

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Sel darah putih, atau leukosit, merupakan salah satu elemen kunci dalam sistem kekebalan tubuh manusia. Sel ini berperan penting dalam melindungi tubuh dari berbagai infeksi yang disebabkan oleh bakteri, virus, jamur, maupun parasit[2]. Setiap jenis dari sel darah putih memiliki tugas tertentu dalam pertahanan tubuh. Neutrofil adalah fagosit yang aktif yang menelan dan mencerna mikroorganisme berbahaya. Limfosit menghasilkan antibodi yang menargetkan antigen luar. Monosit, eosinofil, dan basofil juga berperan dalam respon imun yang mencakup inflamasi, reaksi alergi, dan pertahanan terhadap parasit[3].

Perubahan dalam rasio dan jumlah jenis leukosit dapat menunjukkan berbagai kondisi patologis yang berbeda[4]. Infeksi akut, peradangan, atau kondisi malignan seperti leukimia sering dikaitkan dengan leukositos, atau peningkatan jumlah leukosit. Sebaliknya, kondisi leukopenia, yaitu penurunan jumlah sel darah putih, dapat menyebabkan penurunan fungsi sistem kekebalan tubuh sehingga meningkatkan kerentanan terhadap infeksi[5]. Menghitung persentase setiap jenis leukosit, atau analisis diferensial leukosit, memberikan informasi tentang kondisi kesehatan seseorang. Peningkatan neutrofil biasanya dikaitkan dengan infeksi bakteri, sedangkan peningkatan limfosit dapat menunjukkan infeksi virus atau kondisi autoimun. Oleh karena itu, hasil pemeriksaan darah lengkap mencakup penghitungan jenis leukosit, sangat berharga untuk membantu dokter membuat diagnosis, mengawasi perkembangan penyakit, dan mengevaluasi efektivitas pengobatan.

Pemeriksaan apusan darah tepi adalah salah satu teknik diagnostik yang umum digunakan dalam hematologi. Di bawah mikroskop, sampel darah yang dioleskan pada kaca objek diamati secara visual selama pemeriksaan ini. Untuk mendiagnosis berbagai penyakit hematologi seperti leukemia, limfoma, dan anemia, ahli patologi akan menganalisis morfologi sel darah, terutama sel darah putih, atau leukosit[6]. Namun, ada beberapa keterbatasan pada proses analisis citra apusan darah tepi secara manual. Pertama, proses ini membutuhkan banyak

waktu, yang dapat menunda diagnosis dan pengobatan. Kedua, hasil analisis sangat bergantung pada pendapat pengamat, sehingga rentan terhadap kesalahan interpretasi. Akurasi hasil dapat diubah oleh kondisi pencahayaan mikroskop, kelelahan pengamat, dan variasi morfologi sel darah. Ketiga, seringkali sulit untuk mendapatkan ahli patologi yang berpengalaman, terutama di daerah dengan sumber daya terbatas.

Kemajuan kecerdasan buatan bidang *deep learning*, membawa solusi untuk mengatasi keterbatasan metode konvensional. *Deep learning* telah menunjukkan hasil yang sangat baik dalam berbagai tugas pengenalan pola, seperti citra medis. *Mask Region-based Convolutional Neural Network* atau *Mask R-CNN*, merupakan arsitektur *deep learning* yang menjanjikan, mampu mendeteksi dan menyegmentasi objek citra dengan sangat akurat. *Mask R-CNN* juga sering dijadikan oleh peneliti sebagai salah satu alat utama untuk melakukan segmentasi *instance* pada citra medis.

Pada penelitian berfokus pada masalah segmentasi sitoplasma pada citra sitologi serviks, yang dikenal sulit karena adanya sel yang tidak jelas dan saling tumpang tindih. Para peneliti mengusulkan metode berbasis *Mask R-CNN* dengan *backbone ResNet50* untuk mengatasi masalah ini. Hasilnya menunjukkan bahwa metode mengungguli pendekatan canggih lainnya dengan DSC 0.92 dan FPRp 0,0008 pada ambang DSC 0,8. Hasil tersebut menunjukkan bahwa metode segmentasi berbasis *Mask R-CNN* yang diusulkan dapat efektif dalam analisis sitologi[7].

