

BAB I

PENDAHULUAN

A. Latar Belakang

Berbagai kelainan retina, seperti *retinopati diabetik* (DME), *neovaskularisasi koroid* (CNV), dan *Drusen* akibat degenerasi *makula*, telah diidentifikasi sebagai penyebab utama kebutaan global yang sebenarnya dapat dicegah [1]. Menurut laporan *World Health Organization* (WHO), sekitar 2,2 miliar orang mengalami gangguan penglihatan, dengan 1 miliar kasus di antaranya belum tertangani atau bersifat *avoidable* [2]. Di Indonesia peningkatan prevalensi diabetes mellitus dari 6,9% (2013) menjadi 8,5% (2018) telah memicu lonjakan kasus komplikasi okuler seperti DME, yang memerlukan deteksi dini untuk mencegah kerusakan permanen [3]. Adanya tenaga *oftalmologi* yang tidak merata sekitar 1.522 dokter spesialis mata untuk melayani 270 juta penduduk menjadi hambatan utama dalam skrining massal [4]. Hal ini menjadi urgensi penerapan teknologi diagnostik yang akurat untuk proses skrining awal.

Optical Coherence Tomography (OCT) muncul sebagai modalitas kunci dalam *Ophthalmology* modern berkat kemampuannya mencitrakan struktur retina dengan resolusi mikrometer [5]. Adanya interpretasi manual citra *Optical Coherence Tomography* (OCT) membutuhkan waktu 10-15 menit per pasien dan rentan terhadap variabilitas subjektif antar klinisi, dengan tingkat kesalahan diagnosis mencapai 30% akibat faktor kelelahan atau bias manusia [6]. Studi terbaru menunjukkan bahwa integrasi *artificial intelligence* (AI) dalam *platform* telemedis memungkinkan skrining penyakit mata dilakukan secara *remote* menggunakan teknologi, sehingga dapat menjangkau ke masyarakat yang kurang memiliki akses ke layanan perawatan mata [7]. Penggunaan *deep learning* (DL) menjadi terobosan signifikan, salah satunya penggunaan model *deep learning* (DL) *Convolutional Neural Networks* (CNN) telah menunjukkan akurasi yang lebih konsisten dalam hal mengklasifikasikan penyakit retina berbasis *Optical Coherence Tomography* (OCT) dengan akurasi 96,6% pada dataset publik [8].

Model *Convolutional Neural Networks* (CNN) tunggal memiliki keterbatasan mendasar, termasuk bias arsitektur, *overfitting* pada data heterogen, dan generalisasi yang lemah terhadap variasi perangkat *Optical Coherence Tomography* (OCT) [9], [10], [11]. Sebagai contoh pada arsitektur VGG16 yang unggul dalam mengekstraksi pola spasial dasar dan gagal menangkap fitur multi-skala, sedangkan ResNet50 lebih efektif untuk jaringan dalam cenderung *overfitting* pada dataset kecil [12], [13]. Untuk mengatasi masalah pada model klasifikasi tunggal pendekatan *ensemble learning* diterapkan. Beberapa penelitian menggunakan *ensemble* pada citra OCT telah dilakukan diantaranya mencapai akurasi hingga 83% untuk klasifikasi multi-kelas [21]. Peningkatan akurasi klasifikasi diperlukan, pendekatan yang diusulkan menggunakan model *ensemble* dengan *feature fusion*, model tersebut menggunakan lima arsitektur *Convolutional Neural Networks* (CNN) yaitu VGG16, ResNet50, InceptionV3, DenseNet121, EfficientNetB0. Integrasi kelima model ini memadukan keunggulan masing-masing model tunggal dari VGG16 untuk pola spasial, ResNet50 dengan *residual connections* untuk fitur kompleks, InceptionV3 dengan filter multi-skala, DenseNet121 melalui koneksi padat antar-lapisan, dan EfficientNetB0 yang optimal dalam efisiensi komputasi [12], [13], [14], [15], [16]. Model membuktikan bahwa penggunaan model *ensemble Convolutional Neural Networks* (CNN) yang digunakan pada klasifikasi *glioma* otak mampu meningkatkan klasifikasi sebesar 12% dibandingkan model tunggal, hal ini menunjukkan potensi pendekatan ensemble dalam bidang medis [17].

