

BAB V

SIMPULAN DAN SARAN

5.1 Simpulan

Kesimpulan utama dari penelitian mengenai prediksi status kelulusan mahasiswa menggunakan model Machine Learning dengan pendekatan Hybrid Ensemble berbasis Voting Ensemble (hard voting dan soft voting). Kesimpulan dirumuskan berdasarkan tiga fokus analisis penelitian, yaitu evaluasi performa model individual, efektivitas metode Hybrid Ensemble dibandingkan model tunggal, serta identifikasi faktor-faktor yang paling berpengaruh terhadap prediksi status kelulusan mahasiswa melalui interpretasi SHAP. Kesimpulan ini dibangun berdasarkan hasil evaluasi empiris menggunakan stratified 5-fold cross-validation pada tiga tingkat kompleksitas prediksi (Semester 2, Semester 4, dan Semester 6) untuk memastikan generalisasi model yang lebih reliabel.

Hasil evaluasi performa model individual menunjukkan bahwa seluruh model (LightGBM, XGBoost, CatBoost, Random Forest, dan MLP) mengalami penurunan performa seiring bertambahnya jumlah kelas dan kompleksitas prediksi dari Semester 2 menuju Semester 6. Berdasarkan hasil yang ditampilkan, XGBoost dan LightGBM menunjukkan performa paling stabil dengan rata-rata akurasi dan F1-score di atas 80% pada semester awal, serta penurunan performa yang lebih terkendali ($\pm 20\%$). Sebaliknya, CatBoost dan MLP mengalami penurunan performa terbesar ketika berhadapan dengan skenario multi-class dan distribusi kelas yang tidak seimbang. Temuan ini menunjukkan bahwa pemodelan prediksi kelulusan menjadi semakin menantang pada semester lanjut karena kompleksitas pola akademik mahasiswa yang semakin bervariasi.

Pengujian terhadap Hybrid Ensemble berbasis Voting Ensemble memperlihatkan hasil yang lebih stabil dibandingkan model individual, khususnya ketika menghadapi kelas minoritas dan distribusi data yang tidak seimbang. Berdasarkan hasil penelitian bahwa Hybrid Ensemble mampu memberikan performa yang sebanding dengan model terbaik pada Semester 2, namun menawarkan distribusi prediksi yang lebih merata. Pada Semester 4, metode ini

berhasil meningkatkan recall pada kelas “Tidak Lulus Tepat Waktu”, yang sebelumnya sulit dideteksi oleh model individual. Pada Semester 6, Hybrid Ensemble secara konsisten mencapai performa terbaik dengan peningkatan F1-score sebesar 1–3 poin persentase dibandingkan model individual. Hasil ini menunjukkan bahwa pendekatan Voting Ensemble mampu mengombinasikan kekuatan masing-masing model dasar tanpa memerlukan arsitektur stacking yang lebih rumit dan berisiko overfitting pada ukuran dataset yang relatif kecil.

Interpretasi model menggunakan SHAP menghasilkan pemahaman yang lebih dalam mengenai faktor-faktor yang memengaruhi prediksi status kelulusan mahasiswa. Tabel 4.30 menunjukkan bahwa fitur temporal dan akademik, seperti TOTAL_SEMESTER, ANGKATAN, nilai_avg, TOTAL_SKS, serta hadir_consistency merupakan prediktor paling dominan. Fitur variabilitas seperti nilai_std dan hadir_std menegaskan bahwa ketidakstabilan performa akademik merupakan indikator risiko yang penting. Sementara itu, fitur demografis dan sosial ekonomi memberikan kontribusi moderat namun tetap relevan, seperti tingkat pendidikan orang tua dan lokasi asal mahasiswa. Selain bersifat deskriptif, analisis SHAP juga menghasilkan rekomendasi operasional yang dapat diterapkan. Misalnya, mahasiswa dengan TOTAL_SEMESTER tinggi tetapi progress SKS rendah dan konsistensi kehadiran menurun dapat dimasukkan ke dalam kategori risiko tinggi dan diintervensi melalui mentoring akademik, program remedial, atau monitoring intensif oleh pembimbing akademik.

