

## BAB 2 TINJAUAN PUSTAKA

### 2.1 Studi Literatur

Studi literatur memuat beberapa penelitian terdahulu, dan metode yang digunakan dapat mendukung penelitian ini. Berikut merupakan studi literatur pada beberapa penelitian terdahulu dapat dilihat pada **Tabel 2.1**

**Tabel 2.1** Studi Literatur Penelitian Terdahulu

NO	JUDUL PENELITIAN	PENULIS DAN TAHUN	METODE	HASIL AKURASI
1	Enhancement of Diabetic Retinopathy Prognostication Utilizing Deep Learning, CLAHE, and ESRGAN	Alwakid, dkk. (2023)	DenseNet-121	Hasil penelitian tersebut mereka melakukan 2 skenario kasus untuk menguji penelitian mereka, yakni kasus 1 dengan menggunakan CLAHE dan ESRGAN, lalu kasus 2 dengan tanpa menggunakan metode CLAHE dan ESRGAN. Berdasarkan 2 kasus yang diuji kasus 1 mendapatkan akurasi yang baik sebesar 98.7% dan kasus 2 mendapatkan akurasi 81.2%
2	Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network Model Resnet-50	Verdy, dkk (2023)	Resnet-50	Hasil penelitian tersebut mereka melakukan pembagian pengujian rasio menjadi 70:30, 80:20, dan 90:10. Dalam penelitian tersebut pembagian rasio 70:30 menghasilkan akurasi tertinggi yaitu sebesar 66,71%, sedangkan pembagian rasio 80:20 menghasilkan akurasi terendah yaitu sebesar 65,59%, dan pembagian

				rasio 90:10 menghasilkan akurasi 65.59%
3	Detection of Diabetic Retinopathy Using Custom CNN to Segment the Lesions	Saleh Albahli, dkk (2021)	Resnet-50, VGG19, VGG16	Hasil penelitian tersebut mereka melakukan preprocessing yang dilakukan adalah Brightening, Color, dan Kontras (BCC), meningkatkan <i>Color Jitter</i> (CJ), dan CLAHE dengan menggunakan ResNet 50, VGG19, dan VGG16. Pada penelitian ini ResNet 50 memberikan akurasi terbaik untuk dataset yang sudah di preprocessing dengan menggunakan metode CLAHE didapat akurasi sebesar 62.98%

## 2.2 Diabetic Retinopathy

*Diabetic retinopathy* (DR) adalah komplikasi dari diabetes yang berdampak pada kesehatan mata. Proses klasifikasi DR bertujuan untuk menentukan tingkat keparahan penyakit serta merumuskan langkah pengobatan yang tepat [10]. Klasifikasi DR terdiri dari beberapa tingkat: Tidak Ada DR (*No DR*), yang tidak menunjukkan tanda-tanda diabetic retinopathy; Ringan (*Mild*), dengan sedikit mikroaneurisma (pelebaran pada pembuluh darah kecil) yang terjadi pada retina, Sedang (*Moderate*) dengan lebih banyak mikroaneurisma, perdarahan retina, dan eksudat keras (endapan pada lemak atau protein), Parah (*Severe*), yang ditandai dengan banyak perdarahan retina, *venous beading* (pembuluh darah vena yang tidak normal), dan *intraretinal microvascular abnormalities* (IRMAs) atau perubahan pada pembuluh darah kecil di retina, dan Proliferatif (PDR), dengan pertumbuhan pembuluh darah baru yang abnormal di retina atau diskus optikus yang dapat menyebabkan perdarahan vitreous atau ablasi retina [11].

Gejala *diabetic retinopathy* bervariasi sesuai dengan tingkat keparahannya [12]. Pada tahap *No DR*, tidak ada gejala atau perubahan pada penglihatan, tetapi pemeriksaan mata harus tetap rutin. Pada tahap *Mild*/Tahap Ringan, gejala mungkin belum signifikan dan penglihatan tetap normal, namun kontrol gula darah dan pemeriksaan mata teratur diperlukan. Pada tahap *Moderate*/Tahap Sedang gejala seperti penglihatan kabur atau adanya bintik-bintik gelap dapat mulai muncul, dan perawatan mungkin diperlukan untuk mencegah perkembangan lebih lanjut. Pada tahap *Severe*/Tahap Parah, gejala yang lebih serius seperti penglihatan sangat kabur, lebih banyak bintik-bintik gelap, dan kesulitan melihat di

malam hari dapat terjadi, sehingga memerlukan perawatan medis segera untuk mencegah kerusakan retina lebih lanjut. Tahap PDR (*Proliferative DR*) adalah yang paling serius, dengan gejala termasuk kehilangan penglihatan yang signifikan, bintik-bintik gelap besar, dan bahkan kebutaan, yang mungkin memerlukan perawatan intensif seperti operasi laser atau *vitrektomi* [13]. Maka dari itu, penting untuk selalu memantau kesehatan pada mata dan mengontrol diabetes dengan baik untuk mencegah atau memperlambat perkembangan *diabetic retinopathy*.

