

BAB I

PENDAHULUAN

1.1 Latar Belakang

Citra medis memiliki peran penting dalam mendeteksi, mendiagnosis, dan memantau berbagai kondisi kesehatan secara lebih akurat [1]. Perkembangan teknologi telah meningkatkan kualitas layanan kesehatan dan mendukung pengambilan keputusan medis yang cepat dan tepat. Namun, banyak prosedur diagnostik, khususnya dalam radiologi, masih bergantung pada interpretasi manual yang rentan terhadap *noise*, ambiguitas citra, serta berbagai keterbatasan lain, sehingga berpotensi menimbulkan kesalahan diagnosis [2]. Kondisi ini menjadi semakin krusial dalam situasi darurat yang menuntut ketepatan dan kecepatan analisis. Salah satu kondisi yang paling umum dihadapi dalam instalasi gawat darurat (IGD) adalah fraktur tulang [3]. Berdasarkan *World Health Organization* (WHO), sekitar 13 juta orang mengalami fraktur pada tahun 2020 [4], dengan tingkat prevalensi sebesar 2,7% [5]. Di tingkat nasional, Indonesia termasuk salah satu negara di Asia Tenggara dengan jumlah kasus fraktur yang tinggi, mencapai sekitar 1,3 juta kasus per tahun menurut laporan Kementerian Kesehatan [5][6]. Salah satu penyebab terbesar terjadinya fraktur di Indonesia adalah kecelakaan. Sekitar 5,8% korban kecelakaan mengalami cedera fraktur [7], dengan distribusi fraktur ekstremitas atas sebesar 36,9% dan ekstremitas bawah sebesar 65,2% [8]. Tingginya angka kejadian tersebut memperbesar tantangan dalam proses diagnosis, terutama karena variasi lokasi fraktur serta adanya fraktur yang sulit diidentifikasi ditambah dengan keterbatasan tenaga ahli radiologi pada rumah sakit kecil dan menengah di daerah terpencil [9] yang meningkatkan risiko kesalahan interpretasi awal. Sebuah studi menunjukkan bahwa hingga 80% kasus fraktur kecil sering terlewat di ruang gawat darurat, yang tentunya dapat berdampak serius terhadap kesehatan pasien dan penanganan selanjutnya [10]. Maka dari itu, perlunya solusi inovatif untuk deteksi dini terkait fraktur dengan menggunakan teknologi seperti *computer vision* dapat membantu analisis citra medis secara otomatis dan konsisten

guna mendukung radiolog dalam menghasilkan diagnosis yang lebih awal dengan efisien [11].

Pendekatan *deep learning* (DL) telah mengubah banyak aspek dalam bidang kecerdasan buatan (AI) [12], terutama karena kemampuannya untuk mempelajari dan mengenali fitur-fitur penting berbasis data secara otomatis [13]. Sifat otonom ini membuat *deep learning* sangat efektif dalam berbagai tugas *computer vision*, seperti segmentasi gambar, deteksi objek, dan klasifikasi gambar [14]. Dari sekian banyak arsitektur dalam *deep learning*, *convolutional neural network* (CNN) memiliki keunggulan dalam menganalisis dan mengekstrak fitur dari data visual [15]. Dengan memanfaatkan CNN, model *deep learning* dapat menganalisis gambar medis, seperti fraktur tulang, secara mendalam dan mengidentifikasi pola-pola penting yang mungkin terlewatkan oleh pengamatan manusia. Meski demikian, peningkatan jumlah lapisan pada *neural network* yang semakin dalam sering kali menimbulkan penurunan performa dan *vanishing gradient*, yaitu kondisi ketika gradien menjadi sangat kecil sehingga proses pembelajaran model menjadi tidak optimal [16]. Permasalahan ini mendorong pengembangan algoritma yang mampu mempertahankan stabilitas pelatihan meskipun memiliki kedalaman jaringan yang tinggi, salah satunya melalui konsep *residual learning* pada algoritma *Residual Network* (ResNet).

