

BAB I

PENDAHULUAN

Bab pendahuluan ini membahas mengenai latar belakang masalah, rumusan masalah, tujuan dan manfaat, ruang lingkup, serta sistematika penulisan yang digunakan dalam dokumen skripsi ini.

1.1 Latar Belakang

Organ mata memiliki peran yang sangat penting dalam mendukung aktivitas sehari-hari, dengan penglihatan sebagai indera utama yang memungkinkan kita untuk berinteraksi dengan lingkungan sekitar. Sebagai bagian dari sistem visual yang kompleks, mata terdiri dari berbagai elemen, termasuk kornea, lensa, retina, dan saraf optik yang bekerja secara sinergis untuk memproses cahaya dan menghasilkan gambar visual. Namun, banyak individu di seluruh dunia yang mengalami gangguan penglihatan akibat berbagai kondisi mata. Penyakit mata, baik yang disebabkan oleh faktor usia, kecelakaan, atau kondisi medis lainnya, dapat mengganggu kemampuan visual seseorang, yang pada gilirannya memengaruhi kualitas hidup mereka. Menurut laporan WHO, lebih dari 2,2 miliar orang di dunia mengalami gangguan penglihatan, dengan sekitar 1,1 miliar di antaranya dapat dicegah atau diobati, namun akses terbatas terhadap perawatan mata di banyak wilayah menghambat upaya pencegahan dan pengobatan tersebut (Burton dkk., 2021).

Glaukoma termasuk ke dalam salah satu penyebab utama kebutaan yang tidak dapat dipulihkan di seluruh dunia. Penyakit ini terutama disebabkan oleh peningkatan cairan yang ada di dalam mata atau yang disebut dengan *intraocular pressure* (IOP), yang menyebabkan kerusakan progresif pada saraf optik dan akhirnya mengakibatkan kehilangan penglihatan permanen (Varma dkk., 2011). Menurut perkiraan, sekitar 111,8 juta orang akan menderita glaukoma pada tahun 2040, dengan mayoritas kasus berasal dari Asia dan Afrika, wilayah dengan tingkat pertumbuhan populasi yang tinggi dan akses terbatas terhadap layanan kesehatan mata (Tham dkk., 2014). Glaukoma dikenal sebagai "pencuri penglihatan yang diam-diam" karena sering kali berkembang tanpa gejala yang jelas pada tahap awal, sehingga banyak pasien tidak menyadari adanya penyakit ini hingga kerusakan sudah terjadi secara signifikan (Quigley & Broman, 2006). Akibatnya, banyak kasus glaukoma baru

terdiagnosis pada tahap lanjut, di mana intervensi medis hanya dapat memperlambat progresi penyakit tetapi tidak dapat mengembalikan penglihatan yang hilang (Jonas dkk., 2017).

Saat ini, metode utama dalam diagnosis glaukoma meliputi pemeriksaan IOP, analisis lapang pandang (*visual field*), serta evaluasi struktur *optic disc* melalui fundus retina (Tham dkk., 2014). Salah satu indikator utama dalam analisis fundus retina adalah rasio *cup-to-disc* (CDR), yang sering kali menjadi tanda awal adanya kerusakan akibat glaukoma (Jonas dkk., 2017). Studi telah menunjukkan bahwa analisis fundus retina dapat memberikan informasi struktural yang penting untuk mengklasifikasi glaukoma, terutama melalui pengukuran peningkatan rasio CDR dan perubahan bentuk *optic disc* (Burgoyne, 2011). Namun, metode manual dalam pemeriksaan ini sering kali memakan waktu, memerlukan keahlian khusus, dan bergantung pada tingkat pengalaman dari dokter mata (Li dkk., 2018). Selain itu, ketidaksempurnaan dalam teknik pengukuran tradisional dapat menyebabkan hasil yang bervariasi antar pemeriksa, sehingga meningkatkan risiko keterlambatan diagnosis (Tampa, Mekongo, & Tiedeu, 2024).

Dalam beberapa tahun terakhir, kemajuan dalam bidang *artificial intelligence* (AI), khususnya *deep learning*, telah memberikan solusi yang lebih efisien untuk diagnosis otomatis glaukoma (Guergueb & Akhloufi, 2023). Salah satu pendekatan yang paling banyak digunakan adalah *Convolutional Neural Networks* (CNN), yang telah terbukti efektif dalam analisis citra medis, termasuk citra fundus retina, untuk mengklasifikasi tanda-tanda glaukoma (Li dkk., 2018; Tampa dkk., 2024). CNN dapat secara otomatis mengenali pola yang relevan dalam citra fundus tanpa memerlukan ekstraksi fitur secara manual, menjadikannya lebih efisien dibandingkan metode berbasis *machine learning* tradisional (Juneja dkk., 2022).

