

BAB I

PENDAHULUAN

A. Latar Belakang

Penyakit pernapasan merupakan salah satu ancaman kesehatan global yang memerlukan perhatian serius. Beberapa penyakit pernafasan yang menjadi penyebab utama mortalitas di seluruh dunia adalah Pneumonia, Tuberkulosis, Penyakit Paru Obstruktif Kronis, dan Kanker Paru-Paru. Pada tahun 2019, penyakit pernapasan kronis merupakan penyebab kematian ketiga secara global dengan sekitar 4 juta kematian [1]. Infeksi saluran pernapasan bawah menyumbang lebih dari 2,5 juta kematian per tahun secara global [2]. Ditambah lagi dengan adanya pandemi COVID-19, kasus kematian dengan diagnosis penyakit pernafasan meningkat. Hal ini telah membuka mata dunia terhadap kerentanan sistem kesehatan dalam penanganan penyakit pernapasan. Hal ini menunjukkan pentingnya merancang sistem diagnosis yang cepat, akurat, dan terjangkau untuk populasi berisiko tinggi. Di tengah keterbatasan sumber daya kesehatan, teknologi diagnostik berbasis pencitraan medis menjadi tulang punggung deteksi dini. Teknologi ini menggunakan foto *X-ray* toraks sebagai modalitas utama di fasilitas kesehatan primer karena ketersediaannya yang luas dan biaya operasional yang rendah.

Di Indonesia, penyakit pernapasan merupakan beban yang sangat besar dalam sistem layanan kesehatan. Data Kementerian Kesehatan pada tahun 2023 menunjukkan bahwa Infeksi Saluran Pernapasan Akut (ISPA) menduduki peringkat pertama dalam 10 besar penyakit rawat jalan di puskesmas dengan 27,8 juta kasus yang tercatat pada tahun 2022. Sementara itu, Indonesia berada di peringkat kedua dunia untuk kasus tuberkulosis setelah India. Pada 2023, Indonesia menyumbang 10% dari total kasus tuberkulosis global dengan estimasi 1,02 juta kasus baru dan 112.000 kematian [3]. Kondisi ini diperburuk oleh tantangan struktural yang signifikan dalam sistem kesehatan Indonesia. Hal ini antara lain adalah distribusi tenaga radiolog yang tidak merata dan keterbatasan akses terhadap peralatan diagnostik di daerah terpencil. Keterbatasan infrastruktur diagnostik ini berkontribusi pada keterlambatan diagnosis yang dapat meningkatkan angka

komplikasi dan mortalitas, terutama pada kasus tuberkulosis di wilayah pedesaan [4].

Pada konteks diagnostik, *X-ray* toraks menjadi pilihan utama di fasilitas kesehatan primer Indonesia karena keterjangkauan dan kecepatannya. Namun, modalitas ini memiliki keterbatasan signifikan dibandingkan *CT Scan*, seperti resolusi yang lebih rendah dan adanya tumpang tindih ciri visual antar-penyakit. Contohnya, infiltrat pada Pneumonia Bakteri dan Tuberkulosis sering kali tampak serupa pada citra *X-ray*. Penelitian menunjukkan bahwa sensitivitas *X-ray* untuk deteksi tuberkulosis berkisar antara 50–70%, jauh di bawah modalitas pencitraan yang lebih canggih, sehingga berisiko pada hasil negatif palsu. Studi di Uganda menunjukkan bahwa sensitivitas *X-ray* untuk skrining TB mencapai 93% dengan spesifisitas 65% ketika dibandingkan dengan kultur Lowenstein Jensen [5]. Selain itu, interpretasi *X-ray* sangat bergantung pada keahlian klinis tenaga medis, dan variabilitas diagnostik antar pengamat. Hal tersebut menjadi tantangan tersendiri dalam praktik klinis [6]. Kondisi ini diperparah oleh tingginya beban kerja tenaga medis di Indonesia, sehingga meningkatkan risiko kesalahan diagnosis.