ResNet merupakan algoritma *deep learning* yang sangat efektif dalam pengenalan gambar medis berkat kemampuannya untuk mengatasi masalah degradasi yang sering terjadi pada model basis CNN [17]. Dengan menggunakan *residual connections*, algoritma ini mengekstrak informasi untuk melewati lapisan-lapisan jaringan tanpa terdegradasi, sehingga mengurangi masalah *vanishing gradient* [18]. Hal ini memungkinkan ResNet untuk memiliki lapisan yang sangat dalam dan luas, berdasarkan tipenya penamaan ResNet dengan angka seperti 50 menandakan bahwa arsitektur ini mencapai 50 lapisan, begitupun seterusnya pada arsitektur ResNet lain. Lapisan tersebut mampu mempelajari representasi fitur yang kompleks dan menghasilkan performa yang sangat baik pada berbagai klasifikasi gambar. Beberapa studi membuktikan penggunaan model *deep learning* seperti ResNet-50 dalam konteks gambar medis pada tulang. Salah satu pemanfaatan

ResNet-50 dengan *transfer learning* dapat digunakan dalam mengklasifikasikan kondisi mekanis tulang kortikal dan trabekular menggunakan citra SR-microCT [19]. Pendekatan ini menghasilkan akurasi hingga 99% pada *dataset* tulang trabekular dengan evaluasi fitur menggunakan visualisasi *gradient class activation maps* (Grad-CAMs). Penggunaan *backbone* ResNet menunjukkan performa yang luar biasa dalam segmentasi fraktur tulang dengan nilai akurasi hingga 98% dan *Area under Curve* (AUC) yang mencapai 0.99 [20]. ResNet juga digunakan sebagai *backbone* pada *ensemble model* untuk mengklasifikasikan citra *X-ray* tulang bahu dari *dataset* MURA [21]. Model tersebut menghasilkan nilai akurasi 84,72% menggunakan optimalisasi Adam dan *cross-entropy loss function*.

Dalam konteks deteksi fraktur, sebuah studi usulan melakukan penemuan model berbasis CNN terbaik dilakukan dengan membandingkan ResNet-50, VGGNet, dan AlexNet untuk klasifikasi citra *X-ray* fraktur tulang [22]. Hasil penelitian tersebut menunjukkan bahwa ResNet-50 memperoleh akurasi tertinggi sebesar 78%, dibandingkan VGGNet (75%) dan AlexNet (72%), sehingga menegaskan keunggulan ResNet-50 sebagai model dasar dalam deteksi fraktur. Studi tersebut menyatakan bahwa pendekatan berbasis CNN, khususnya ResNet-50, mampu menjembatani kesenjangan antara teknik deteksi konvensional dan teknologi *deep learning* modern dengan tingkat keandalan yang tinggi. Meskipun demikian, pendekatan yang digunakan studi tersebut masih terbatas pada arsitektur dasar tanpa eksplorasi mekanisme tambahan yang dapat meningkatkan sensitivitas model terhadap area pada fraktur yang mungkin tersembunyi. Namun, mayoritas literatur yang ditemukan terkait fraktur saat ini menunjukkan kecenderungan objek penelitian yang terbatas pada satu hingga dua jenis tulang spesifik atau tipe fraktur. Di sisi lain, arsitektur ResNet juga memiliki beberapa kelemahan, model ini memerlukan data pelatihan yang besar. Sebuah penelitian menunjukkan bahwa semakin besar ukuran *dataset*, semakin akurat hasil pelatihan model [23]. Ukuran *dataset* yang bervariasi memengaruhi kinerja model, dan jika *dataset* terbatas, model akan menghasilkan hasil yang kurang optimal. Selain itu, proses pelatihan yang memakan waktu dan komputasi yang tinggi juga menjadi salah satu kelemahan utama CNN-based ResNet-50 [24]. Hal ini menunjukkan masih adanya

ruang pengembangan untuk meningkatkan performa deteksi fraktur berbasis ResNet-50.

