

BAB V

SIMPULAN DAN SARAN

5.1 Simpulan

Penelitian ini dilaksanakan untuk mengembangkan model prediksi status kelulusan mahasiswa Program Studi Sistem Informasi Universitas Multimedia Nusantara dengan memanfaatkan data akademik historis. Latar belakang penelitian didasarkan pada kebutuhan akan mekanisme prediksi berbasis data yang dapat membantu pemantauan risiko akademik mahasiswa secara lebih sistematis. Selama ini, pemantauan performa akademik masih dilakukan berdasarkan evaluasi hasil studi yang bersifat periodik, sehingga potensi risiko keterlambatan kelulusan atau dropout baru teridentifikasi setelah indikator akademik menunjukkan penurunan yang signifikan.

Data yang digunakan dalam penelitian ini berasal dari Biro Administrasi Akademik Universitas Multimedia Nusantara dan mencakup 1.024 mahasiswa angkatan 2020–2024. Setelah melalui proses pembersihan data, pelabelan status kelulusan, dan penyaringan berdasarkan ketersediaan status akhir studi, diperoleh 421 mahasiswa yang digunakan sebagai sampel penelitian. Dataset pemodelan dibangun dari fitur-fitur akademik hasil rekayasa data transkrip, meliputi IPK, IPS, total SKS yang ditempuh, jumlah SKS gagal, jumlah mata kuliah mengulang, rata-rata kehadiran, tren perubahan IPS, serta indikator konsistensi beban studi. Seluruh data telah dianonimkan dan hanya memuat informasi akademik yang relevan.

Pada tahap pemodelan, penelitian ini menggunakan tiga algoritma, yaitu CatBoost, Logistic Regression dengan regularisasi L1 (Lasso), dan *K-Nearest Neighbors* (KNN). Pembagian data dilakukan secara stratified dengan proporsi 80% data latih dan 20% data uji. Ketidakseimbangan kelas pada data latih ditangani menggunakan metode SMOTE. CatBoost pada tahap awal dikonfigurasi menggunakan parameter konservatif, yaitu 200 iterations, depth 4, learning rate 0,03, dan nilai regularisasi L2 sebesar 3. Model Lasso dikonfigurasi dengan penalti L1 dan nilai C sebesar 1,0, sedangkan KNN menggunakan jumlah tetangga sebanyak 15 dengan bobot uniform.

Sebagai bagian dari proses pemodelan, dilakukan optimasi *hyperparameter* pada model CatBoost menggunakan pendekatan Hyperopt berbasis *Tree-structured Parzen Estimator*. Optimasi dilakukan dengan memperluas ruang pencarian parameter, termasuk jumlah iterasi, kedalaman pohon, *learning rate*, regularisasi, serta parameter *subsampling* dan *random subspace*. Proses optimasi menghasilkan konfigurasi parameter dengan nilai iterasi dan kedalaman model yang lebih besar dibandingkan model *baseline*. Namun, ketika model hasil optimasi dievaluasi pada data uji, diperoleh nilai akurasi dan F1-score *macro* yang lebih rendah dibandingkan model CatBoost tanpa optimasi. Hal ini menunjukkan bahwa peningkatan kompleksitas model tidak selalu menghasilkan peningkatan kinerja pada data uji, khususnya pada dataset dengan ukuran terbatas dan distribusi kelas yang tidak seimbang.

Hasil evaluasi menunjukkan bahwa model CatBoost *baseline* menghasilkan akurasi sebesar 69,05% dengan nilai F1-score *macro* sebesar 0,593. Model ini menunjukkan kinerja yang relatif stabil pada sebagian besar kelas, dengan performa tertinggi pada kelas Dropout. Model Lasso menghasilkan akurasi sebesar 59,52% dengan nilai F1-score *macro* sebesar 0,539, sedangkan model KNN menghasilkan akurasi sebesar 58,33% dengan nilai F1-score *macro* sebesar 0,541. Perbedaan kinerja antar model menunjukkan bahwa pendekatan berbasis ensemble pohon keputusan lebih sesuai untuk menangkap pola pada data akademik yang memiliki hubungan nonlinier antar fitur.