### 2.3 Data Preprocessing

*Preprocessing data* merupakan tahapan yang berguna untuk meningkatkan kualitas citra yang digunakan, karena dengan menggunakan kualitas citra yang baik dapat menghasilkan informasi gambar yang lebih baik yang akan digunakan untuk pemrosesan lebih baik [14]. Selain itu, dilakukannya *preprocessing data* adalah untuk mendapatkan format gambar yang standar dengan cara mengolah gambar pada dataset yang mengandung banyak noise. Misalnya, beberapa gambar yang tidak fokus, mempunyai banyak eksposur, pencahayaan yang ekstra, dan adanya latar belakang yang hitam [15].

Metode *preprocessing* yang digunakan dalam penelitian ini adalah metode Ben Graham, yang dirancang untuk meningkatkan kualitas gambar pada dataset citra retina. Metode ini dilakukan melalui beberapa langkah utama, yaitu:

1. Rescale Gambar: Mengubah ukuran dari citra yang akan sesuai dengan kebutuhan model
2. Pengurangan Warna Citra : Mengurangi intensitas warna dengan mengaplikasikan warna lokal ke 50% abu-abu

Metode Ben Graham memiliki beberapa keunggulan yang menjadi alasan utama penggunaannya dalam penelitian ini. Ben Graham dipilih karena fokus pada peningkatan kontras citra yang sederhana namun tanpa menambah noise, proses lebih efisien dan tidak memerlukan penyesuaian parameter yang kompleks, hasil dari *preprocessing* jadi lebih konsisten, sehingga dapat mendukung performa model secara optimal.

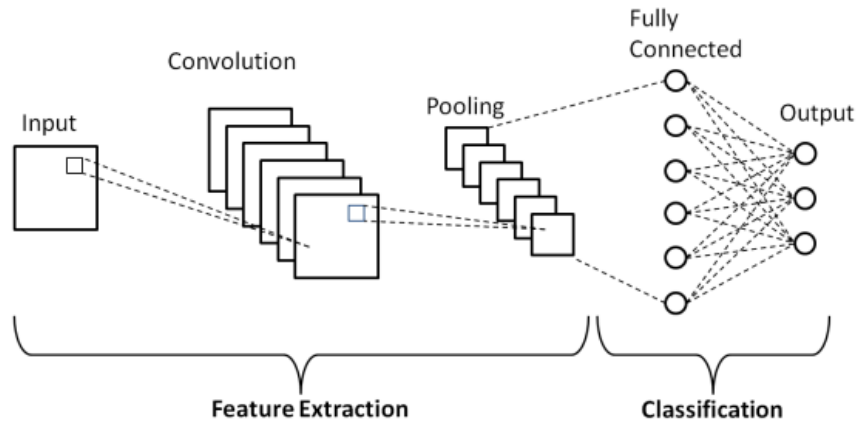
### 2.4 Hyperparameter Tuning

Hyperparameter Tuning merupakan teknik yang digunakan untuk menentukan kombinasi parameter yang optimal terhadap model Convolutional Neural Networks yang dibangun. Penggunaan teknik hyperparameter tuning memiliki dampak yang signifikan terhadap kinerja model yang dibangun [20]. Adapun parameter yang akan dilakukan tuning antara lain dropout value dan optimizer untuk melatih model.

### 2.5 Convolutional Neural Network

*Convolutional Neural Network* (CNN) merupakan salah satu jenis algoritma *Deep Learning* yang banyak digunakan untuk menganalisis, mengenali, atau mengklasifikasikan gambar karena membuat gambar lebih mudah untuk dianalisis. Selain itu, CNN dapat mengenali objek sebuah gambar yang dapat digunakan machine learning untuk mengenali gambar [18]. *Convolutional Neural Network* (CNN) terdiri


dari 3 macam layer diantaranya yakni *convolution layer*, *pooling layer*, dan *fully connected layer* [19]. Adapun arsitektur CNN dapat dilihat pada **Gambar 2.1**.