Pendekatan *transfer learning* dengan model *pretrained* merupakan solusi efektif untuk mengatasi keterbatasan dataset sekaligus memperbaiki kelemahan pada arsitektur ResNet [25]. Teknik ini melatih model pada *dataset* besar yang tidak terkait langsung dengan *domain target*, sehingga model dapat disesuaikan dengan *dataset* yang lebih kecil. Selanjutnya, untuk mengatasi tantangan komputasi yang tinggi dan waktu pelatihan yang lama pada model ResNet-50, penerapan teknik untuk memaksimalkan performa model dilakukan. Beberapa teknik seperti integrasi *attention mechanism* dan *hyperparameter tuning* merupakan salah satu langkah strategis. Dalam studi di bidang medis lain model *pretrained* ResNet-50 ditunjukkan memiliki peningkatan dalam akurasi deteksi *X-ray* pneumonia sebesar 98%, peningkatan 7% dari model *baseline* ResNet-50 sebelumnya [26], dengan menggunakan *Convolutional Block Attention Module* (CBAM) yang berfokus pada fitur, fungsi *focal loss* dan *skip connections*. Selain itu, pada studi fraktur yang masih tergolong terbatas, sebuah pengembangan model CNN *based* dengan *multiple attention blocks* dilakukan untuk deteksi fraktur tulang pada beberapa *region X-ray* dan menghasilkan akurasi hingga 96,72% [27].

Penelitian ini bertujuan untuk mengimplementasi teknologi *deep learning* dalam mendeteksi fraktur tulang pada area ekstremitas atas maupun bawah yang menjadi permasalahan pada ruang lingkup IGD. Melalui penerapan ini, penelitian dirancang untuk menekan angka terlewatnya fraktur kecil akibat keterbatasan tenaga ahli radiologi, khususnya pada rumah sakit kecil atau terpencil melalui analisis optimasi model ResNet-50 untuk mencapai performa yang lebih baik sekaligus yang menjadi fokus penelitian ini. Dalam proses pengembangannya, model *pretrained* ResNet-50 berbasis ImageNet diintegrasikan dengan *attention mechanism* yaitu CBAM untuk mempertajam fokus model pada fitur visual yang paling relevan di area citra fraktur. Integrasi metode ini diharapkan mampu meningkatkan efisiensi pelatihan secara signifikan dan hasil penelitian dapat memberikan kontribusi nyata dalam mempercepat proses diagnosis kasus fraktur sebagai alat deteksi dini.

1.2 Rumusan Masalah

Berdasarkan permasalahan yang telah dijabarkan pada latar belakang, rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana penerapan model *pretrained* ResNet-50 sebagai model basis (*baseline*) pada deteksi fraktur tulang pada gambar medis?
2. Bagaimana penerapan *Convolutional Block Attention Module* untuk pemfokusan fitur pada model *pretrained* ResNet-50 dalam mendeteksi fraktur tulang pada gambar medis?
3. Bagaimana perbandingan performa model *pretrained* ResNet-50 dalam mendeteksi fraktur tulang sebelum dan sesudah menggunakan *Convolutional Block Attention Module* berdasarkan metrik akurasi, presisi, sensitivitas (*recall*), dan F1-score?
4. Bagaimana rancangan dan implementasi sistem deteksi dini fraktur tulang berbasis *web* menggunakan Streamlit dengan mengintegrasikan model dengan hasil evaluasi terbaik?

