

BAB I

PENDAHULUAN

1.1. Latar Belakang

Para ilmuwan telah melaporkan bahwa infertilitas telah menjadi masalah yang cukup mengancam bagi para pasangan berkeluarga. Berdasarkan statistik, hampir 15% pasangan menderita masalah infertilitas di seluruh dunia [1]. Pada tahun 1999, penelitian WHO menunjukkan bahwa jumlah pasangan dengan masalah infertilitas di Amerika Serikat, hampir 35-40% masalah disebabkan oleh pria, dan hampir 35% disebabkan oleh wanita, 20% disebabkan oleh masalah pada kedua jenis kelamin dan 10% karena alasan yang tidak diketahui [2].

Dewasa ini, bagi kebanyakan pasangan yang infertil, In-Vitro Fertilization (IVF) adalah salah satu cara untuk memperoleh keturunan. Terutama dengan metode Intracytoplasmic Sperm Injection (ICSI), penyuntikan satu sperma hidup ke dalam sel telur. Walaupun demikian, dikarenakan sulitnya untuk menemukan sel sperma dengan kualitas baik, IVF memiliki tingkat kegagalan yang cukup tinggi, yaitu sekitar 60-70% [3]

Menurut penelitian yang dilakukan oleh WHO, kualitas sperma itu sendiri dapat ditentukan dari konsentrasi sperma, jenis arah pergerakannya, dan morfologinya (bentuk dan ukuran dari kepala dan ekor sperma) [4]. Berdasarkan beberapa kriteria tersebut, analisa pergerakan dari sperma diperlukan untuk menentukan tingkat kesuburan sperma. Sayangnya, melakukan penilaian pada motilitas sel sperma sangat sulit dilakukan dikarenakan pergerakannya yang sangat cepat. Maka dari itu, pada akhir 1980-an CASA (Computer-Aided Sperm Analysis) dibuat untuk menganalisa karakteristik pergerakan sperma [5]. Seiring berkembangnya teknologi, CASA juga mengalami perkembangan yang cukup signifikan beberapa tahun belakang ini dan dapat digunakan jauh lebih cepat dan akurat daripada penelitian secara manual [6]. Otomatisasi analisis morfologi spermatozoa menggunakan visi komputer menghadirkan serangkaian tantangan yang berbeda dari tugas deteksi objek pada umumnya. Keberhasilan sebuah model sangat bergantung pada kemampuannya untuk mengatasi kendala-kendala berikut:

- Tantangan 1: Objek Berukuran Kecil dan Bervariasi: Spermatozoa dan komponennya (kepala, akrosom, vakuola) secara inheren merupakan objek yang sangat kecil relatif jika dibandingkan dengan keseluruhan 1 layar pandang citra mikroskopis. Hal ini membuat proses deteksi ini secara tegas termasuk dalam kategori "deteksi objek kecil" (small object detection), yang merupakan salah satu tantangan paling sulit dalam visi komputer karena informasi visual yang terbatas dan hilangnya detail spasial selama proses downsampling di dalam arsitektur CNN manapun [7].
- Tantangan 2: Kelangkaan Data dan Ketidakseimbangan Kelas: Dataset citra medis, termasuk untuk analisis sperma, seringkali sulit diperoleh dalam jumlah besar, yang dapat membatasi kemampuan generalisasi model. Lebih lanjut, dalam konteks klinis, jumlah sampel sperma dengan morfologi abnormal mungkin jauh lebih sedikit daripada sampel normal. Ketidakseimbangan kelas (class imbalance) ini dapat menyebabkan model menjadi bias terhadap kelas mayoritas (normal) dan gagal mendeteksi kelainan yang mana lebih jarang dengan baik [8].
- Tantangan 3: Kontras Rendah dan Noise Visual: Citra mikroskopis, terutama dari sampel yang tidak diwarnai (*unstained*), seringkali memiliki kontras yang rendah antara objek dan latar belakang. Selain itu, adanya kotoran sel, sel lain, atau artefak dalam data dapat menciptakan *noise visual* yang signifikan, yang berpotensi menyebabkan prediksi positif palsu (false positives). Maka dari itu dibutuhkan penerapan machine learning yang lebih advance dengan menerapkan metode pembelajaran deep learning [9].

Deep learning berkontribusi dalam perkembangan pemrosesan citra mengalami peningkatan dari segi kecepatan dan akurasi dengan adanya CNN [10]. CNN adalah satu dari sekian banyak algoritma pada deep learning yang dapat menerima input berupa citra, dan menentukan fitur apa saja yang ada pada suatu citra yang bisa digunakan untuk mendeteksi dan membedakan satu citra dengan citra yang lain [11]. Hal ini tentunya akan sangat membantu dalam penerapan CASA, karena

tahapan pertama dari analisa sperma adalah deteksi sperma [12]. Seiring berkembangnya deep learning, berbagai arsitektur Convolutional Neural Network (CNN) telah dikembangkan untuk tugas deteksi objek. Penerapan CNN sebagai pendeteksi objek tampak dengan adanya berbagai macam arsitektur CNN seperti, YOLO, R-CNN, SSD dan RetinaNet. Secara umum, arsitektur-arsitektur ini dapat dikategorikan ke dalam dua paradigma utama: two-stage detector dan one-stage detector [13]. Two-stage detector, seperti keluarga R-CNN, dikenal dengan akurasi yang sangat tinggi karena melakukan proses deteksi dalam dua tahap sekuensial: proposal wilayah dan klasifikasi. Namun, proses ini membutuhkan biaya komputasi yang tinggi, sehingga menghasilkan kecepatan inferensi yang rendah dan kurang sesuai untuk aplikasi analisis video secara real-time. Mengingat tantangan dalam penelitian ini adalah untuk menganalisis sperma yang bergerak dengan cepat dari data video mikroskopis dengan waktu yang terbatas, diperlukan sebuah pendekatan yang memprioritaskan kecepatan pemrosesan (*throughput*) tinggi tanpa mengorbankan nilai akurasi secara signifikan. Oleh karena itu, paradigma one-stage detector menjadi pilihan yang lebih pragmatis.

