi Manajerial dan Rekomendasi Strategis

Berdasarkan hasil analisis SHAP, penelitian ini merumuskan beberapa rekomendasi manajerial yang dapat dipertimbangkan oleh pengelola perguruan tinggi. Pertama, terkait stabilitas jaringan Wi-Fi kampus yang teridentifikasi sebagai salah satu prediktor dominan kepuasan, institusi disarankan melakukan audit infrastruktur jaringan secara berkala serta mempertimbangkan peningkatan kapasitas bandwidth pada area dengan kepadatan pengguna tinggi seperti perpustakaan dan ruang kelas. Kedua, mengingat variasi metode pembelajaran dosen turut menjadi faktor penting, program pengembangan kompetensi pedagogis dosen melalui pelatihan metode pembelajaran aktif dapat menjadi prioritas dalam program peningkatan mutu akademik. Ketiga, dan yang paling krusial, solusi terhadap kesulitan keuangan mahasiswa muncul sebagai prediktor dominan baik pada model kepuasan maupun loyalitas, sehingga institusi perlu memastikan ketersediaan skema bantuan finansial yang responsif, seperti keringanan UKT bertahap atau beasiswa darurat bagi mahasiswa yang mengalami kendala ekonomi mendadak. Keempat, terkait temuan bahwa transparansi beasiswa menjadi prediktor utama loyalitas, institusi disarankan meningkatkan keterbukaan informasi mengenai kriteria, kuota, dan proses seleksi beasiswa melalui kanal komunikasi yang mudah diakses mahasiswa, guna membangun persepsi keadilan prosedural yang pada gilirannya dapat memperkuat loyalitas jangka panjang. Kelima, efisiensi prosedur administrasi turut perlu menjadi perhatian, terutama dalam konteks digitalisasi layanan administrasi untuk mengurangi waktu tunggu dan kompleksitas birokrasi yang dapat menurunkan persepsi kualitas layanan. Rekomendasi-rekomendasi tersebut sejalan dengan kerangka penelitian yang telah dirancang pada tahap awal (Gambar 1), di mana hasil interpretasi model diarahkan untuk menghasilkan rekomendasi manajerial yang aplikatif bagi pengambilan keputusan institusi, bukan sekadar angka evaluasi model semata.

Perbandingan hasil penelitian ini dengan studi-studi sejenis menunjukkan konsistensi sekaligus perbedaan yang informatif. Nilai AUC-ROC model kepuasan sebesar 0,8819 sejalan dengan rentang performa model prediksi kepuasan mahasiswa berbasis *machine learning* pada penelitian sebelumnya yang umumnya berada pada kisaran 0,80 hingga 0,90 [1], [9]. Namun demikian, performa model loyalitas yang lebih rendah menegaskan bahwa loyalitas mahasiswa secara konsisten lebih sulit diprediksi dibandingkan kepuasan pada berbagai konteks penelitian, sebagaimana juga dilaporkan pada studi [2] dan [3] yang menggunakan pendekatan SEM. Perbedaan pendekatan metodologis antara SEM dan *Random Forest* turut memberikan perspektif komplementer: jika SEM lebih menekankan pengujian hipotesis hubungan kausal antarkonstrukt laten, pendekatan berbasis pohon keputusan seperti *Random Forest* yang dipadukan SHAP lebih unggul dalam mengungkap pola interaksi non-linear dan peringkat kepentingan fitur secara data-driven tanpa perlu spesifikasi model teoritis di awal. Kombinasi kedua pendekatan tersebut pada penelitian mendatang berpotensi memberikan pemahaman yang lebih holistik mengenai determinan kepuasan dan loyalitas mahasiswa. Secara umum, *Random Forest* dikenal sebagai algoritma *ensemble* yang kuat dan relatif tahan terhadap *overfitting* [21], serta telah dibandingkan dengan berbagai teknik *machine learning* lain pada prediksi retensi mahasiswa [22], sebagaimana dirangkum dalam kajian *educational data mining* dan *learning analytics* [23].