Kecerdasan Buatan berbasis *Deep Learning* menawarkan solusi potensial untuk mengatasi keterbatasan tenaga medis dan kesalahan diagnosis. Model *Convolutional Neural Network* telah terbukti mampu menganalisis pola yang tidak jelas terlihat pada citra *X-ray* yang mungkin terlewat oleh mata manusia dengan akurasi yang mendekati atau bahkan melampaui ahli radiologi. Penelitian menunjukkan bahwa algoritma AI berbasis *deep learning* dapat mencapai *Area Under the ROC Curve* hingga 0.90 - 0.95 untuk deteksi *tuberculosis* pada *X-ray* toraks [7]. Namun, performa model ini sangat dipengaruhi oleh pemilihan *hyperparameter*, seperti *learning rate*, *batch size*, dan arsitektur jaringan. Metode optimasi tradisional seperti *Grid Search* tidak efisien untuk ruang pencarian yang besar, sementara *Random Search* sering gagal mencapai konvergensi yang optimal [8]. Di sinilah Optimasi Bayesian berperan penting, metode ini membangun model probabilistik untuk memetakan *hyperparameter* ke performa model dengan secara cerdas menyeimbangkan eksplorasi dan eksploitasi ruang pencarian[8].

Pemilihan arsitektur *deep learning* yang tepat menjadi faktor krusial dalam mengoptimalkan performa klasifikasi citra medis, khususnya *X-ray* toraks. Tiga

arsitektur yaitu EfficientNetB2, DenseNet121, dan ResNet50 telah menunjukkan keunggulan masing-masing dalam domain *computer vision* medis. EfficientNetB2 menonjol dengan efisiensi komputasinya melalui filosofi *compound scaling* yang menyeimbangkan kedalaman, lebar, dan resolusi citra dalam mencapai akurasi tinggi dengan jumlah parameter yang jauh lebih sedikit dibanding arsitektur konvensional [9]. Di sisi lain, DenseNet121 mengimplementasikan *dense connectivity pattern* yang memfasilitasi *reuse* fitur dan memperkuat propagasi gradien, yang terbukti efektif dalam *dataset* medis dengan sampel terbatas [10]. DenseNet121 dapat mengurangi jumlah parameter hingga 3 kali lipat dibanding ResNet50 sambil mempertahankan performa yang sama [10]. Sementara itu, ResNet50 dengan arsitektur *residual learning*-nya tetap menjadi *baseline* yang tangguh (*robust*) dalam berbagai aplikasi *medical imaging*, khususnya dalam mengatasi problem *vanishing gradient* pada jaringan dalam [10]. Namun, performa optimal ketiga arsitektur ini sangat bergantung pada konfigurasi *hyperparameter* yang presisi, aspek yang sering kali diabaikan dalam penelitian sebelumnya [9].

Meskipun arsitektur CNN modern seperti EfficientNetB2, DenseNet121, dan ResNet50 telah menunjukkan performa yang baik, integrasi mekanisme *attention* dapat lebih meningkatkan kemampuan model dalam memfokuskan perhatian pada region anatomis yang relevan. *Convolutional Block Attention Module* merupakan modul *attention* yang efektif dan ringan yang dapat diintegrasikan secara *seamless* ke dalam berbagai arsitektur CNN [11]. CBAM bekerja dengan cara menginferensikan *attention maps* secara sekuensial pada dua dimensi terpisah: *channel attention* dan *spatial attention*. *Channel attention* berfokus pada "apa" fitur yang penting, sementara *spatial attention* berfokus pada "di mana" lokasi yang penting dalam citra [11]. Penelitian menunjukkan bahwa CBAM dapat meningkatkan performa klasifikasi pada berbagai *dataset* secara konsisten, termasuk pada aplikasi *medical imaging* seperti segmentasi lesi pada citra medis [12]. Keunggulan CBAM adalah kemampuannya untuk menyaring fitur yang tidak informatif dan memperkuat fitur diskriminatif dengan *overhead* komputasi yang *negligible* [11]. Namun, efektivitas CBAM sangat bergantung pada konfigurasi *hyperparameter* yang optimal, aspek yang belum banyak dieksplorasi dalam konteks klasifikasi penyakit paru-paru dari *X-ray* toraks.