Kinerja model *ensemble* sangat bergantung pada optimasi *hyperparameter*, seperti *learning rate*, *dropout rate*, dan konfigurasi *dense layer*. Pemilihan *hyperparameter* yang tepat secara substansial meningkatkan kemampuan model untuk mempelajari pola-pola kompleks dari data citra dan mencegah *overfitting* dengan menyeimbangkan antara kompleksitas dan generalisasi model [18]. Penelitian ini mengadopsi Keras Tuner dengan metode *RandomSearch* untuk mengeksplorasi 12 *hyperparameter* kritis, termasuk *learning rate* (0,00001 sampai dengan 0,01), *dropout rate* (0,2 sampai dengan 0,7), dan *units* pada *dense layer* (128 sampai dengan 512). Pendekatan merupakan solusi efisien untuk ruang pencarian

hyperparameter yang kompleks [19]. Pada *preprocessing* yang diterapkan untuk meningkatkan generalisasi model menggunakan augmentasi data diantaranya *random flip*, *rotation*, *zoom* untuk mensimulasikan variasi klinis, normalisasi piksel ke rentang $[0,1]$ dan penyeimbangan kelas dengan *class weighting* untuk mengatasi ketidakseimbangan data [20].

Adanya model *ensemble* untuk klasifikasi dengan akurasi yang tinggi pengintegrasikan ke *platform telehealth* berpotensi menjangkau 1,2 juta pasien diabetes yang berisiko *retinopati*, sekaligus menekan biaya skrining dari Rp 500.000 menjadi Rp 50.000 per pasien [22]. Berdasarkan uraian tersebut penelitian ini menjadi salah satu pendekatan penggunaan *deep learning* untuk inovasi layanan kesehatan dalam meningkatkan aksesibilitas layanan *ophthalmologic* secara luas.

B. Rumusan Masalah

1. Bagaimana mengembangkan model *ensemble* untuk mengklasifikasi penyakit retina pada citra *Optical Coherence Tomography* (OCT)?
2. Bagaimana proses optimasi *hyperparameter* dapat menentukan konfigurasi terbaik untuk mencapai akurasi maksimal pada model *ensemble* yang diusulkan?

C. Batasan Masalah

1. Keterbatasan Dataset

Penelitian ini menggunakan dataset citra *Optical Coherence Tomography* (OCT) retina yang tersedia secara publik dari *platform* Kaggle. Dataset ini terdiri dari gambar yang diklasifikasikan ke dalam empat kelas kondisi retina, yaitu: CNV (*Choroidal Neovascularization*), DME (*Diabetic Macular Edema*), *Drusen*, dan Normal. Secara keseluruhan, dataset dibagi menjadi tiga dengan komposisi 80% untuk data latih (*train*) yang terdiri dari 8.000 gambar, 15% untuk data validasi (*validation*) sebanyak 1.200 gambar, dan 5% untuk data uji (*test*) sebanyak 400 gambar. Perlu dicatat bahwa tidak ada pengumpulan data primer melalui uji klinis atau eksperimen lapangan, sehingga variasi data terbatas pada karakteristik yang sudah ada dalam dataset, seperti resolusi citra,

jenis perangkat OCT, dan demografi pasien. Hal ini berpotensi mempengaruhi generalisasi model pada populasi atau kondisi klinis yang belum terwakili.

2. Fokus pada Kondisi Retina Tertentu

Penelitian ini berfokus pada klasifikasi empat kondisi retina yaitu CNV (pertumbuhan pembuluh darah abnormal di bawah retina), DME (penumpukan cairan makula akibat diabetes), *Drusen* (deposit terkait degenerasi makula), dan Normal (retina sehat). Kondisi lain seperti *ablasi* retina, *retinitis pigmentosa*, atau infeksi retina tidak termasuk dalam analisis. Pemilihan ketiga kondisi patologis ini didasarkan pada prevalensi dan urgensi klinisnya, sedangkan kelas normal digunakan sebagai pembanding untuk membedakan ciri retina sehat dan bermasalah.

3. Seleksi Arsitektur *Ensemble*

Model *ensemble* yang dikembangkan menggabungkan lima arsitektur *deep learning*: VGG16 (ekstraksi pola spasial dasar), ResNet50 (*residual connections* untuk jaringan dalam), InceptionV3 (filter multi-skala), DenseNet121 (*dense connectivity* antar-lapisan), dan EfficientNetB0 (efisiensi komputasi). Arsitektur terkini seperti *Vision Transformer* (ViT) atau *Swin Transformer* tidak dieksplorasi karena pertimbangan kompleksitas komputasi dan fokus pada model *Convolutional Neural Networks* (CNN) yang telah divalidasi secara luas dalam literatur *Optical Coherence Tomography* (OCT).