Dari sisi keterbatasan, penelitian ini belum melibatkan validasi eksternal pada populasi mahasiswa dari perguruan tinggi lain, sehingga generalisasi pola prediktor yang ditemukan perlu diuji lebih lanjut pada konteks institusi yang berbeda karakteristik demografis dan geografisnya. Selain itu, sifat data yang *cross-sectional* belum dapat menangkap dinamika perubahan persepsi kepuasan dan loyalitas mahasiswa sepanjang masa studi, sehingga pendekatan *longitudinal* pada penelitian mendatang berpotensi memberikan gambaran yang lebih komprehensif mengenai bagaimana faktor-faktor dominan yang teridentifikasi pada penelitian ini berevolusi dari waktu ke waktu. Penelitian mendatang juga disarankan mengeksplorasi penggunaan teknik penanganan ketidakseimbangan kelas yang lebih adaptif, seperti *cost-sensitive learning* atau *ensemble hybrid*, untuk mengatasi keterbatasan *recall* pada kelas minoritas yang teridentifikasi pada model loyalitas. Penggunaan SMOTE [24] juga masih menyisakan keterbatasan pada kelas minoritas, sehingga pada data tidak seimbang metrik berbasis presisi-*recall* dapat melengkapi AUC-ROC sebagai dasar evaluasi [25].

Perlu ditekankan pula bahwa nilai *Gini importance* dan nilai SHAP, meskipun keduanya mengukur kontribusi fitur, tidak selalu menghasilkan urutan peringkat yang identik karena perbedaan mekanisme

perhitungan: *Gini importance* bersifat global dan berbasis pengurangan impuritas pada seluruh pohon keputusan, sedangkan SHAP menghitung kontribusi marjinal setiap fitur secara aditif pada level prediksi individual maupun agregat. Konsistensi arah temuan antara kedua metode pada penelitian ini, di mana fitur-fitur teratas pada Gambar 4 juga muncul sebagai fitur dominan pada Gambar 5, memperkuat keandalan interpretasi bahwa faktor finansial, teknologi, dan pedagogis memang secara substansial memengaruhi kepuasan dan loyalitas mahasiswa, bukan sekadar artefak dari satu metode pengukuran kepentingan fitur saja. Konsistensi lintas-metode semacam ini juga menjadi salah satu praktik yang dianjurkan dalam literatur *Explainable AI* untuk meningkatkan kepercayaan terhadap hasil interpretasi model, khususnya ketika model akan digunakan sebagai dasar pengambilan keputusan institusional yang berdampak langsung pada mahasiswa [10], [16]. Pendekatan ini juga sejalan dengan taksonomi dan tantangan *Explainable AI* yang bertanggung jawab (*responsible AI*) [26].

4. KESIMPULAN

Penelitian ini berhasil membangun model prediksi kepuasan dan loyalitas mahasiswa menggunakan algoritma *Random Forest* yang diinterpretasikan secara transparan melalui pendekatan *Explainable AI* berbasis SHAP. Model kepuasan mencapai akurasi 94,32% dan AUC-ROC 0,8819, sedangkan model loyalitas menghasilkan akurasi 87,50% dengan AUC-ROC 0,5490 yang mengindikasikan kompleksitas konstruk loyalitas. Analisis SHAP menunjukkan bahwa kepuasan didominasi faktor teknologi (stabilitas Wi-Fi, layanan digital) dan pedagogis (variasi metode mengajar), sedangkan loyalitas lebih dipengaruhi faktor finansial-administratif (transparansi beasiswa, efisiensi administrasi), serta mengungkap efek sinergis antara transparansi beasiswa dan efisiensi administrasi yang tidak dapat ditangkap oleh model statistik konvensional. Secara praktis, kerangka kerja ini dapat diadopsi perguruan tinggi lain untuk mengembangkan sistem prediksi yang akurat sekaligus dapat dipertanggungjawabkan, dengan keterbatasan berupa data *cross-sectional* pada satu institusi dan *recall* kelas minoritas yang rendah pada model loyalitas. Penelitian selanjutnya disarankan untuk memperluas ukuran sampel kelas minoritas, mengintegrasikan data *longitudinal*, membandingkan *Random Forest* dengan XGBoost atau LightGBM, serta mengembangkan sistem rekomendasi berbasis SHAP secara *real-time*.