Berdasarkan hasil evaluasi tersebut, CatBoost tanpa optimasi *hyperparameter* dipilih sebagai model terbaik dalam penelitian ini. Pemilihan ini didasarkan pada nilai kinerja yang lebih stabil pada data uji serta kesesuaian konfigurasi model dengan karakteristik dataset yang digunakan. Model hasil optimasi tetap memberikan informasi tambahan terkait sensitivitas parameter, tetapi tidak digunakan sebagai model akhir karena tidak menunjukkan peningkatan kinerja pada tahap evaluasi.

Selain pengukuran kinerja prediksi, penelitian ini juga menerapkan pendekatan Explainable AI menggunakan SHAP untuk menganalisis kontribusi

fitur terhadap hasil prediksi. Hasil analisis menunjukkan bahwa IPK, IPS, jumlah SKS gagal, total SKS yang ditempuh, serta tren perubahan IPS memiliki pengaruh yang signifikan terhadap prediksi status kelulusan mahasiswa. Analisis pada tingkat individu memperlihatkan hubungan antara nilai akademik, konsistensi beban studi, dan status kelulusan yang diprediksi oleh model.

Secara keseluruhan, penelitian ini menunjukkan bahwa penerapan model machine learning yang dikombinasikan dengan analisis interpretabilitas dapat digunakan untuk memprediksi status kelulusan mahasiswa berdasarkan data akademik historis. Hasil penelitian ini dapat dijadikan dasar pengembangan sistem pendukung pengambilan keputusan akademik yang berbasis data di lingkungan perguruan tinggi.

5.2 Saran

Berdasarkan hasil dan pembahasan penelitian yang telah dilakukan, beberapa saran dapat diajukan sebagai tindak lanjut dan pengembangan ke depan. Pertama, penelitian selanjutnya disarankan untuk mengembangkan pemodelan prediksi yang lebih adaptif terhadap tahapan studi mahasiswa, misalnya dengan membangun model terpisah atau bertingkat untuk setiap lapisan semester. Pendekatan ini penting karena karakteristik data, jumlah fitur, serta pola risiko mahasiswa pada semester awal berbeda dengan mahasiswa pada semester menengah maupun akhir, sehingga strategi intervensi yang dihasilkan dapat menjadi lebih tepat sasaran.

Kedua, diperlukan upaya peningkatan kinerja prediksi pada kelas-kelas yang masih memiliki nilai F1-score rendah, khususnya kategori Tidak Lulus Tepat Waktu dan Lulus Lebih Awal. Peningkatan ini dapat dilakukan melalui optimasi lanjutan pada model CatBoost, seperti eksplorasi parameter yang lebih luas, penggunaan teknik ensemble atau hybrid model, serta pengujian metode penyeimbangan data yang lebih variatif agar representasi kelas minoritas menjadi lebih kuat.

Ketiga, integrasi model ke dalam sistem operasional program studi perlu dipertimbangkan sebagai langkah lanjutan, misalnya dalam bentuk sistem

peringatan dini berbasis dashboard interaktif. Dengan integrasi tersebut, hasil prediksi dan interpretasi model dapat dimanfaatkan secara langsung oleh dosen pembimbing akademik untuk memantau risiko mahasiswa secara berkala dan mendukung pengambilan keputusan berbasis data.

Terakhir, penelitian mendatang juga disarankan untuk memperluas cakupan data, baik dengan menambahkan angkatan baru maupun mengombinasikan data akademik dengan sumber informasi lain yang relevan, selama tetap memperhatikan aspek etika dan privasi. Perluasan ini diharapkan dapat meningkatkan kemampuan generalisasi model serta memperkaya pemahaman terhadap faktor-faktor yang memengaruhi kelulusan mahasiswa secara lebih komprehensif.