Optimasi Bayesian melalui kerangka kerja Optuna menawarkan pendekatan sistematis untuk mengeksplorasi ruang *hyperparameter* yang kompleks. Dua algoritma utama yaitu *Tree-structured Parzen Estimator* (TPE) dan *Gaussian Process* (GP) memiliki karakteristik komplementer: TPE unggul dalam eksplorasi awal ruang pencarian dengan efisiensi komputasi tinggi karena menggunakan pendekatan non-parametrik berbasis *tree-structured density estimation*, sementara GP memberikan estimasi *uncertainty* yang lebih presisi untuk *fine-tuning* melalui pemodelan fungsi kontinu dengan *kernel covariance* [13]. Optuna sendiri merupakan *framework* optimasi *hyperparameter* generasi baru yang menggunakan API *define-by-run*, memungkinkan konstruksi ruang pencarian secara dinamis dan mendukung *pruning* untuk mempercepat proses optimasi [13]. Studi komparatif menunjukkan bahwa Optuna merupakan pilihan terbaik untuk masalah *Combined Algorithm Selection and Hyperparameter optimization* (CASH) dengan mempertimbangkan *trade-off* antara waktu komputasi dan performa model. HyperOpt menunjukkan keunggulan dalam optimasi arsitektur *multilayer perceptron* dibanding metode lain seperti Optunity dan SMAC [8]. Penelitian terkini menunjukkan bahwa strategi optimasi *hyperparameter* berbasis *Bayesian optimization* seperti TPE dapat meningkatkan akurasi model secara signifikan dengan waktu komputasi yang lebih efisien dibanding pendekatan *grid search* dan *random search* konvensional [8]. Dalam konteks klasifikasi penyakit paru-paru dari *X-ray*, perbedaan akurasi sekecil apapun akan sangat berdampak terhadap diagnosis. Oleh karena itu, pengoptimalan berupa eksplorasi sistematis terhadap interaksi antara arsitektur jaringan, mekanisme *attention*, dan konfigurasi *hyperparameter* menjadi sangat penting.

Penelitian ini akan mengimplementasikan strategi optimasi *hyperparameter* dengan mengintegrasikan *Gaussian Process* (GP) untuk fase eksplorasi dan *Tree-structured Parzen Estimator* (TPE) untuk fase eksploitasi melalui kerangka kerja Optuna. Hal ini dilakukan untuk mengoptimalkan tiga arsitektur CNN berbeda yaitu EfficientNetB2, DenseNet121, dan ResNet50. Model akan dilatih untuk bisa mengklasifikasi lima kategori penyakit paru-paru (*Bacterial Pneumonia*, COVID-19, *Normal*, *Tuberculosis*, dan *Viral Pneumonia*). Penelitian ini bertujuan untuk membandingkan secara sistematis performa enam model klasifikasi independen

yang merupakan kombinasi dari tiga arsitektur dengan *hyperparameter default* dan *hyperparameter* optimal hasil optimasi Bayesian. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem *Computer-Aided Diagnosis* (CAD) yang lebih akurat dan efisien untuk mendukung deteksi dini penyakit pernapasan di Indonesia, terutama di fasilitas kesehatan dengan keterbatasan infrastruktur diagnostik dan ketersediaan tenaga ahli radiologi.

B. Rumusan Masalah

1. Bagaimana menerapkan optimasi *hyperparameter* dengan menggunakan metode *Tree-structured Parzen Estimator* (TPE) dan *Gaussian Process* (GP) melalui kerangka kerja Optuna untuk klasifikasi penyakit paru-paru dari citra *X-ray* toraks?
2. Bagaimana dampak optimasi *hyperparameter* Bayesian terhadap performa klasifikasi pada tiga arsitektur CNN berbeda (EfficientNetB2, DenseNet121, ResNet50)?

C. Batasan Masalah

1. Batasan Dataset

Dataset yang digunakan dalam penelitian ini bersumber dari repositori publik Kaggle yang berupa citra *X-ray* toraks dengan lima kategori diagnosis paru-paru. Kategori tersebut adalah *Bacterial Pneumonia*, COVID-19, *Normal*, *Tuberculosis*, dan *Viral Pneumonia*. Seluruh data diperoleh secara sekunder tanpa keterlibatan langsung dalam proses akuisisi citra dari lingkungan klinis. Oleh karena itu, keberagaman data bergantung sepenuhnya pada dataset yang sudah dipublikasi oleh masing-masing pemilik *dataset*.

