

BAB I

PENDAHULUAN

1.1 Latar Belakang

Luka merupakan kondisi kontinuitas suatu jaringan terputus akibat cedera atau tindakan pembedahan. Berdasarkan penyebabnya, terdapat berbagai jenis luka, seperti luka bakar, luka robek (*vulnus laceratum*), luka lecet (*vulnus excoriasi*), luka tusuk (*vulnus punctum*), luka memar (*vulnus contusum*), dan luka sayat (*vulnus insivum*) (Dini & Kurniawaty, 2022). Pada tahun 2021, Badan Pusat Statistik mencatat jumlah luka ringan di Indonesia mencapai 117.913 orang. Sedangkan pada tahun 2022 jumlah luka ringan di Indonesia berjumlah 160.449. Angka ini menunjukkan peningkatan terjadinya luka ringan (*Badan Pusat Statistik, 2022*).

Berdasarkan prevalensi semakin meningkatnya kasus jumlah luka ringan di Indonesia, klasifikasi jenis luka luar menjadi penting karena setiap jenis luka membutuhkan pendekatan penanganan yang berbeda. Tanpa klasifikasi yang tepat, risiko infeksi, keterlambatan penyembuhan, bahkan komplikasi serius dapat meningkat (*The Importance Of Accurate Wound Assessment Tools For Wound Classification, 2024*). Klasifikasi luka luar juga secara otomatis mendukung pencapaian akses layanan kesehatan yang berkualitas, merata, dan responsif, terutama di wilayah dengan keterbatasan tenaga medis (Monroy dkk., 2023).

Pengembangan teknologi untuk klasifikasi luka yang akurat dapat memberikan manfaat, termasuk mempercepat diagnosis, mengurangi kesalahan diagnosis, dan

menyesuaikan perawatan sesuai dengan jenis luka. Dengan memanfaatkan perkembangan dalam kecerdasan buatan, klasifikasi luka luar pada manusia dapat dilakukan menggunakan teknik *deep learning* seperti *Convolutional Neural Network* untuk memperoleh akurasi klasifikasi kondisi medis dengan akurat (Ramadhani dkk., 2023).

CNN terbukti efektif dalam berbagai tugas klasifikasi citra medis, termasuk deteksi luka. CNN menawarkan akurasi lebih tinggi namun dengan pemilihan arsitektur model yang optimal akan mempengaruhi performa klasifikasi (Gunawan & Setiawan, 2022a). Dalam klasifikasi citra medis, keterbatasan jumlah dan variasi dataset membuat pelatihan model dari awal rentan *overfitting* serta memerlukan komputasi besar. Oleh karena itu, *transfer learning* dipilih karena mampu memanfaatkan model pra-latih pada dataset besar seperti *ImageNet*, sehingga pelatihan menjadi lebih efisien dan akurat meskipun data terbatas (Abou Baker dkk., 2022a). Selain itu, distribusi data yang tidak seimbang juga dapat membatasi kemampuan model dalam melakukan generalisasi. Untuk mengatasi hal tersebut, teknik augmentasi data digunakan guna menambah variasi citra dan mencegah *overfitting* (Rahmadwati dkk., 2024).

Pemilihan varian *EfficientNetB0* hingga *EfficientNetB7* sebagai objek komparasi pada penelitian ini didasari oleh kebutuhan untuk menemukan arsitektur yang paling optimal dalam tugas klasifikasi luka luar. Skema *compound scaling* yang menjadi dasar *EfficientNet* memungkinkan penyesuaian kedalaman, lebar, dan resolusi model sehingga setiap varian dari *EfficientNetB0* hingga *EfficientNetB7*

menawarkan keseimbangan berbeda antara kemampuan belajar dan kebutuhan komputasinya (Manole dkk., 2024).

Pendekatan ini telah terbukti efektif pada domain citra medis, misalnya pada penelitian yang dilakukan oleh (Ramesh dkk., 2024) dan (Kanchana dkk., 2024) membahas mengenai penerapan metode *transfer learning* untuk mendiagnosis penyakit kanker kulit. Penelitian ini memanfaatkan arsitektur *Convolutional Neural Networks* (CNN) dengan menggunakan arsitektur model utama *EfficientNet-B7*. Hasil akurasi yang diperoleh mencapai 92% dan 84,4%. Selain itu penelitian yang dilakukan oleh (Purbandanu dkk., 2024) berfokus pada penggunaan model yang lebih ringan yaitu *EfficientNetB2*. Model ini digunakan untuk meningkatkan akurasi deteksi kanker kulit menggunakan dataset HAM10000 yang menunjukkan kinerja menjanjikan. Model *EfficientNetB2* berhasil mencapai akurasi 86% dengan nilai *precision* 0.87 dan *recall* 0.85.