Dalam penelitian lain, dikembangkan pendekatan yang lebih efektif untuk mendeteksi kanker paru-paru pada citra CT scan dengan memanfaatkan metode *Mask R-CNN* yang menggunakan *backbone ResNet101*. Hasilnya, model yang dikembangkan berhasil mencapai akurasi 99,32% dan rata-rata DICE 99,45% dalam mengidentifikasi daerah paru-paru yang terinfeksi. Dengan akurasi yang tinggi, metode ini berpotensi meningkatkan diagnosis dini dan pengobatan kanker paru-paru[8].

Berdasarkan kajian literatur yang telah dipaparkan, *Mask R-CNN* telah menunjukkan kinerja yang baik dalam bidang medis. Kemampuannya dalam

menangani data yang kompleks dan menghasilkan output yang akurat menjadikan algoritma ini sebagai pilihan yang tepat untuk mengatasi tantangan dalam variasi ukuran dan bentuk sel darah putih, adanya noise pada citra, serta overlap antara sel-sel darah. Untuk mengatasi tantangan-tantangan tersebut, diperlukan pengembangan model *Mask R-CNN* yang disesuaikan dengan karakteristik citra apusan darah tepi. Selain itu, perlu dilakukan pengumpulan dan anotasi dataset citra apusan darah tepi yang berkualitas tinggi untuk melatih model. Dengan adanya *dataset* yang memadai, model *Mask R-CNN* dapat dilatih untuk menghasilkan kinerja yang optimal dalam mendeteksi dan mengklasifikasikan sel darah putih.

Dengan menerapkan *Mask R-CNN* pada citra sel darah putih, diharapkan dapat dikembangkan sistem otomatis yang mampu mendeteksi dan mengklasifikasi jenis leukosit secara akurat. Sistem ini dapat membantu ahli patologi membuat keputusan klinis yang lebih tepat dengan meningkatkan efisiensi proses diagnosis dan meningkatkan akurasi dan reproduktibilitas hasil. Segmentasi dan deteksi otomatis pada sel darah putih melalui penggunaan *Mask R-CNN* memiliki potensi signifikan dalam meningkatkan efisiensi dan akurasi diagnosis hematologi. Sistem yang dikembangkan mampu mengidentifikasi berbagai jenis leukosit, seperti neutrofil, limfosit, monosit, eosinofil, dan basofil.

Selain algoritma yang digunakan selama proses segmentasi dan deteksi, *backbone* dan *hyperparameter* seperti *epoch* berdampak pada saat proses training dan hasil model yang dibuat. *Backbone* merupakan arsitektur utama pada *Convolutional Neural Network* yang digunakan untuk ekstraksi fitur citra. Berdasarkan literatur penelitian sebelumnya, segmentasi *instance* menggunakan *Mask R-CNN* umumnya menggunakan *backbone ResNet* dengan versi yang berbeda-beda. Kinerja model secara keseluruhan sangat dipengaruhi oleh pemilihan *backbone*, selain algoritma utama *Mask R-CNN*. Salah satu komponen utama jaringan *Convolutional Neural Network* (CNN) adalah *backbone*, yang bertanggung jawab untuk mengekstrak fitur dari gambar yang dimasukkan. Proses deteksi dan segmentasi dalam *Mask R-CNN* didasarkan pada fitur-fitur ini. Kualitas fitur *backbone* sebanding dengan akurasi hasil deteksi dan segmentasi objek.

Dalam hal kedalaman jaringan, efisiensi komputasi, dan kemampuan ekstraksi fitur, masing-masing backbone memiliki fitur arsitektural yang berbeda. Sebagai contoh, ResNet50 dikenal karena kecepatannya dan efisiensinya dalam komputasi berkat jumlah parameter yang relatif sedikit. Sementara itu, ResNet101 memiliki arsitektur yang lebih dalam, yang memungkinkannya mengenali dan mengekstraksi fitur-fitur yang lebih kompleks dari data. Di sisi lain, konsep cardinality meningkatkan kemampuan representasi fitur tanpa menambah jumlah parameter. Oleh karena itu, untuk memenuhi kebutuhan untuk akurasi model, efisiensi komputasi, dan kompleksitas data yang dihadapi, backbone yang tepat sangat penting. Ini terutama berlaku untuk gambar apusan darah tepi dengan bentuk sel yang berbeda dan terkadang tumpang tindih.