2. Batasan Cakupan Klasifikasi

Ruang lingkup penelitian ini dibatasi pada klasifikasi lima kategori diagnosis paru-paru yaitu *Bacterial Pneumonia*, COVID-19, *Normal*, *Tuberculosis*, dan *Viral Pneumonia*. Pemilihan lima kategori diagnosis paru-paru di dasarkan pada ketersediaan *dataset* publik yang memiliki kelayakan dari segi kualitas dan jumlah data citra *X-ray* toraks.

3. Batasan Arsitektur Model

Arsitektur *deep learning* yang digunakan dalam penelitian ini terbatas pada tiga model yaitu EfficientNetB2, DenseNet121, dan ResNet50. Pertimbangan

pemilihan 3 Arsitektur Model didasarkan kepada Track record ketiganya yang terbukti efektif dalam citra medis, ketersediaan *pre-trained weights* pada ImageNet yang memungkinkan menggunakan *transfer learning*, dan memiliki keseimbangan antara kompleksitas arsitektur dan efisiensi komputasi. Selain itu, ketiga arsitektur model ini merepresentasikan paradigma desain yang berbeda yaitu *compound scalling*, *dense connectivity* dan *residual learning*.

4. Batasan Optimasi Hyperparameter

Optimasi *hyperparameter* dalam penelitian ini mengimplementasikan strategi *sequential model-based optimization*. Strategi ini menggunakan *Gaussian Process* (GP) untuk fase eksplorasi kemudian menggunakan *Tree-structured Parzen Estimator* (TPE) untuk fase eksploitasi. Keduanya dieksekusi melalui kerangka kerja Optuna. Konfigurasi pencarian dibatasi pada 50 *trial*, dengan alokasi 20 *trial* untuk GP *sampler* kemudian diteruskan sebanyak 30 *trial* untuk TPE. Parameter yang menjadi target optimasi mencakup *learning rate* (rentang 1×10^{-6} hingga 1×10^{-2} , skala logaritmik), *weight decay* (1×10^{-7} hingga 1×10^{-3} , skala logaritmik), jumlah *dense units* (128 hingga 512 dengan *step* 64), *dropout rate* (0,3 hingga 0,7 dengan *step* 0,1), *activation function* (*relu* atau *swish*), serta *label smoothing* (0,0 hingga 0,2 dengan *step* 0,05). *Batch size* dikonstantkan pada nilai 64 untuk menjamin stabilitas konvergensi dan *compliance* terhadap *constraint* memori GPU yang tersedia.

5. Batasan Infrastruktur Komputasi

Pelatihan, evaluasi, visualisasi dan pengujian model dilakukan menggunakan server komputasi Lovelace milik Universitas Atmajaya Yogyakarta. Spesifikasi dari Perangkat adalah dual GPU NVIDIA Ada L40S 48 GB, memori 128 GB DDR5, dan dual Intel Xeon EMR 4510. Server adalah server bersama sehingga diimplementasikan beberapa strategi untuk manajemen pelatihan. Beberapa startegi yang di terapkan adalah memory growth untuk mengontrol alokasi memori, penetapan batch size sebesar 64 untuk konsistensi penggunaan VRAM, dan mixed precision training untuk mengoptimalkan throughput komputasi sambil mengurangi konsumsi memori.

6. Batasan Pengembangan Model dan Deployment Model

Penelitian ini mengembangkan dan membandingkan enam model

klasifikasi independen: *EfficientNetB2-defaultparams*, *EfficientNetB2-bestparams*, *DenseNet121-defaultparams*, *DenseNet121-bestparams*, *ResNet50-defaultparams*, dan *ResNet50-bestparams*. varian "*bestparams*" menggunakan *hyperparameter* optimal hasil optimasi Bayesian berbasis Optuna. Prototipe *deployment* dikembangkan dengan menggunakan *Flask framework* untuk memvalidasi bahwa model terbaik dapat dioperasikan secara fungsional dalam *development environment*. Sistem memungkinkan pengguna untuk *upload* citra *X-ray*, menganalisis citra *X-ray*, menampilkan hasil prediksi dengan *confidence score* dan membuat laporan dalam ekstensi pdf dan csv.