Salah satu teknik yang umum digunakan untuk meningkatkan kinerja model CNN pada data medis adalah *transfer learning*, yang memungkinkan model yang telah dilatih pada *dataset* besar untuk diadaptasi dengan *dataset* yang lebih kecil seperti citra fundus namun tetap menghasilkan kinerja yang optimal (Sarki dkk., 2020). *Transfer learning* telah diterapkan dalam berbagai studi untuk meningkatkan akurasi klasifikasi glaukoma berdasarkan citra fundus retina, bahkan dalam kondisi di mana jumlah data yang tersedia terbatas (Tampa dkk., 2024). Selain itu, penerapan *preprocessing* seperti teknik *data*

augmentation juga dapat membantu meningkatkan kinerja model dalam mengklasifikasi glaukoma (Tampa dkk., 2024).

VGG19 (*Visual Geometry Group 19*) merupakan salah satu arsitektur CNN yang pertama kali diperkenalkan oleh Simonyan & Zisserman (2015). Arsitektur yang terdiri dari 19 *layers* (16 *convolution* dan 3 *fully-connected*) ini mampu mengekstraksi fitur visual yang mendetail, sehingga mencapai akurasi tinggi pada berbagai tugas klasifikasi gambar medis. Kulkarni & Ahmed (2024) menulis pada laporannya bahwa arsitektur VGG19 menghasilkan akurasi tertinggi (97,89%) untuk identifikasi glaukoma dibandingkan VGG16, ResNet50, ResNet152, InceptionV3, Xception, DenseNet121, dan EfficientNetB7. Temuan serupa disampaikan oleh He dkk. (2024) yang juga menempatkan VGG19 sebagai model dengan akurasi paling tinggi (92%) dalam klasifikasi penyakit pneumonia dibandingkan metode lain seperti ResNet50 dan SVM. Selain itu, Chen dkk. (2021) berhasil mencapai akurasi tertinggi (99,42%) ketika menggunakan model berbasis VGG19 untuk mengklasifikasi penyakit *Diabetic Macular Edema* (DME) pada pasien diabetes dibandingkan arsitektur lain seperti AlexNet, GoogleNet, VGG16, ResNet18, ResNet50, dan ResNet101.

Meskipun arsitektur seperti VGG19 telah tersedia, pembuatan model yang optimal tidak dapat terlepas dari penyesuaian *hyperparameter* yang tepat. *Hyperparameter* adalah parameter eksternal model yang ditentukan sebelum *training* (misalnya *learning rate*, *batch size*, dan *dropout rate*). Pemilihan *hyperparameter* yang sesuai sangat penting untuk mencapai kinerja model yang optimal (Ebadi dkk., 2025), karena konfigurasi *hyperparameter* yang kurang tepat dapat menyebabkan model mengalami *overfitting* (terlalu kompleks sehingga kinerjanya buruk pada data baru) atau *underfitting* (terlalu sederhana sehingga gagal mempelajari pola dari data *training* dengan baik).

Penerapan *deep learning* dalam klasifikasi penyakit glaukoma tidak hanya memberikan keuntungan dalam hal kecepatan dan akurasi diagnosis, tetapi juga dapat mengurangi beban tenaga medis serta meningkatkan aksesibilitas layanan kesehatan mata (Guergueb & Akhloufi, 2023; Varma dkk., 2011). Penelitian ini menaruh perhatian pada proses optimasi *hyperparameter* model berbasis arsitektur VGG19, agar kemampuan terbaik model dapat diwujudkan dalam klasifikasi penyakit glaukoma pada citra fundus retina. Hasil yang didapatkan dari penelitian ini dapat membantu dokter mata dalam melakukan

klasifikasi penyakit glaukoma yang lebih cepat dan akurat, terutama di daerah dengan keterbatasan tenaga medis dan fasilitas kesehatan.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dipaparkan, rumusan masalah dari penelitian ini adalah bagaimana mengoptimasi *hyperparameter* terbaik untuk pembuatan model klasifikasi glaukoma menggunakan arsitektur VGG19 dari citra fundus retina.