**Gambar 2.1** Arsitektur CNN

### 2.5.1 Convolutional Layer

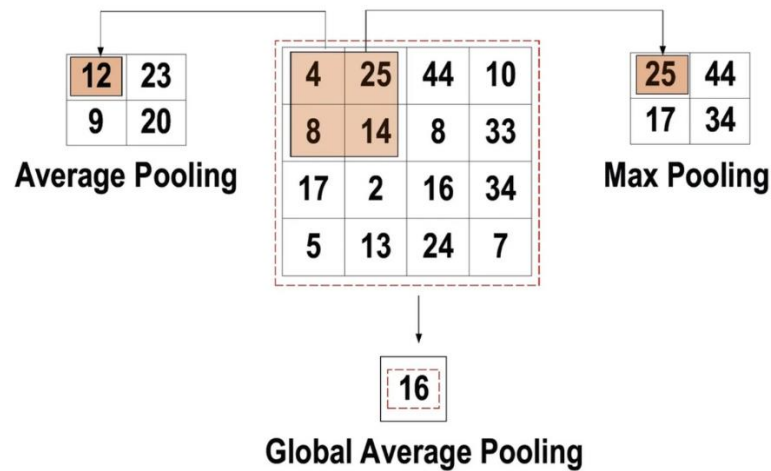
*Convolution Layer* adalah lapisan yang berfungsi untuk mengekstraksi fitur pada gambar. *Convolution Layer* terdiri beberapa dari neuron yang membentuk filter sehingga menghasilkan keluaran *feature map* atau *activation map* [20]. Adapun detail dari proses convolution layer yang dapat dilihat pada **Gambar 2.2**.



**Gambar 2.2** Proses Convolution Layer

### 2.5.2 Pooling Layer


*Pooling layer* adalah lapisan yang dirancang untuk mengurangi jumlah parameter yang ada dan waktu komputasi dalam arsitektur CNN (*Convolutional Neural Network*). Ada beberapa metode penggabungan lapisan: pengumpulan pohon, pengumpulan gerbang, pengumpulan rata-rata, pengumpulan minimum, pengumpulan maksimum, pengumpulan rata-rata global (GAP), dan pengumpulan maksimum global. Metode *pooling* yang paling dikenal dan paling sering digunakan adalah *max pooling* dan *average pooling*. [21]. Fungsi *max pooling* adalah mengambil nilai maksimum dari proses konvolusi. Sedangkan fungsi *average pooling* adalah mencari nilai rata-rata dari proses konvolusi. Adapun detail dari proses tersebut dapat dilihat pada **Gambar 2.3**.



Gambar 2.3 Proses Pooling Layer

### 2.5.3 Fully Connected Layer

*Fully Connected Layer* adalah lapisan yang terhubung ke lapisan output yang berfungsi sebagai pengklasifikasi yang terdapat pada *Convolutional Neural Network* (CNN). Pada lapisan ini, semua neuron pada lapisan sebelumnya akan terhubung pada lapisan saat ini untuk dilakukan proses prediksi guna menghasilkan keluaran [22]. Adapun detail dari proses *fully connected layer* dapat dilihat pada Gambar 2.4.



Gambar 2.4 Proses Fully Connected Layer

### 2.6 ResNet-50

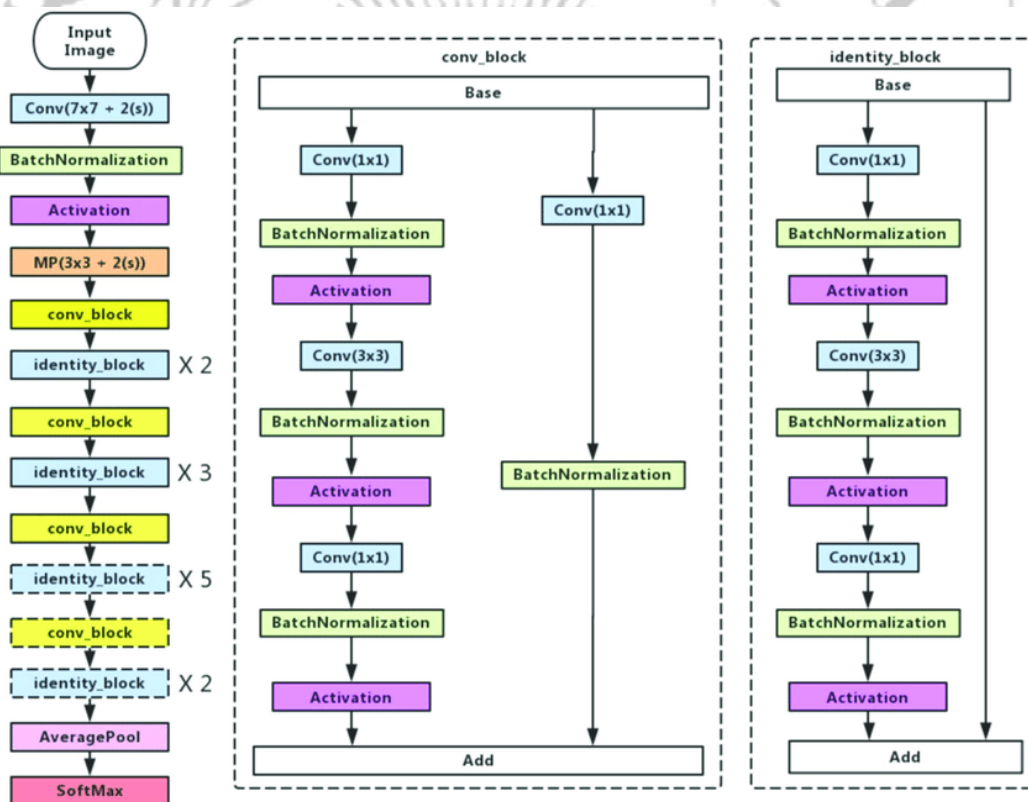
Dalam penelitian ini, model yang digunakan untuk klasifikasi *diabetic retinopathy* adalah arsitektur ResNet-50. ResNet (*Residual Network*) adalah jenis jaringan saraf dengan struktur residual yang memiliki kedalaman signifikan, di mana versi terdalamnya mencapai 152 lapisan [18]. ResNet-50 merupakan salah satu arsitektur *Convolutional Neural Network* (CNN) yang mengimplementasikan konsep *shortcut connections* untuk mengatasi masalah *vanishing gradient* yang muncul ketika jaringan semakin dalam. Dengan ResNet-50, sebanyak 405 gambar diubah menjadi 405 embedding, di mana setiap embedding terdiri dari 2048 fitur [19].