D. Tujuan penelitian

Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi optimasi *hyperparameter bayesian Tree-structured Parzen Estimator* (TPE) dan *Gaussian Process* (GP) melalui kerangka kerja Optuna untuk menemukan konfigurasi *hyperparameter* optimal dalam klasifikasi penyakit paru-paru dari citra *X-ray* toraks. Penelitian ini juga akan menganalisis dan membandingkan dampak optimasi *hyperparameter* terhadap performa klasifikasi pada tiga arsitektur model CNN yaitu *EfficientNetB2*, *DenseNet121*, dan *ResNet50*. Hal ini dilakukan dengan cara membandingkan 3 arsitektur model menggunakan *hyperparameter default* dengan *hyperparameter* optimal. Melalui perbandingan sistematis ini, penelitian ini diharapkan dapat memberikan gambaran dan pemahaman terkait dengan dampak optimasi *hyperparameter* terhadap performa klasifikasi pada berbagai arsitektur CNN. Hasil penelitian juga akan mengidentifikasi apakah *hyperparameter* optimal bersifat *architecture-specific* atau dapat digeneralisasi.

E. Sistematika Penulisan

BAB I Pendahuluan

Bab ini memaparkan latar belakang masalah terkait klasifikasi penyakit paru-paru menggunakan citra *X-ray* toraks. Pembahasan ditekankan pada tantangan interpretasi subjektif, keterbatasan ketersediaan radiolog, dan kesenjangan infrastruktur diagnostik di fasilitas kesehatan Indonesia. Selain itu, bab ini menguraikan rumusan masalah mengenai penerapan optimasi *hyperparameter* berbasis *Bayesian optimization* (*Tree-structured Parzen Estimator* dan *Gaussian Process*) pada tiga arsitektur *deep learning* (*EfficientNetB2*, *DenseNet121*,

ResNet50). Bab ini juga menjelaskan tujuan penelitian dalam mengidentifikasi konfigurasi model optimal melalui perbandingan enam model kandidat, batasan penelitian, serta sistematika penulisan laporan.

BAB II Tinjauan Pustaka

Bab ini mengkaji literatur dan penelitian terdahulu yang relevan dengan klasifikasi penyakit paru-paru berbasis citra medis. Kajian mencakup studi tentang peran *X-ray* toraks dalam diagnosis klinis, penerapan *Convolutional Neural Network* untuk analisis citra medis, serta perkembangan arsitektur *deep learning* seperti EfficientNetB2, DenseNet121, dan ResNet50 dalam domain *medical imaging*. Bab ini juga menganalisis penelitian terkait teknik optimasi *hyperparameter* menggunakan *Bayesian optimization*, kerangka kerja Optuna sebagai *framework* implementasi, serta penerapan *attention mechanism* seperti *Convolutional Block Attention Module* untuk meningkatkan representasi fitur pada citra *X-ray* toraks.

BAB III Landasan Teori

Bab ini menjelaskan konsep teoretis yang menjadi fondasi penelitian secara mendalam. Pembahasan meliputi prinsip dasar *deep learning* untuk klasifikasi citra medis, arsitektur EfficientNetB2 dengan filosofi *compound scaling* yang mengoptimalkan *depth*, *width*, dan *resolution* secara bersamaan, DenseNet121 dengan *dense connectivity pattern* yang memfasilitasi *feature reuse*, dan ResNet50 dengan *residual learning framework* untuk mengatasi *vanishing gradient problem*. Bab ini juga menguraikan mekanisme kerja *Convolutional Block Attention Module* yang menggabungkan *spatial* dan *channel attention*, teknik *preprocessing* khusus citra *X-ray* toraks termasuk segmentasi paru-paru berbasis *mask* untuk mengisolasi *region of interest*, teori *Bayesian optimization* dengan *Tree-structured Parzen Estimator* dan *Gaussian Process* sebagai metode *sequential model-based optimization*, serta metrik evaluasi yang sesuai untuk *imbalanced medical datasets* seperti strategi *class weighting* dan augmentasi adaptif.