1.3 Tujuan dan Manfaat Penelitian

Berdasarkan dari rumusan masalah yang sudah dipaparkan, tujuan yang ingin dicapai dari penelitian ini adalah untuk mencari *hyperparameter* terbaik dalam pembentukan model klasifikasi glaukoma menggunakan arsitektur VGG19 pada citra fundus retina. Penelitian ini juga bertujuan untuk melakukan evaluasi akurasi model pada setiap skenario *hyperparameter* guna memperoleh model dengan performa terbaik.

Manfaat utama dari penelitian ini adalah meningkatkan kecepatan dan efisiensi klasifikasi penyakit glaukoma melalui optimasi model, sehingga dalam jangka panjang dapat mengurangi angka kebutaan yang disebabkan oleh keterlambatan klasifikasi penyakit ini.

1.4 Ruang Lingkup

Ruang lingkup ditetapkan agar penelitian ini tidak menyimpang dari permasalahan yang sudah ditetapkan. Berikut adalah ruang lingkup pada penelitian ini:

1. *Dataset* yang digunakan merupakan gabungan dua buah sumber. *Dataset* ACRIMA merupakan bagian dari *ACRIMA Project* yang didirikan oleh *Ministry of Economy, Trade and Business of Spain* (Diaz-Pinto dkk., 2019). ACRIMA terdiri dari 705 citra fundus, dimana 396 diantaranya merupakan glaukoma. *Dataset* tersebut kemudian digabungkan dengan *Retinal IMage database for Optic Nerve Evaluation for Deep Learning* (RIM-ONE DL) yang didapatkan dari beberapa rumah sakit di Spanyol (Fumero dkk., 2020). RIM-ONE DL terdiri dari 485 citra fundus, 172 diantaranya merupakan glaukoma. Total jumlah data di dalam *dataset* adalah 1190 citra fundus yang terbagi menjadi dua kelas yaitu glaukoma dan normal, kemudian dibagi kembali menjadi tiga *split* yaitu *training*, *validation*, dan *testing*.
2. Proses augmentasi data dilakukan pada *training split*.

3. *Hyperparameter* yang dilakukan *tuning* guna mendapatkan kombinasi terbaik meliputi *dropout*, *learning rate*, dan *batch size*.
4. Evaluasi dilakukan dengan mengukur *accuracy* dan *loss* model pada setiap skenario yang dilakukan.

1.5 Sistematika Penulisan

Sistematika penulisan yang digunakan dalam penelitian ini terbagi dalam lima bab, yaitu:

BAB I PENDAHULUAN

Bab ini memaparkan latar belakang, rumusan masalah, tujuan dan manfaat penelitian, ruang lingkup penelitian, serta sistematika penulisan.

BAB II TINJAUAN PUSTAKA

Bab ini berisi kajian mengenai teori yang relevan dengan topik penelitian. Kajian ini meliputi pemahaman tentang glaukoma, teknik *deep learning*, CNN, *transfer learning*, arsitektur yang digunakan, dsb. Selain itu, juga dibahas beberapa studi terdahulu yang berkaitan dengan topik ini untuk memberikan gambaran tentang perkembangan teknologi dalam diagnosis glaukoma berbasis CNN.

BAB III METODOLOGI PENELITIAN

Bab ini menjelaskan metodologi yang digunakan dalam penelitian, mulai dari pengumpulan *dataset*, augmentasi *dataset*, pemilihan *hyperparameter*, implementasi model dengan *transfer learning* arsitektur VGG19, hingga evaluasi model.

BAB IV HASIL DAN PENJELASAN

Bab ini menyajikan konfigurasi perangkat keras, *environment*, dan nilai *hyperparameter* pada setiap konfigurasi pada seluruh skenario *training* yang dilakukan. Selanjutnya, nilai *training*, *validation*, dan *testing accuracy* dari setiap konfigurasi tersebut dibandingkan untuk dipilih model dengan performa terbaik dari setiap skenarionya, dan kemudian dari seluruh skenario. Terdapat juga pembahasan mengenai bagaimana dan seberapa besar pengaruh setiap *hyperparameter* terhadap performa model seperti *accuracy* dan *loss*. Bab ini ditutup dengan perhitungan nilai *precision*, *recall*, dan *F1-Score* dari model terbaik.

BAB V KESIMPULAN DAN SARAN

Bab ini berisi kesimpulan dari bab-bab sebelumnya dan penelitian secara keseluruhan. Juga terdapat penguraian saran-saran yang dapat dilakukan untuk pengembangan lebih lanjut berdasarkan hasil dan keterbatasan yang dihadapi selama penelitian ini.