

## BAB V

### PENUTUP

#### 5.1. Kesimpulan

Penelitian ini bertujuan untuk mengevaluasi penerapan metode augmentasi data berbasis *Wasserstein Generative Adversarial Network with Gradient Penalty* (WGAN-GP) dalam mendukung deteksi abnormalitas morfologi kepala sperma dari citra mikroskopis, serta membandingkan efektivitasnya dengan metode augmentasi tradisional. Dari hasil implementasi dan eksperimen, diperoleh kesimpulan sebagai berikut:

1. Model WGAN-GP yang dilatih menggunakan dataset primer berupa hasil *cropping* objek tunggal dari citra mikroskopis multi-objek menghasilkan nilai *Fréchet Inception Distance* (FID) terendah sebesar 110, yang mengindikasikan bahwa kualitas citra sintetis secara umum masih belum optimal. Meskipun demikian, beberapa citra hasil sintesis menunjukkan bentuk morfologi kepala *spermatozoa* yang mulai terbentuk dan masih dapat dikenali, sehingga tetap layak digunakan untuk evaluasi lebih lanjut. Variasi kualitas ini diduga disebabkan oleh kompleksitas data, seperti perbedaan pencahayaan, tekstur, ukuran objek, serta keberadaan oklusi yang menyebabkan lebih dari satu objek dalam satu citra.
2. Berdasarkan hasil pada Tabel 4.7, diketahui bahwa augmentasi menggunakan WGAN-GP (Skenario 2) menghasilkan peningkatan performa dibandingkan model tanpa augmentasi (Skenario 1). Nilai presisi meningkat dari 0.449 menjadi 0.569,  $mAP@0.5$  dari 0.494 menjadi 0.595, dan  $mAP@0.5:0.95$  dari 0.263 menjadi 0.309, meskipun *recall* sedikit menurun dari 0.723 menjadi 0.664. Hal ini menunjukkan bahwa sebagian citra hasil WGAN-GP masih memberikan kontribusi positif terhadap pelatihan model deteksi.
3. Berdasarkan data pada tabel, metode augmentasi geometris tradisional (Skenario 2) menghasilkan performa model deteksi yang tertinggi dan lebih unggul dibandingkan dengan augmentasi WGAN-GP (Skenario 3). Hal ini terlihat dari perbandingan langsung di semua metrik evaluasi, di mana Skenario 2 secara konsisten memiliki nilai yang lebih tinggi. Nilai Presisi (0.569 vs 0.506), *Recall* (0.664 vs 0.644),  $mAP@0.5$  (0.595 vs 0.539), dan

mAP@0.5:0.95 (0.309 vs 0.284) semuanya lebih baik pada model yang menggunakan augmentasi geometris tradisional.

## 5.2. Saran Pengembangan

Berdasarkan hasil temuan dan keterbatasan yang dihadapi selama penelitian, berikut saran yang dapat diajukan untuk penelitian lanjutan:

1. Gunakan arsitektur GAN yang bersifat kondisional, seperti cGAN atau cWGAN-GP, untuk memberikan kontrol eksplisit terhadap kelas objek yang ingin dihasilkan. Dengan pendekatan ini, model dapat diarahkan untuk mempelajari representasi objek tertentu, sehingga mengurangi risiko mode collapse.
2. Pertimbangkan untuk memecah dataset multi-objek menjadi subset yang lebih sederhana, misalnya dataset per kelas atau citra single-objek, agar model lebih mudah mempelajari distribusi masing-masing kelas sebelum digabungkan dalam bentuk multi objek.
3. Eksplorasi pendekatan arsitektural yang lebih modern, seperti StyleGAN atau *diffusion-based generative models*, yang telah terbukti lebih unggul dalam menghasilkan struktur objek kompleks pada domain citra medis.
4. Eksplorasi metode *preprocessing* untuk dilakukan *Enhancement* lebih lanjut agar menghasilkan kualitas yang lebih baik.