Pada penelitian lain dengan tujuan segmentasi *instance* pada citra satelit jarak jauh yang memiliki lebih dari 3 *channel* warna. Metode Mask R-CNN diterapkan, dan performanya dievaluasi menggunakan berbagai arsitektur *backbone*, yaitu *ResNet50-FPN*, *ResNet50-DC5*, *ResNet50-C4*, *ResNet101-FPN*, *ResNet101-DC5*, *ResNet101-FPN*, dan *ResNeXt101-FPN*. Penelitian ini menggunakan *framework detectron2* dalam membangun model segmentasi *instance*. Hasilnya, *ResNeXt101-FPN* memiliki hasil terbaik, dengan keunggulan 3% dibandingkan model terbaik kedua (*ResNet101-FPN*)[9]. *Epoch* merupakan iterasi lengkap satu kali pada seluruh dataset training saat model mempelajari data saat proses training. Semakin besar nilai *epoch*, maka proses training model akan lama dan nilai akurasi lebih tinggi[10]. Namun, nilai epoch yang terlalu besar juga dapat terjadi *overfitting*[11]. *Overfitting* yaitu kondisi dimana model terlalu menghafal data training sehingga membuatnya berkinerja buruk pada data baru. Salah satu solusi yang ditawarkan dapat menggunakan *Early Stopping*.

Keberhasilan arsitektur ResNeXt101 dalam penelitian tersebut mendorong penulis untuk membandingkan kinerja backbone serupa pada domain citra medis, khususnya pada segmentasi dan deteksi sel darah putih. Pemilihan backbone ResNet50, ResNet101, dan ResNeXt101 dalam penelitian ini tidak hanya didasarkan pada popularitas penggunaannya, tetapi juga pada pertimbangan arsitektural. ResNet50 merupakan model efisien yang banyak dijadikan baseline, ResNet101 memiliki kedalaman lebih sehingga dapat mengekstraksi fitur

kompleks secara lebih baik, sedangkan ResNeXt101 menawarkan peningkatan kapasitas representasi melalui mekanisme cardinality tanpa peningkatan parameter secara signifikan.

Selain itu, pengaturan jumlah epoch juga berpengaruh terhadap kinerja model. Epoch merupakan iterasi lengkap dari seluruh data latih saat model belajar. Semakin besar nilai epoch, semakin banyak peluang model mengenali pola dalam data, namun berisiko mengalami overfitting jika tidak dikontrol. Oleh karena itu, pada penelitian ini digunakan nilai epoch sebanyak 50 dengan mekanisme *Early Stopping* untuk menghentikan pelatihan jika model tidak menunjukkan peningkatan validasi dalam beberapa iterasi berturut-turut. Tujuannya adalah untuk memperoleh model dengan kinerja optimal namun tetap terhindar dari overfitting.

Dari semua yang sudah dipaparkan, maka penelitian ini menggunakan *Mask Region-based Convolutional Neural Network (Mask R-CNN)* untuk segmentasi dan deteksi sel darah putih. Pada saat proses *training* dilakukan beberapa uji coba pada *backbone* dan *epoch* untuk mendapatkan model paling baik dari uji coba yang dilakukan. Hasil kinerja pada proses *training* dilihat dari nilai mAP50 pada proses segmentasi dan mAP50 *bounding box* pada proses deteksi. mAP50 dihitung sebagai rata-rata dari nilai *Average Precision (AP)* pada *threshold IoU* sebesar 0.5. Ini berarti bahwa jika area tumpang tindih antara *bounding box* atau segmentasi yang diprediksi dan *bounding box* atau segmentasi yang sebenarnya adalah setidaknya 50%, maka prediksi tersebut dianggap benar.

Penelitian ini membantu mengevaluasi efektivitas metode segmentasi dan deteksi leukosit yang menggunakan Mask R-CNN dengan berbagai *backbone*. Hasilnya diharapkan memberikan wawasan ilmiah tentang cara terbaik untuk memilih arsitektur *backbone* untuk tugas segmentasi dan deteksi objek dalam domain citra medis, khususnya sel darah putih.