Meskipun model-model *EfficientNet* telah menunjukkan kemampuan yang baik dalam bidang dermatologi, studi-studi terdahulu tersebut masih memiliki celah penelitian. Penelitian-penelitian tersebut cenderung berfokus pada model tunggal seperti *EfficientNetB7* atau *EfficientNetB2* dan berfokus pada kasus kanker kulit saja, tanpa membandingkan secara sistematis seluruh seri arsitektur *EfficientNetB0* hingga *EfficientNetB7*. Hal ini penting karena kompleksitas arsitektur yang berlebihan seperti *EfficientNetB7* dapat menyebabkan *overfitting* pada dataset yang tidak terlalu besar atau beragam, sementara model yang lebih ringan mungkin mengalami *underfitting*. Oleh karena itu, penelitian ini bertujuan untuk mengisi kekurangan tersebut dengan menguji semua varian *EfficientNet* untuk

mengidentifikasi model *EfficientNet* mana yang paling optimal untuk klasifikasi luka luar dengan mengevaluasi performa model *EfficientNetB0* hingga *EfficientNetB7* berdasarkan metrik akurasi, presisi, *recall*, dan *f1-score*. Proses pelatihan model juga akan dioptimalkan menggunakan *Adam optimizer*.

1.2 Rumusan Masalah

- a. Bagaimana mengimplementasikan model *EfficientNetB0* hingga *EfficientNetB7* dengan pendekatan *transfer learning* untuk klasifikasi citra luka luar?
- b. Bagaimana kinerja masing-masing model *EfficientNetB0* hingga *EfficientNetB7* dalam mengklasifikasikan jenis luka luar berdasarkan citra digital jika dievaluasi menggunakan metrik akurasi, presisi, *recall*, dan *f1-score*?

1.3 Tujuan Penelitian

- a. Mengimplementasikan model *EfficientNetB0* hingga *EfficientNetB7* dengan pendekatan *transfer learning* untuk klasifikasi citra luka luar.
- b. Mengevaluasi kinerja masing-masing model *EfficientNetB0* hingga *EfficientNetB7* dalam mengklasifikasikan jenis luka luar berdasarkan citra digital dengan menggunakan metrik evaluasi seperti akurasi, presisi, *recall*, dan *f1-score*.

1.4 Manfaat Penelitian

- a. Memberikan hasil perbandingan kinerja model *EfficientNetB0* hingga *EfficientNetB7* pada klasifikasi citra luka luar sebagai dasar bagi penelitian selanjutnya.

- b. Menambah referensi akademik terkait penggunaan metode *Deep Learning*, khususnya arsitektur *EfficientNet*, dalam analisis citra medis berbasis luka luar.
- c. Menyediakan rekomendasi mengenai arsitektur *EfficientNet* yang paling optimal dan efektif untuk implementasi klasifikasi luka luar.

1.5 Batasan Masalah

- a. Penelitian ini hanya berfokus pada luka luar pada kulit manusia, yaitu *abrasions* (luka lecet), *bruises* (luka memar), *burns* (luka bakar), *cut* (luka sayat), *laceration* (luka robek), dan *stab wound* (luka tusuk). Luka yang diteliti tidak mencakup luka dalam, luka akibat penyakit tertentu misalnya ulkus diabetik, atau luka infeksius seperti luka akibat gangren atau infeksi bakteri.
- b. Dataset gambar luka yang digunakan dalam penelitian ini berasal dari sumber terbuka yaitu pada *Kaggle* dan dengan metode web crawling ekstensi *Google Chrome* bernama *ImageDownloader*.
- c. Penelitian ini hanya berfokus pada tahap pengujian akurasi model untuk klasifikasi luka, tanpa melakukan pengembangan aplikasi atau implementasi dalam sistem medis yang sesungguhnya.
- d. Evaluasi model dilakukan berdasarkan akurasi, presisi, *recall*, dan *F1-score*.