1.3 Batasan Masalah

Selanjutnya, batasan masalah dalam penelitian ini adalah sebagai berikut:

1. Penelitian ini menggunakan *dataset* gabungan yang terbatas pada citra *X-ray*, yaitu FracAtlas dan Bone Fracture *X-ray*: Simple vs. Comminuted sebagai sumber utama
2. Penelitian ini hanya berfokus pada 3 kelas deteksi patah tulang atau fraktur, seperti Fraktur Sederhana (Simple fracture), Fraktur Kominuta/Berkeping (Comminuted fracture), dan Normal (Non fracture).
3. Penelitian tidak membahas kasus terkait tulang lainnya seperti dislokasi, penyakit tulang tertentu, atau kelainan pada tulang, serta aspek klinis terkait diagnosis/tindakan lanjutan.
4. Penggunaan metrik evaluasi untuk mengevaluasi performa model adalah *accuracy*, *precision*, *recall*, dan F1-score.

1.4 Tujuan dan Manfaat Penelitian

1.4.1 Tujuan Penelitian

Berdasarkan rumusan masalah yang telah diidentifikasi, tujuan penelitian ini adalah:

1. Mengimplementasikan model *pretrained* ResNet-50 sebagai model basis penelitian dalam mendeteksi fraktur tulang.
2. Mengoptimasi model *pretrained* ResNet-50 menggunakan *Convolutional Block Attention Module* dalam mendeteksi fraktur tulang.
3. Menganalisis kinerja dari penggunaan *Convolutional Block Attention Module* pada deteksi fraktur menggunakan model *pretrained* ResNet-50 berdasarkan metrik akurasi, presisi, sensitivitas (*recall*), dan F1-score.
4. Merancang dan membangun aplikasi deteksi dini fraktur tulang berbasis *web* menggunakan *framework* Streamlit dengan mengintegrasikan model hasil evaluasi terbaik sebagai mesin inferensi.

1.4.2 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

1. Manfaat Teoritis
 - a. Memberikan kontribusi pada literatur penerapan *transfer learning* menggunakan model *pretrained* dan *Convolutional Block Attention Module* dalam deteksi fraktur tulang, khususnya dengan model ResNet-50 pada *dataset* terbatas.
 - b. Memperluas wawasan dan referensi tentang peran *Convolutional Block Attention Module* dan model *pretrained* dalam meningkatkan performa model *deep learning*.
2. Manfaat Praktis
 - a. Mengembangkan metode deteksi otomatis berbasis *deep learning* untuk diagnosis fraktur tulang yang lebih awal dan cepat.
 - b. Menyediakan alat bantu bagi tenaga medis dalam melakukan verifikasi diagnosis fraktur tulang sejak dini guna meminimalisir risiko kesalahan manusia (*human error*).

- c. Mempercepat proses *screening* awal pasien fraktur di fasilitas kesehatan melalui sistem berbasis *web* yang mudah diakses dan efisien.

1.5 Sistematika Penulisan

Dibawah ini merupakan sistematika penulisan yang runtut pada setiap bab penelitian ini:

BAB I PENDAHULUAN

Pada bab ini memuat latar belakang, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian dan sistematika penulisan penelitian.

BAB II LANDASAN TEORI

Pada bab kedua memuat penelitian terdahulu terkait dengan penelitian yang dilakukan, serta teori-teori pendukung penelitian seperti citra medis, fraktur tulang, *deep learning*, *framework* dan algoritma, serta alat (*tools*) yang menunjang penelitian ini.

BAB III METODOLOGI PENELITIAN

Pada bab ketiga memuat tahapan penelitian yang dilakukan, seperti pengumpulan data, praproses data, transformasi data, *data mining*, evaluasi, penulisan laporan, dan spesifikasi sistem komputer.

BAB IV ANALISIS DAN HASIL PENELITIAN

Pada bab keempat memuat hasil dari penelitian yang dilakukan, serta penemuan yang sesuai dengan permasalahan yang ditemukan dan tujuan dari penelitian pada bab pertama.

BAB V SIMPULAN DAN SARAN

Pada bab kelima memuat kesimpulan dari penelitian yang dilakukan untuk menjawab permasalahan penelitian dan saran yang muncul terkait penelitian.