## 1.2 Perumusan Masalah

### 1.2.1 Permasalahan

Diagnosis penyakit hematologi sangat bergantung pada akurasi dan kecepatan dalam menganalisis apusan darah tepi, khususnya dalam

mengidentifikasi jenis-jenis sel darah putih. Metode konvensional yang masih banyak digunakan saat ini, yaitu analisis manual, yang mana memiliki beberapa keterbatasan seperti subjektivitas pengamat dalam membedakan morfologi sel darah putih, waktu yang lama, dan potensi kesalahan manusia dalam menghitung jumlah sel. Akibatnya, akurasi diagnosis penyakit hematologi menjadi tidak konsisten dan dapat bervariasi antar pengamat. Oleh karena itu, perlu dilakukan segmentasi dan deteksi jenis sel darah putih secara otomatis agar proses analisis lebih akurat dan efisien waktu.

### 1.2.2 Metode Penelitian

Metode yang diaplikasikan dalam studi ini adalah *algoritma Mask Region-based Convolutional Neural Network (Mask R-CNN)*, yang berfungsi untuk identifikasi dan segmentasi objek sel darah putih dari citra mikroskopis. Pada *backbone* dan nilai *epoch* dilakukan beberapa uji coba. *Backbone* di uji coba dengan *ResNet50*, *Resnet101*, dan *ResNeXt101*. Pada *epoch* dilakukan uji coba bernilai 50.

### 1.2.3 Pertanyaan Penelitian

1. Bagaimana pengaruh *backbone ResNet50* terhadap hasil kinerja *Mask R-CNN* dalam segmentasi dan deteksi sel darah putih berdasarkan mAP50?
2. Bagaimana pengaruh *backbone Resnet101* terhadap hasil kinerja *Mask R-CNN* dalam segmentasi dan deteksi sel darah putih berdasarkan mAP50?
3. Bagaimana pengaruh *backbone ResNeXt101* terhadap hasil kinerja *Mask R-CNN* dalam segmentasi dan deteksi sel darah putih berdasarkan mAP50?

## 1.3 Tujuan dan Manfaat

### 1.4.1 Tujuan

1. Untuk mengetahui pengaruh *backbone ResNet50* terhadap hasil kinerja *Mask R-CNN* pada segmentasi dan deteksi sel darah putih pada apusan darah tepi
2. Untuk mengetahui pengaruh *backbone ResNet101* terhadap hasil kinerja *Mask R-CNN* pada segmentasi dan deteksi sel darah putih pada apusan darah tepi

3. Untuk mengetahui pengaruh *backbone ResNeXt101* terhadap hasil kinerja *Mask R-CNN* pada segmentasi dan deteksi sel darah putih pada apusan darah tepi

#### 1.4.2 Manfaat

1. Manfaat bagi masyarakat

Beberapa manfaat bagi masyarakat yang didapatkan dari penelitian ini meliputi:

1. Membantu proses identifikasi dan analisis sel darah putih dengan cepat dan akurat
2. Mempercepat proses diagnosis dan mempersingkat waktu dalam menunggu hasil pemeriksaan
3. Meningkatkan layanan kesehatan masyarakat

2. Manfaat bagi ilmu pengetahuan

Beberapa manfaat bagi ilmu pengetahuan yang didapatkan dari penelitian ini meliputi:

1. Mengembangkan ilmu kecerdasan buatan dan computer vision
2. Menjadi acuan untuk pengembangan teknik analisis citra medis
3. Membuka peluang riset lanjutan yang bertujuan untuk meningkatkan efisiensi dan akurasi teknologi kesehatan
4. Memperkaya literatur mengenai metode *Mask R-CNN* pada citra medis

#### 1.4 Batasan Masalah

Agar penelitian lebih terarah dan spesifik, adapun batasan masalah yang digunakan dalam penelitian ini:

1. Metode yang digunakan adalah *Mask Region-based Convolutional Neural Network (Mask R-CNN)*
2. Segmentasi digunakan untuk menunjukkan bentuk sel darah putih
3. Deteksi dilakukan pada jenis-jenis sel darah putih yang dibagi menjadi 5 kelas, *Neutrophil*, *Basophil*, *Eosinophil*, *Monocyte*, *Lymphocyte*
4. Sumber *dataset* yang digunakan pada penelitian ini merupakan dataset publik yang disediakan oleh <https://www.kaggle.com/datasets/mahdihabibi/segmented-peripheral->

blood-cells-using-opencv”. Data berformat JPG dengan resolusi 360 x 363 pixel dan menggunakan model warna RGB

5. Jumlah data yang digunakan sebanyak 975 dengan 195 per kelas. Kemudian di augmentasi menjadi 3.315 dengan 663 perkelas
6. Data di augmentasi dengan 3 teknik. Horizontal flip, shift width 15% ke kanan, dan shift width 15% ke kiri.
7. Jumlah *epoch* yang digunakan 50 dengan *early stopping*
8. *Learning rate* menggunakan *Reduce LR On Plateau* dengan nilai awal 0.0001
9. *Optimizer* yang digunakan adalah *Stochastic Gradient Descent* (SGD)
10. *Batch Size* yang digunakan adalah 2
11. *Backbone* yang digunakan adalah *ResNet50*, *Resnet101*, dan *ResNeXt101*.
12. Evaluasi menggunakan mAP50 dengan rentang nilai 0.00 – 1.00. Dimana nilai 0.00 menandakan 0% dan nilai 1.00 menandakan 100%.

## 1.5 Sistematika Penulisan Skripsi

Proses penulisan skripsi ini dirancang agar dapat memaparkan secara luas penelitian yang telah dilaksanakan. Berikut adalah sistematika penulisan skripsi ini secara berurutan:

### BAB I PENDAHULUAN

Bab ini berisi penjelasan mengenai latar belakang dilakukannya penelitian ini, perumusan masalah yang menjadi fokus, metodologi penelitian yang diterapkan, batasan masalah yang ditetapkan, tujuan dan manfaat dari penelitian, serta sistematika penulisan tugas akhir secara keseluruhan.

### BAB II KAJIAN PUSTAKA

Bab ini berisi tinjauan landasan teori penelitian yang komprehensif dari berbagai sumber jurnal dan buku. Pokok bahasan meliputi penjelasan tentang sel darah putih, metode-metode segmentasi dan deteksi, model *Mask Region-based Convolutional Neural Network (Mask R-CNN)* dan istilah-istilah yang muncul, serta *hyperparameter*. Bagian ini juga menyajikan ringkasan dari penelitian-penelitian terdahulu yang relevan dengan topik yang diangkat.

### **BAB III METODOLOGI PENELITIAN**

Bab ini menjabarkan secara lengkap dari Metodologi Penelitian yang digunakan. Dimulai dari penjelasan deskripsi dari dataset mencakup jenis, jumlah data, dan karakteristiknya, selanjutnya arsitektur model meliputi alur *training* dan *testing*. Bab ini juga menjelaskan bagaimana alur uji coba yang diusulkan.

### **BAB IV HASIL DAN PEMBAHASAN**

Menyajikan hasil traning skenario uji coba pada tiap fold, meliputi hasil mAP tiap epoch dan perbandingan grafik loss dan mAP pada training dan validasi. Kemudian, menganalisis kinerja pada masing-masing *backbone* berdasarkan mAP50 dimana nilai tertinggi pada tiap skenario, dilakukan testing untuk mengetahui model terbaik.

### **BAB V PENUTUP**

Bab ini berfungsi untuk menyajikan kesimpulan yang komprehensif dari penelitian yang telah dilakukan, sebagai jawaban atas rumusan masalah. Di samping itu, saran dan rekomendasi untuk penelitian lanjutan turut disertakan.

### **DAFTAR PUSTAKA**

Memuat semua sumber referensi yang telah dirujuk dan digunakan dalam penulisan skripsi, mulai dari buku, jurnal ilmiah, hingga sumber daring yang kredibel. Setiap entri dalam daftar pustaka disusun secara sistematis berdasarkan kaidah penulisan yang relevan.