4. Optimasi *Hyperparameter* Terbatas

Proses optimasi *hyperparameter* dibatasi pada konfigurasi berikut:

- a) Jumlah *Dense layer*: 128–512 neuron per cabang (`hp.Int(128, 512, step=64)`).
- b) *Learning rate*: 0,0001 hingga 0,01 (`hp.Float(0,0001; 0,01, sampling="log")`).
- c) *Dropout rate*: 0,2–0,6 untuk cabang individu dan 0,2–0,7 untuk *fusion layer* (`hp.Float(0,2; 0,7; step=0,1)`).
- d) Fungsi aktivasi: ReLU, tanh, atau ELU (tanpa *sigmoid*).

- e) Batch size: 32 (tetap, tidak dioptimasi). Metode *Random Search* dengan 5 iterasi (max_trials=100) digunakan untuk menyeimbangkan eksplorasi ruang parameter dan efisiensi komputasi.
- f) Pembatasan jumlah epoch pelatihan (100 epoch) demi efisiensi waktu.

5. Ketergantungan pada Kapasitas Komputasi

Pelatihan model dilakukan menggunakan server Supermicro SYS-621C-TN12R - X13 dengan spesifikasi teknis sebagai berikut: dua prosesor Intel Xeon EMR 4510 (12 Core @2.4GHz, 30MB cache, 150W), memori 128GB DDR5-4800 ECC (4x32GB), dan dua GPU NVIDIA Ada L40S 48GB GDDR6 PCIe Gen 4. Sistem operasi yang digunakan adalah Ubuntu 22.04 LTS (x86_64) dengan Python 3.10. Meskipun server ini memiliki kapasitas komputasi tinggi, penelitian tetap dibatasi oleh penggunaan *batch size* kecil (32) untuk memastikan kompatibilitas dengan VRAM GPU.

D. Tujuan Penelitian

Penelitian ini bertujuan untuk merancang dan mengembangkan sebuah arsitektur model *ensemble* dengan mekanisme *feature fusion* untuk melakukan klasifikasi empat kelas penyakit retina (CNV, DME, Drusen, dan Normal) dari citra *Optical Coherence Tomography* (OCT). Selain itu, penelitian ini juga bertujuan untuk menganalisis proses optimasi hyperparameter guna mengidentifikasi konfigurasi terbaik mencakup *learning rate*, *dropout*, jumlah neuron, dan optimizer yang mampu memaksimalkan akurasi klasifikasi pada model *ensemble* yang diusulkan, sehingga dapat mendukung diagnosis penyakit retina secara lebih tepat dan efektif.

E. Sistematika Penulisan

BAB I Pendahuluan

Bab ini memaparkan latar belakang masalah terkait klasifikasi penyakit retina menggunakan citra OCT, rumusan masalah yang ingin dipecahkan, tujuan penelitian terutama dalam *hyperparameter* dan *ensemble learning*, ruang lingkup, serta sistematika penulisan laporan penelitian.

BAB II Tinjauan Pustaka

Bab ini menguraikan kajian literatur dan penelitian-penelitian terdahulu yang berkaitan dengan klasifikasi penyakit retina, metode *ensemble learning*, teknik optimasi *hyperparameter*, dan pemrosesan citra OCT sebagai dasar pengembangan model.

BAB III Landasan Teori

Bab ini menjelaskan teori-teori fundamental yang menjadi dasar penelitian, seperti konsep *ensemble learning*, algoritma klasifikasi, metode optimasi *hyperparameter* (misalnya *Bayesian Optimization*, *Grid Search*), serta karakteristik citra OCT dan penyakit retina yang menjadi objek klasifikasi.

BAB IV Metodologi Penelitian

Bab ini menjabarkan bahan dan alat penelitian, yaitu dataset citra OCT, perangkat lunak dan hardware yang digunakan, serta tahapan penelitian meliputi preprocessing data, pembangunan model *ensemble*, strategi optimasi *hyperparameter*, dan metode evaluasi performa klasifikasi.

BAB V Hasil dan Pembahasan

Bab ini menyajikan hasil eksperimen optimasi *hyperparameter* pada model *ensemble*, evaluasi kinerja klasifikasi penyakit retina berdasarkan metrik yang relevan (akurasi, presisi, recall, F1-score), serta analisis dan pembahasan terkait dampak optimasi terhadap peningkatan performa model.

BAB VI Kesimpulan dan Saran

Bab ini berisi kesimpulan dari penelitian mengenai efektivitas optimasi *hyperparameter* dalam meningkatkan klasifikasi penyakit retina berbasis citra OCT menggunakan model *ensemble*, serta saran untuk penelitian lanjutan dan pengembangan metode yang lebih baik.