

BAB V PENUTUP

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa metode problem transformation yaitu Binary Relevance, Classifier Chain, dan Label Powerset berhasil diterapkan pada model klasifikasi multi-label manfaat dan efek samping produk kosmetik. Penerapan metode problem transformation dilakukan melalui beberapa tahapan utama, yaitu preprocessing data, pembentukan label multi-label menggunakan MultiLabel Binarizer, transformasi fitur menggunakan TF-IDF dan One-Hot Encoding, serta seleksi fitur menggunakan Mutual Information dan Chi-Square untuk memperoleh fitur yang paling relevan. Selanjutnya, dilakukan pembagian data menjadi data latih dan data uji, diikuti dengan proses pelatihan model menggunakan algoritma XGBoost sebagai base classifier. Tahap akhir berupa evaluasi model menggunakan metrik multi-label seperti F1-Score (Micro, Macro, dan Weighted), Hamming Loss, serta Subset Accuracy untuk mengukur dan membandingkan performa masing-masing metode.

Selanjutnya, berdasarkan hasil matriks evaluasi, metode Binary Relevance dan Classifier Chain menunjukkan performa terbaik dengan nilai F1-Score Micro dan Weighted masing-masing sebesar 94%, serta Hamming Loss sebesar 5% yang menandakan kesalahan prediksi relatif rendah. Pada F1-Score Macro, Binary Relevance sedikit lebih unggul (94%) dibandingkan Classifier Chain (93%). Kedua metode juga mencapai Subset Accuracy sebesar 64%, yang menunjukkan kemampuan cukup baik dalam memprediksi kombinasi label. Sementara itu, Label Powerset memiliki performa lebih rendah dengan F1-Score Micro 77%, F1-Score Macro 71%, F1-Score Weighted 76%, Hamming Loss 15%, dan Subset Accuracy 25%, akibat meningkatnya jumlah kelas dan distribusi data yang tidak merata. Dengan demikian, Binary Relevance dan Classifier Chain menjadi metode

yang paling optimal, tanpa perbedaan performa yang signifikan di antara keduanya.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran untuk pengembangan penelitian selanjutnya. Pertama, disarankan untuk mencoba penggunaan algoritma lain sebagai base classifier, seperti Random Forest atau pendekatan deep learning, guna mengetahui potensi peningkatan performa model dalam klasifikasi multi-label. Kedua, penanganan ketidakseimbangan data (imbalance data) dapat dilakukan secara lebih optimal, misalnya dengan teknik Synthetic Oversampling of Multi-Label Data Based on Local Label Distribution (MLSOL), dan Integrating Unsupervised Clustering and Label-specific Oversampling to Tackle Imbalanced Multi-Label Data (UCLSO) agar performa model pada label minoritas dapat meningkat. Ketiga, disarankan untuk melakukan hyperparameter tuning yang lebih luas dan mendalam agar model dapat mencapai performa yang lebih optimal.

Selain itu, selama penelitian terdapat beberapa kendala yang dihadapi. Salah satunya adalah ketidakseimbangan distribusi label yang menyebabkan beberapa label memiliki performa rendah. Selain itu, metode Label Powerset memiliki kompleksitas yang tinggi karena menggabungkan kombinasi label menjadi kelas baru, sehingga jumlah kelas meningkat secara signifikan dan berdampak pada lamanya waktu pelatihan, terutama pada dataset berukuran besar. Proses transformasi teks menggunakan TF-IDF juga menghasilkan fitur berdimensi tinggi yang meningkatkan kebutuhan komputasi. Oleh karena itu, disarankan untuk menggunakan perangkat dengan spesifikasi yang memadai serta mempertimbangkan teknik optimasi agar proses pelatihan model dapat berjalan lebih efisien.