

BAB V PENUTUP

5.1 Kesimpulan

Setelah melakukan kajian dan penelitian yang membahas tentang analisis perbandingan kinerja Algoritma *Random Forest* dan *Gradient Boosting* dalam prediksi penyakit gagal ginjal kronis, penelitian ini memperoleh beberapa hasil yang dapat diuraikan dalam kesimpulan sebagai berikut:

1. Berdasarkan hasil penelitian, setelah dilakukan analisis dan evaluasi, Algoritma *Random Forest* mencapai akurasi sebesar 98%, sedangkan *Gradient Boosting* mencapai akurasi sebesar 96%. Dari hasil tersebut, dapat disimpulkan bahwa *Random Forest* lebih unggul dalam memprediksi penyakit gagal ginjal kronis dibandingkan dengan *Gradient Boosting*.
2. Berdasarkan analisis korelasi antara fitur dan target, hubungan yang terbentuk tidak terlalu kuat. Hal ini menunjukkan bahwa setiap faktor tetap memiliki kontribusi dalam membangun model prediksi yang lebih komprehensif.

Faktor-faktor utama yang berpengaruh dalam model ini mencakup karakteristik individu, seperti 'Age', 'Gender', 'SocioeconomicStatus', dan 'EducationLevel', yang dapat memberikan gambaran awal mengenai risiko penyakit. Selain itu, gaya hidup dan kebiasaan kesehatan seperti 'BMI', 'Smoking', 'AlcoholConsumption', 'PhysicalActivity', 'DietQuality', dan 'SleepQuality' berkontribusi dalam menentukan kondisi kesehatan secara umum.

Dari aspek riwayat medis, faktor-faktor seperti 'FamilyHistoryKidneyDisease', 'FamilyHistoryHypertension', 'FamilyHistoryDiabetes', 'PreviousAcuteKidneyInjury', dan 'UrinaryTractInfections' menjadi indikator penting dalam mendeteksi potensi risiko. Sementara itu, parameter klinis seperti 'SystolicBP', 'DiastolicBP', 'FastingBloodSugar', 'HbA1c', 'SerumCreatinine', 'BUNLevels', 'GFR', 'ProteinInUrine', dan 'ACR' memiliki peran

besar dalam mengevaluasi fungsi ginjal dan kesehatan metabolik.

Selain itu, elektrolit darah dan kadar lipid ('SerumElectrolytesSodium', 'SerumElectrolytesPotassium', 'SerumElectrolytesCalcium', 'SerumElectrolytesPhosphorus', 'HemoglobinLevels', 'CholesterolTotal', 'CholesterolLDL', 'CholesterolHDL', 'CholesterolTriglycerides') turut berkontribusi dalam analisis prediksi. Pengaruh penggunaan obat-obatan ('ACEInhibitors', 'Diuretics', 'NSAIDsUse', 'Statins', 'AntidiabeticMedications') serta gejala klinis ('Edema', 'FatigueLevels', 'NauseaVomiting', 'MuscleCramps', 'Itching') juga menjadi pertimbangan dalam model.

Terakhir, faktor lingkungan dan kepatuhan pasien terhadap perawatan kesehatan seperti 'HeavyMetalsExposure', 'OccupationalExposureChemicals', 'WaterQuality', 'MedicalCheckupsFrequency', 'MedicationAdherence', dan 'HealthLiteracy' semakin melengkapi model dalam memahami pola risiko penyakit.

Dengan mempertimbangkan semua faktor ini, model dapat mengidentifikasi pola yang lebih mendalam dan meningkatkan ketepatan prediksi. Hasil ini mendukung pengambilan keputusan medis yang lebih baik dalam pengembangan model yang lebih presisi dalam diagnosis dan pencegahan penyakit.

5.2 Saran

Mengingat masih adanya kekurangan pada penelitian yang dijalankan, penulis memberikan beberapa saran yang dapat menjadi acuan dalam melakukan studi serupa di masa mendatang, sebagai berikut :

1. Eksperimen dengan Algoritma yang berbeda dari yang digunakan dalam penelitian untuk memperkaya hasil dan memberikan perspektif baru
2. Menguji model pada dataset lain di luar Kaggle untuk melihat apakah hasilnya tetap konsisten