Di antara arsitektur one-stage detector yang populer seperti YOLO (You Only Look Once) dan SSD (Single Shot MultiBox Detector), SSD dipilih karena kemampuannya yang telah terbukti dalam memberikan keseimbangan yang optimal antara kecepatan dan akurasi [14]. Namun, sebuah tantangan krusial dalam deteksi sperma adalah ukurannya yang relatif kecil terhadap keseluruhan citra, sebuah area di mana arsitektur SSD standar diketahui memiliki keterbatasan. Untuk mengatasi masalah spesifik ini, penelitian ini tidak menggunakan arsitektur SSD standar, melainkan mengadopsi sebuah varian yang telah disempurnakan untuk mengatasi kelemahan tersebut.

Metode yang dipilih untuk penelitian ini adalah MobileNetV2 SSD FPN-Lite 320x320. Arsitektur ini merupakan sebuah kombinasi sinergis dari tiga komponen teknologi kunci yang dirancang untuk mengatasi tantangan-tantangan yang ada. Pertama, MobileNetV2 digunakan sebagai jaringan backbone atau pengekstraksi fitur. MobileNetV2 dirancang khusus untuk efisiensi komputasi tinggi dengan memanfaatkan *depthwise separable convolutions*, yang secara drastis mengurangi

beban komputasi dan memungkinkan pemrosesan real-time bahkan pada perangkat keras *non-spesialis*. Kedua, kerangka kerja SSD menjadi dasar sebagai detektor satu tahap (*one stage detector*) yang menjamin kecepatan deteksi yang tinggi. Ketiga, dan yang terpenting, arsitektur ini diperkuat dengan Feature Pyramid Network Lite (FPN-Lite). FPN-Lite adalah mekanisme pengekstraksi fitur yang secara khusus dirancang untuk meningkatkan kemampuan model dalam mendeteksi objek berukuran kecil dengan cara menggabungkan informasi fitur dari berbagai skala resolusi secara efektif, sehingga secara langsung mengatasi keterbatasan utama dari SSD standar [15].

Kombinasi ini, yang tersedia sebagai model pra-terlatih (pre-trained) pada dataset COCO melalui TensorFlow 2 Object Detection API, memungkinkan penerapan metodologi *transfer learning* [16]. Dengan pendekatan ini, model dapat memanfaatkan pengetahuan fitur visual yang telah dipelajarinya dari jutaan citra untuk kemudian disempurnakan (*fine-tuned*) pada dataset sperma yang lebih kecil dan spesifik. Hal ini tidak hanya mempercepat proses pelatihan tetapi juga berpotensi meningkatkan akurasi dan kemampuan generalisasi model pada tahap evaluasi. Dengan demikian, pemilihan arsitektur MobileNetV2 SSD FPN-Lite 320x320 didasarkan pada pertimbangan strategis untuk mencapai keseimbangan terbaik antara kecepatan, efisiensi komputasi, dan akurasi deteksi objek kecil, yang semuanya merupakan persyaratan kritis untuk keberhasilan penelitian ini [15].

1.2. Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan diatas, maka perumusan masalah yang terkait dengan penelitian ini adalah sebagai berikut :

1. Bagaimana menerapkan model pembelajaran deep learning dengan metode Mobile-Net dalam deteksi sperma berbasis video?
2. Bagaimana menerapkan real-time detection menggunakan metode Mobile-Net SSD dalam deteksi sperma?
3. Seberapa besar tingkat presisi, recall dan F-1 Score model menggunakan metode Mobile-Net SSD dalam deteksi abnormalitas sperma berdasarkan akrosom?

1.3. Tujuan Penelitian

Penelitian ini bertujuan untuk mendeteksi abnormalitas sperma berdasarkan akrosom pada video mikroskopik menggunakan deep learning dengan menerapkan metode Mobile-Net SSD agar dapat digunakan untuk mengetahui tingkat akurasi yang dapat dihasilkan.

1.4. Manfaat Penelitian

Dalam penelitian yang dilakukan ini diharapkan dapat memberikan manfaat antara lain :

1. Manfaat Bagi Penulis, Sebagai tambahan wawasan keilmuan dan pengetahuan tentang deep learning terutama dalam menerapkan deep learning dan Mobile-Net SSD untuk klasifikasi suatu objek.
2. Manfaat Bagi Pembaca, Sebagai referensi bagi pembaca dalam menyelesaikan suatu masalah klasifikasi jenis pergerakan sperma dengan menggunakan deep learning dengan metode Mobile-Net SSD serta memperoleh tambahan wawasan di bidang informatika.

1.5. Batasan Masalah

Agar penelitian ini tidak keluar dari inti permasalahan yang diterapkan, maka diperlukan adanya batasan masalah sebagai berikut :

1. Metode deep learning pada pembuatan otomatisasi yang akan dilakukan adalah Mobile-Net SSD dan transfer learning
2. Dataset yang digunakan dalam penelitian ini adalah data video dan gambar sperma yang didapatkan dari GitHub.
3. Output dari penelitian ini adalah berupa otomatisasi dari pengklasifikasian kelas abnormal dan normal pada morfologi akrosom sperma menggunakan deep learning dengan metode transfer learning dan Mobile-Net SSD.

Halaman ini sengaja dikosongkan