BAB IV Dataset dan Pengembangan Model

Bab ini menjelaskan secara komprehensif proses pengembangan model klasifikasi penyakit paru-paru berbasis citra X-ray toraks yang mencakup lima kategori kelas, yaitu *Bacterial Pneumonia*, *COVID-19*, *Tuberculosis*, *Viral Pneumonia*, dan *Normal*. Dataset dibagi menjadi *train*, *validation*, dan *test set* dengan distribusi yang disesuaikan untuk menjaga keseimbangan proporsi data. Tahapan *preprocessing* mencakup segmentasi paru-paru otomatis menggunakan *pre-trained U-Net*, normalisasi dengan *ImageNet statistics*, serta augmentasi adaptif untuk mengatasi *class imbalance*. Selanjutnya dilakukan optimasi *hyperparameter* berbasis Bayesian melalui framework Optuna dengan integrasi dua algoritma *sequential model-based optimization*: *Gaussian Process* (GP) untuk fase eksplorasi awal sebanyak 20 *trials* dan *Tree-structured Parzen Estimator* (TPE) untuk fase eksploitasi sebanyak 30 *trials*. Hasil optimasi tersebut diaplikasikan pada tiga arsitektur CNN berbeda yaitu EfficientNetB2, DenseNet121, dan ResNet50. Masing-masing diuji dalam konfigurasi *default* dan *optimized* untuk menghasilkan enam model klasifikasi independen. Proses pelatihan menggunakan strategi two-stage fine-tuning dengan *transfer learning* dari *ImageNet weights*, penerapan *class weighting* untuk mengatasi ketidakseimbangan kelas, serta *early stopping* untuk mencegah *overfitting*. Evaluasi performa dilakukan secara menyeluruh menggunakan metrik akurasi, *F1-score* makro, *precision*, *recall*, PR-AUC, serta *confusion matrix* untuk menganalisis pola kesalahan klasifikasi antarkelas.

BAB V Implementasi dan Pengujian Model

Bab ini membahas hasil eksperimen dan analisis performa dari keenam model klasifikasi yang dibangun. Proses optimasi *hyperparameter* Bayesian dengan integrasi TPE-GP menghasilkan konfigurasi optimal untuk parameter-parameter penting seperti *learning rate*, *weight decay*, *dense units*, *dropout rate*, *activation function*, dan *label smoothing*, dengan visualisasi berupa *optimization history* dan *convergence plot*. Analisis distribusi dataset menunjukkan adanya *class imbalance*, dan penerapan strategi *class weighting* serta augmentasi adaptif terbukti efektif dalam memperbaiki representasi kelas minoritas. Hasil pengujian memperlihatkan perbandingan performa keenam model pada data validasi dan uji dengan

mempertimbangkan *trade-off* antara akurasi dan kompleksitas komputasi. Model terbaik diidentifikasi berdasarkan F1-score makro dan PR-AUC, yang kemudian divalidasi melalui *statistical significance testing* untuk memastikan perbedaan performa antarmodel bersifat signifikan. Analisis *confusion matrix* memberikan wawasan terhadap pola kesalahan klasifikasi, terutama pada kelas dengan kemiripan visual tinggi seperti *Bacterial Pneumonia* dan *Viral Pneumonia*. Pembahasan terakhir menyoroti implikasi dari konfigurasi *hyperparameter optimal* terhadap efisiensi komputasi, waktu inferensi, serta potensi penerapan model di lingkungan klinis Indonesia yang memiliki keterbatasan sumber daya komputasi.

BAB VI Kesimpulan dan Saran

Bab ini berisi rangkuman temuan utama penelitian serta implikasinya terhadap pengembangan model klasifikasi penyakit paru-paru berbasis CNN. Pada bagian kesimpulan, dibahas hasil penelitian yang menjawab rumusan masalah terkait penerapan optimasi *hyperparameter* menggunakan metode Bayesian melalui Optuna serta perbandingan performa antar arsitektur CNN. Sementara itu, bagian saran memuat rekomendasi untuk penelitian selanjutnya, termasuk pengembangan optimasi Bayesian yang lebih spesifik terhadap arsitektur model, perluasan ruang pencarian *hyperparameter*, serta penerapan teknik lanjutan seperti augmentasi data dan *multi-task learning* untuk meningkatkan performa dan generalisasi model.