UCAPAN TERIMA KASIH

Penelitian ini didukung oleh Lembaga Penelitian dan Pengabdian kepada Masyarakat (LPPM) Universitas Ibnu Sina melalui Skema Pendanaan Hiba Fundamentasl Tahun 2026.

REFERENSI

- [1] Q. Widayati, K. Adi, R. R. Isnanto, E. P. Agustini, D. R. R. Julianto, and F. B. Prakasa, "Predicting Student Loyalty in Higher Education Using Machine Learning: A Random Forest Approach," *Journal of Information Systems and Informatics*, vol. 7, no. 1, pp. 63–77, Mar. 2025, doi: 10.51519/journalisi.v7i1.977.
- [2] M. de la C. Del Río-Rama, J. Álvarez-García, N. K. Mun, and A. Durán-Sánchez, "Influence of the Quality Perceived of Service of a Higher Education Center on the Loyalty of Students," *Front. Psychol.*, vol. 12, Jun. 2021, doi: 10.3389/fpsyg.2021.671407.
- [3] T. T. Borishade, O. O. Ogunnaike, O. Salau, B. D. Motilewa, and J. I. Dirisu, "Assessing the relationship among service quality, student satisfaction and loyalty: the NIGERIAN higher education experience," *Heliyon*, vol. 7, no. 7, p. e07590, Jul. 2021, doi: 10.1016/j.heliyon.2021.e07590.
- [4] A. Fakhruddin, Nuryakin, I. Fatmawati, and M. Suyanto, "The Influence of Academic Service Quality on Student Loyalty: Mediating Effects of Student Satisfaction," *Amwaluna: Jurnal Ekonomi dan Keuangan Syariah*, vol. 9, no. 1, pp. 69–83, 2025, doi: 10.29313/amwaluna.v6i2.3549.
- [5] H. V. Nguyen, T. D. Vu, M. Saleem, and A. Yaseen, "The influence of service quality on student satisfaction and student loyalty in Vietnam: the moderating role of the university image," *Journal of Trade Science*, vol. 12, no. 1, pp. 37–59, Mar. 2024, doi: 10.1108/JTS-12-2023-0032.
- [6] S. Aghaei, Y. Shahbazi, M. Pirbabaei, and H. Beyti, "A hybrid SEM-neural network method for modeling the academic satisfaction factors of architecture students," *Computers and Education: Artificial Intelligence*, vol. 4, p. 100122, Jan. 2023, doi: 10.1016/J.CAEAI.2023.100122.
- [7] Y. Luthfiana, S. Sujarwoto, and Moh. Said, "Evaluating Public University Service Quality and its Influence on Student Satisfaction and Loyalty: The Disjoint Two-Stage Approach," *Jurnal Manajemen Pelayanan Publik*, vol. 9, no. 2, pp. 392–410, Jun. 2025, doi: 10.24198/jmpp.v9i2.61990.



