

BAB V PENUTUP

5.1 Kesimpulan

Dari hasil-hasil yang telah diperoleh, kita dapat mengambil beberapa kesimpulan:

5.1.1 Model Tanpa PSO:

1. Model Naive Bayes yang dilatih tanpa menggunakan Particle Swarm Optimization (PSO) memiliki akurasi sekitar 61.53% pada set pengujian.
2. Parameter model mengalami penyesuaian tambahan, yaitu dengan menambahkan fitur seleksi pada data.
3. Seleksi fitur yang digunakan adalah 6, jadi fitur yang dipilih enam fitur terbaik untuk pelatihan data.

5.1.2 Model Dengan Particle Swarm Optimization (PSO):

1. Menggunakan Particle Swarm Optimization (PSO) untuk mengoptimalkan parameter model Naive Bayes memberikan hasil yang lebih baik.
2. Model Naive Bayes dengan particle swarm optimization (PSO) ada tambahan seleksi fitur, seleksi fitur yang digunakan adalah 6, jadi fitur yang dipilih enam fitur terbaik untuk pelatihan data.
3. Setelah optimasi, model Naive Bayes memiliki akurasi sekitar 76.92% pada set pengujian.
4. Parameter terbaik yang ditemukan untuk **var_smoothing** adalah sekitar 0.00516891460773298.

5.1.3 Kesimpulan Umum:

Particle Swarm Optimization (PSO) digunakan untuk mengoptimalkan parameter **var_smoothing** dari model Gaussian Naive Bayes. **var_smoothing** adalah parameter yang mengontrol kehalusan estimasi likelihood dalam algoritma Naive Bayes. Nilai **var_smoothing** biasanya digunakan untuk menghindari probabilitas nol dan untuk meratakan distribusi probabilitas. Evaluasi dan

pemilihan parameter yang tepat dapat secara signifikan meningkatkan akurasi model, membuatnya lebih dapat diandalkan dalam memprediksi label pada data baru.

Dengan demikian, hasil eksperimen ini menunjukkan bahwa particle swarm optimization (PSO) dapat menjadi alat yang berguna untuk mengoptimalkan parameter model, terutama pada kasus seperti model Naive Bayes yang menggunakan parameter seperti **var_smoothing**.

5.2 Saran

Berdasarkan hasil eksperimen tersebut, beberapa saran dapat diajukan guna penelitian kedepannya:

1. Optimasi Lanjutan:

Melakukan eksplorasi lebih lanjut terhadap ruang parameter menggunakan particle swarm optimization (PSO) atau metode optimasi lainnya mungkin menghasilkan peningkatan lebih lanjut dalam kinerja model. Variasi pada nilai batas (bounds) atau jumlah iterasi particle swarm optimization (PSO) dapat dieksplorasi untuk menemukan nilai parameter yang lebih optimal.

2. Evaluasi Metrik Lain:

Selain akurasi, juga pertimbangkan untuk mengevaluasi model menggunakan metrik lain seperti presisi, recall, atau F1-score, terutama jika distribusi kelas tidak seimbang. Metrik-metrik ini memberikan wawasan tambahan tentang kinerja model di berbagai aspek.

3. Pemahaman Lebih Lanjut terhadap Data:

Menjalankan analisis eksploratif lebih lanjut pada data, memahami distribusi, dan karakteristiknya dapat membantu dalam pemilihan fitur yang lebih baik atau menemukan pola-pola penting yang dapat meningkatkan performa model.

4. Penyetelan Model Lain:

Mempertimbangkan penyetelan parameter pada model klasifikasi lainnya atau bahkan mencoba model yang berbeda dapat memberikan wawasan tambahan tentang mana model yang paling sesuai untuk dataset yang diberikan.

5. Validasi Silang (Cross-Validation):

Melakukan validasi silang pada proses penyetelan model dapat membantu memitigasi risiko *overfitting* dan memberikan estimasi kinerja yang lebih stabil.

6. Interpretasi Hasil:

Memahami arti dari nilai-nilai yang dioptimalkan dan dampaknya terhadap model dapat membantu interpretasi hasil dan pemahaman terhadap faktor-faktor yang memengaruhi kinerja model.

Setiap saran di atas dapat membantu meningkatkan pemahaman dan kinerja model, dan pemilihan strategi tergantung pada tujuan spesifik dan konteks masalah yang dihadapi.