

BAB V

PENUTUP

5.1. Kesimpulan

Setelah melalui rangkaian tahapan penelitian mulai dari akuisisi data mikroskopis yang kompleks hingga tahap pengembangan model, penelitian ini berhasil membuktikan bahwa teknologi *Deep Learning* dapat diandalkan untuk otomatisasi analisis sperma. Berdasarkan hasil penelitian yang diperoleh, dapat ditarik beberapa kesimpulan utama sebagai berikut:

1. Pemanfaatan arsitektur *3D-Convolutional Neural Network* (3D-CNN) berhasil mengekstraksi fitur spasial dan temporal secara simultan dari klip video. Model ini tidak hanya mengenali bentuk sperma, tetapi juga memahami pola pergerakan dalam dimensi waktu melalui klip 32 *frame*. Berdasarkan hasil evaluasi, model ini mencapai akurasi sebesar 79%. Secara mendetail, model menunjukkan performa luar biasa pada kelas *Progressive* dan *Immotile*, meskipun terdapat tantangan kecil pada kelas *Progressive* karena adanya kemiripan karakteristik kecepatan pada ambang batas klasifikasi tertentu.
2. Pendekatan klasifikasi morfologi melalui model EfficientNet-V2 memberikan hasil yang sangat akurat dengan akurasi mencapai 97%. Keberhasilan ini didorong oleh proses *ROI Cropping* yang presisi dan teknik *Image Enhancement* menggunakan operasi morfologi erosi. Proses tersebut berhasil mengisolasi objek sperma tunggal dan memperjelas struktur kepala serta ekor. Penggunaan *Binary Focal Crossentropy* sebagai fungsi *loss* terbukti efektif dalam menangani karakteristik data yang sulit diklasifikasikan, sehingga model mampu mengenali sperma abnormal dengan nilai *Precision* dan *Recall* yang hampir sempurna (0.98).
3. Penelitian ini berhasil mewujudkan sistem utuh (*end-to-end*) yang diintegrasikan melalui kerangka kerja Streamlit. Sistem ini mampu menjembatani kerumitan model *Deep Learning* ke dalam antarmuka yang ramah pengguna. Alur kerja paralel dimana video diolah secara bersamaan oleh model motilitas dan morfologi berhasil dikelola dengan baik oleh basis data

Pandas. Hasil akhirnya adalah sebuah *dashboard* yang mampu menampilkan persentase kesehatan sperma, hingga indikasi klinis jenis abnormalitas berdasarkan WHO, sehingga data medis yang kompleks dapat dipahami dengan cepat oleh tenaga profesional.

4. Secara keseluruhan, sistem yang dikembangkan telah menjawab kebutuhan akan analisis yang lebih objektif dan efisien dibandingkan metode manual. Penggunaan metrik evaluasi seperti *Confusion Matrix* dan *Classification Report* membuktikan bahwa model memiliki kemampuan generalisasi yang baik dan minim bias meskipun terdapat ketidakseimbangan kelas data (*class imbalance*). Pada pengujian parameter *motility*, arsitektur 3D-CNN berhasil mencapai akurasi sebesar 79%, yang menunjukkan efektivitas model dalam menangkap fitur temporal dari pergerakan spermatozoa secara dinamis. Sementara itu, pada parameter morfologi, penggunaan model EfficientNet-V2 yang didukung oleh teknik *image enhancement* menghasilkan akurasi yang lebih tinggi yaitu sebesar 97%, yang menegaskan presisi sistem dalam mengklasifikasikan detail struktur visual sel.

4.2. Saran Pengembangan

Berdasarkan hasil penelitian dan keterbatasan yang ditemukan selama proses pengembangan sistem, berikut adalah beberapa saran yang diusulkan untuk pengembangan penelitian di masa mendatang:

1. Peningkatan kualitas data pada tahap akuisisi yang bertujuan untuk menghasilkan performa model yang lebih reliabel dengan melakukan standardisasi pada aspek teknis perekaman video mikroskopis, seperti pengaturan intensitas pencahayaan yang lebih stabil serta penggunaan kamera mikroskop dengan resolusi dan *frame rate* yang lebih tinggi. Peningkatan kualitas sensor sejak tahap awal akan meminimalkan munculnya *noise* dan *artifacts* pada video, sehingga memudahkan proses ekstraksi fitur tanpa memerlukan tahap *enhancement* yang terlalu berat di sisi komputasi.
2. Penelitian selanjutnya diharapkan dapat memperbanyak volume dataset secara organik, terutama untuk kategori kelas minoritas seperti sperma dengan morfologi normal dan motilitas *immotile*. Dengan variasi data yang lebih kaya

dan mencakup berbagai kondisi klinis yang berbeda, model akan memiliki kemampuan generalisasi yang lebih kuat dalam mengenali fitur-fitur unik spermatozoa. Hal ini akan mengurangi ketergantungan pada teknik augmentasi buatan dan meningkatkan nilai *F1-Score* pada pengujian data riil di lapangan.

3. Perlu dilakukan kajian lebih lanjut dengan membandingkan kemampuan algoritma *particle tracking* konvensional lainnya terhadap metode berbasis objek seperti *Bounding Box* (misalnya menggunakan YOLO atau DeepSORT). Pendekatan ini bertujuan untuk mengevaluasi efisiensi dan akurasi dalam membedakan sperma yang saling tumpang tindih (*overlap*) atau berdekatan secara rapat. Dengan membandingkan kedua pendekatan ini, dapat ditemukan metode pelacakan yang paling optimal untuk kondisi sampel sperma dengan kepadatan tinggi (hiper-konsentrasi).
4. Optimasi Hyperparameter dan Eksperimen Arsitektur dengan tujuan untuk mencapai performa yang benar-benar maksimal. Pengembangan ke depan dapat difokuskan pada pengujian *hyperparameter* yang lebih mendalam, seperti variasi *learning rate*, hingga penggunaan *scheduler* yang lebih kompleks. Selain itu, eksplorasi terhadap arsitektur *Deep Learning* terbaru lainnya atau teknik *ensemble* antara model motilitas dan morfologi dapat dilakukan untuk menekan tingkat kesalahan klasifikasi pada area batas (*borderline cases*), sehingga sistem dapat memberikan hasil analisis yang lebih presisi dan mendekati standar emas laboratorium klinis.