Secara keseluruhan, penelitian ini memberikan kontribusi penting baik dari sisi metodologis maupun praktis. Dari sisi metodologi, penelitian ini menunjukkan bahwa Hybrid Ensemble berbasis Voting dapat menjadi pendekatan alternatif yang efektif untuk prediksi multi-class pada dataset berukuran kecil tanpa memerlukan proses stacking atau pelatihan dua-level model. Dari sisi penerapan, model dan interpretasi berbasis SHAP dapat dimanfaatkan untuk mendukung sistem *Early Warning* yang lebih adaptif dan personal, sehingga institusi pendidikan dapat mengidentifikasi mahasiswa berisiko lebih awal dan mengambil langkah intervensi yang tepat. Dengan demikian, penelitian ini tidak hanya memberikan kontribusi teoritis terhadap pengembangan model prediktif dalam *educational data mining*,

tetapi juga manfaat praktis dalam mendukung strategi peningkatan kualitas akademik berbasis data.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa rekomendasi yang dapat dipertimbangkan untuk pengembangan penelitian selanjutnya maupun implementasi praktis di lingkungan institusi pendidikan. Penelitian selanjutnya disarankan menggunakan dataset dengan ukuran lebih besar dan cakupan angkatan yang lebih beragam agar kemampuan generalisasi model dapat diuji secara lebih komprehensif. Selain itu, penggunaan *hold-out validation* khusus atau *out-of-time validation* berbasis cohort independen perlu dipertimbangkan untuk memastikan bahwa model tetap stabil ketika digunakan pada data angkatan baru yang tidak dilibatkan dalam proses pelatihan.

Pengembangan fitur (*feature engineering*) juga berpotensi meningkatkan performa model secara signifikan. Penelitian ini masih berfokus pada data akademik, biodata, serta sebagian indikator perilaku seperti kehadiran dan keaktifan organisasi. Pada penelitian berikutnya, fitur berbasis *learning analytics* seperti aktivitas pada Learning Management System (LMS), pola pengerjaan tugas, interaksi forum, waktu pengumpulan tugas, hingga pola login dapat dipertimbangkan. Integrasi fitur tersebut dapat membantu model memahami pola belajar mahasiswa secara lebih dinamis dan kontekstual sehingga prediksi risiko akademik menjadi lebih akurat.

Dari sisi implementasi, hasil penelitian ini dapat dimanfaatkan sebagai dasar pengembangan *Early Warning System* berbasis data untuk mendukung proses monitoring dan intervensi akademik. Model prediksi berperan sebagai detektor risiko, sedangkan interpretasi SHAP dapat digunakan untuk menjelaskan alasan munculnya prediksi tersebut sehingga pihak kampus dapat mengambil tindakan yang tepat dan sesuai konteks. Implementasi praktis sistem peringatan dini perlu disertai mekanisme pendampingan yang jelas, seperti konseling akademik,

mentoring, program remedial, dukungan finansial, atau pembimbingan personal bagi mahasiswa berisiko tinggi.

Untuk pengembangan metodologis, penelitian selanjutnya dapat mempertimbangkan penggunaan pendekatan modeling yang lebih kompleks seperti *deep learning*, *time-series modeling*, atau model *transformer-based* untuk menganalisis dinamika perubahan performa mahasiswa sepanjang masa studi. Selain itu, eksplorasi bentuk ensemble lain seperti blending atau *stacking two-level*, dapat menjadi opsi jika tersedia dataset yang lebih besar untuk mengurangi risiko *overfitting*. Dengan melakukan perluasan tersebut, diharapkan penelitian lanjutan dapat menghasilkan model yang lebih adaptif, lebih generalizable, serta semakin tepat guna dalam mendukung pengambilan keputusan berbasis data di institusi pendidikan.