- [8] M. Nachouki and M. A. Naaj, "Predicting Student Performance to Improve Academic Advising Using the Random Forest Algorithm," *International Journal of Distance Education Technologies*, vol. 20, no. 1, Feb. 2022, doi: 10.4018/IJDET.296702.
- [9] M. Nachouki, E. A. Mohamed, R. Mehdi, and M. Abou Naaj, "Student course grade prediction using the random forest algorithm: Analysis of predictors' importance," *Trends Neurosci. Educ.*, vol. 33, p. 100214, Dec. 2023, doi: 10.1016/J.TINE.2023.100214.
- [10] W. Saeed and C. Omlin, "Explainable AI (XAI): A systematic meta-survey of current challenges and future opportunities," *Knowl. Based. Syst.*, vol. 263, p. 110273, Mar. 2023, doi: 10.1016/J.KNOSYS.2023.110273.
- [11] S. M. Lundberg *et al.*, "From local explanations to global understanding with explainable AI for trees," *Nat. Mach. Intell.*, vol. 2, no. 1, pp. 56–67, 2020, doi: 10.1038/s42256-019-0138-9.
- [12] F. Martínez-Roget, P. Freire Esparís, and E. Vázquez-Rozas, "University Student Satisfaction and Skill Acquisition: Evidence from the Undergraduate Dissertation," *Educ. Sci.*, vol. 10, no. 2, p. 29, 2020, doi: 10.3390/educsci10020029.
- [13] J. Li and X. Chen, "Modeling student satisfaction in online learning using random forest," *Sci. Rep.*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-06686-3.
- [14] Y. Rimal, N. Sharma, and A. Alsadoon, "The accuracy of machine learning models relies on hyperparameter tuning: student result classification using random forest, randomized search, grid search, bayesian, genetic, and optuna algorithms," *Multimed. Tools Appl.*, vol. 83, no. 30, pp. 74349–74364, 2024, doi: 10.1007/s11042-024-18426-2.
- [15] J. G. C. Krüger, A. de S. Britto, and J. P. Barddal, "An explainable machine learning approach for student dropout prediction," *Expert Syst. Appl.*, vol. 233, p. 120933, Dec. 2023, doi: 10.1016/J.ESWA.2023.120933.
- [16] H. Khosravi *et al.*, "Explainable Artificial Intelligence in education," *Computers and Education: Artificial Intelligence*, vol. 3, p. 100074, Jan. 2022, doi: 10.1016/J.CAEAI.2022.100074.
- [17] R. Alamri and B. Alharbi, "Explainable Student Performance Prediction Models: A Systematic Review," *IEEE Access*, vol. 9, pp. 33132–33143, 2021, doi: 10.1109/ACCESS.2021.3061368.
- [18] X. Duan, B. Pei, G. A. Ambrose, A. Hershkovitz, Y. Cheng, and C. Wang, "Towards transparent and trustworthy prediction of student learning achievement by including instructors as co-designers: a case study," *Educ. Inf. Technol. (Dordr.)*, vol. 29, no. 3, pp. 3075–3096, 2024, doi: 10.1007/s10639-023-11954-8.
- [19] V. W. Bwachele, Y.-L. Chong, and G. Krishnapillai, "Perceived service quality and student satisfaction in higher learning institutions in Tanzania," *Humanit. Soc. Sci. Commun.*, vol. 10, no. 1, p. 444, 2023, doi: 10.1057/s41599-023-01913-6.
- [20] M. Nagy and R. Molontay, "Interpretable Dropout Prediction: Towards XAI-Based Personalized Intervention," *Int. J. Artif. Intell. Educ.*, vol. 34, no. 2, pp. 274–300, Jun. 2024, doi: 10.1007/S40593-023-00331-8.
- [21] L. Breiman, "Random Forests," *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, Oct. 2001, doi: 10.1023/A:1010933404324.
- [22] D. Delen, "A comparative analysis of machine learning techniques for student retention management," *Decis. Support Syst.*, vol. 49, no. 4, pp. 498–506, Nov. 2010, doi: 10.1016/j.dss.2010.06.003.
- [23] C. Romero and S. Ventura, "Educational data mining and learning analytics: An updated survey," *WIREs Data Min. Knowl. Discov.*, vol. 10, no. 3, p. e1355, 2020, doi: 10.1002/widm.1355.
- [24] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: Synthetic Minority Over-sampling Technique," *J. Artif. Intell. Res.*, vol. 16, pp. 321–357, 2002, doi: 10.1613/jair.953.
- [25] T. Saito and M. Rehmsmeier, "The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets," *PLoS One*, vol. 10, no. 3, p. e0118432, Mar. 2015, doi: 10.1371/journal.pone.0118432.
- [26] A. Barredo Arrieta *et al.*, "Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI," *Inf. Fusion*, vol. 58, pp. 82–115, 2020, doi: 10.1016/j.inffus.2019.12.012.