

## BAB 5

### KESIMPULAN DAN SARAN

Berdasarkan hasil analisa pada penelitian, penulis mendapatkan kesimpulan dan saran sebagai berikut.

#### 5.1 Kesimpulan

Kesimpulan penelitian ini dirumuskan berdasarkan jawaban atas rumusan masalah yang diajukan:

1. Berdasarkan hasil pengujian performa, model XGBoost dengan kombinasi fitur YUV dan tekstur (LBP, GLRLM, dan Tamura) memberikan hasil terbaik dengan nilai akurasi 90.91%, presisi 93.75%, spesifisitas 93.75%, *recall* 88.24%, dan *F1-score* 90.91%. Nilai-nilai tersebut menunjukkan keseimbangan performa yang baik antar metrik, menjadikan model ini paling optimal dibandingkan kombinasi ruang warna dan model lainnya.
2. Berdasarkan analisis *feature ranking*, fitur yang paling berpengaruh terhadap performa model XGBoost YUV + Tekstur adalah *std\_lbp* (0.1575) dan *contrast\_tamura* (0.1152). Hal ini menunjukkan bahwa informasi tekstur memiliki peran dominan dalam mendekripsi pola citra lesi serviks, sedangkan fitur warna YUV seperti *mean\_u*, *skew\_y*, dan *std\_v* memberikan kontribusi pelengkap.

3. Secara keseluruhan, menunjukkan bahwa kombinasi fitur warna dan tekstur memberikan peningkatan performa signifikan dibandingkan penggunaan fitur tunggal. Integrasi kedua jenis fitur memungkinkan model untuk menangkap variasi pola citra yang lebih kompleks dan meningkatkan stabilitas antar metrik evaluasi.
4. Hasil perbandingan antara dua algoritma *ensemble* menunjukkan bahwa XGBoost lebih unggul dibandingkan AdaBoost dalam hal kestabilan metrik dan generalisasi model, terutama saat menggunakan kombinasi fitur YUV dan tekstur. Hal ini karena XGBoost memiliki mekanisme regularisasi yang lebih baik dalam mengatasi *overfitting* serta mampu menjaga keseimbangan antara akurasi dan *recall*.

## 5.2 Saran

Untuk penelitian selanjutnya yang relevan dengan topik ini, disarankan hal-hal berikut:

1. Melakukan penelitian dengan menggunakan dataset citra IVA yang lebih besar dan bervariasi agar model dapat belajar pola citra dengan lebih representatif dan meningkatkan kemampuan generalisasi.
2. Menggunakan arsitektur *Convolutional Neural Network* (CNN) atau *transfer learning* seperti *ResNet* dan *EfficientNet* untuk melihat apakah hasil klasifikasi dapat meningkat dibandingkan metode ensemble berbasis ekstraksi fitur manual.

3. Penggunaan metode *feature selection* lain seperti *Mutual Information Gain* atau *SHAP Analysis* dapat dipertimbangkan untuk memperdalam pemahaman terhadap kontribusi fitur individu terhadap keputusan model.
4. Menganalisis momen warna dan kombinasi fitur pada ruang warna lain seperti HSV/HSL yang memisahkan *Hue* (corak), *Saturation* (kejemuhan), dan *Value/Lightness* (kecerahan), yang mungkin dapat memberikan representasi warna yang lebih baik terhadap warna lesi *acetowhitening*.