ResNet-50 telah terbukti efektif dalam berbagai tugas pengenalan gambar, termasuk klasifikasi *diabetic retinopathy*. Struktur blok residual pada arsitektur ini memungkinkan jaringan untuk mempelajari representasi yang lebih mendalam tanpa mengalami masalah *vanishing gradient*. Dalam

penerapan untuk *diabetic retinopathy*, ResNet-50 mampu mengidentifikasi dan mengklasifikasikan tingkat keparahan penyakit dengan akurasi tinggi [20].

Selain itu, penggunaan ResNet-50 untuk klasifikasi *diabetic retinopathy* sering melibatkan teknik *transfer learning*. Teknik ini memanfaatkan model yang telah dilatih sebelumnya menggunakan dataset besar seperti ImageNet sebagai dasar untuk melatih model lebih lanjut pada dataset spesifik *diabetic retinopathy*. Pendekatan ini memungkinkan model untuk menggunakan fitur-fitur yang sudah dipelajari sebelumnya sehingga dapat meningkatkan performa dalam menyelesaikan tugas klasifikasi tertentu.

Model ResNet-50 dipilih dalam penelitian ini karena kemampuannya mengatasi masalah vanishing gradient melalui struktur residual yang terdiri dari 50 lapisan. Arsitektur ini efektif untuk menganalisis detail kecil dalam citra retina, seperti pembuluh darah dan mikroaneurisma. Selain itu, ResNet-50 mendukung transfer learning dengan bobot pretrained pada dataset besar seperti ImageNet, sehingga dapat mengenali pola umum dan menyesuaikannya untuk tugas spesifik seperti deteksi *diabetic retinopathy*. Dibandingkan dengan model yang lebih dalam (misalnya, ResNet-101 atau ResNet-152), ResNet-50 menawarkan keseimbangan antara akurasi tinggi dan efisiensi komputasi, yang menjadikannya ideal untuk tugas ini.



Gambar 2.5 Arsitektur ResNet-50

## 2.7 Model Evaluasi

Untuk mengetahui performa dari model yang telah diterapkan dalam mengenali data citra dapat diukur dengan laporan klasifikasi. Seperti *Accuracy*, *Recall*, *Precision*, serta *F1-Score* yang dapat dihitung pada persamaan. Selain itu evaluasi model juga dapat dilihat dari grafik hasil plotting *accuracy*

dan *loss* guna melihat apakah model tersebut mengalami kendala seperti *overfitting* atau *underfitting*. Parameter tersebut selanjutnya ditentukan dengan bantuan *confusion matrix*.

$$\text{Accuracy} = \frac{\text{True Positive} + \text{True Negative}}{\text{Positive} + \text{Negative}}$$

$$\text{Recall} = \frac{\text{True Positive}}{\text{True Positive} + \text{True Negative}}$$

$$\text{Precision} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}}$$

$$\text{F1 - Score} = 2 \times \frac{\text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}}$$

**Tabel 2.2** Confusion Matrix

Nilai Prediksi	Nilai Sebenarnya	
	Positive	Negative
	True	True Positive
False	False Negative	True Negative

