

BAB 2

TINJAUAN PUSTAKA

2.1. DASAR TEORI

2.1.1. MATA

Mata Merupakan indra penglihatan pada manusia. Mata dibentuk untuk menerima rangsangan berkas-berkas cahaya pada retina selanjutnya dengan perantaraan serabut-serabut *nervus optikus*, mengalihkan rangsangan ini ke pusat penglihatan pada otak untuk ditafsirkan (Pearce, 1999).

2.1.2. CITRA FOTO *FUNDUS*

Citra foto *fundus* digital adalah foto retina yang berupa citra digital dengan pembesaran tinggi yang bertujuan untuk menampilkan detail – detail retina dan mendokumentasikan kondisi retina (Fraz, et al., 2012). Foto *fundus* digital diambil dengan menggunakan kamera *fundus* atau kamera retina. Kamera *fundus* merupakan sebuah mikroskop berdaya rendah yang disertai kamera dengan desain untuk mengambil gambar permukaan bagian dalam mata termasuk retina, lensa mata, syaraf optik, makula, dan sebagainya. Kamera *fundus* digunakan para ahli untuk memonitor perkembangan suatu penyakit, diagnosa penyakit, atau dalam program *screening* dimana foto tersebut dianalisis (Fraz, et al., 2012). Contoh foto *fundus* adalah pada


Gambar 2.1



Gambar 2.1. Contoh foto fundus mata normal

2.1.3. DIABETIC RETINOPATHY

Diabetic Retinopathy (DR) adalah *retinopati* (kerusakan pada retina) yang disebabkan oleh komplikasi diabetes melitus, yang pada akhirnya dapat menyebabkan kebutaan apabila tidak ditangani dengan cepat (Javidi, Pourreza, & Harati, 2017). Kelainan yang didapat pada *diabetic retinopathy* bisa berupa kebocoran/kenaikan permeabilitas kapiler dengan akibat *edema retina*, *eksudat* keras (berwarna kuning, karena *eksudasi plasma* yang lama berlangsung), plak-plak wol kapas (*cotton wool patches*) yang berwarna putih, tak berbatas tegas, dan terkait dengan *iskemia retina*, serta timbulnya perdarahan retina akibat gangguan *permeabilitas mikroanuerisma* atau karena pecahnya kapiler. Selain itu, terjadi juga obstruksi kapiler, yang menyebabkan berkurangnya aliran darah dalam kapiler retina (Suhardjo, 2007). Pada gambar **Gambar 2.2** adalah contoh foto *fundus Diabetic Retinopathy*.




Gambar 2.2. Contoh fundus *Diabetic Retinopathy*

2.1.4. GLAUKOMA

Glaukoma adalah penyakit mata yang ditandai oleh tekanan bola mata yang meningkat, ekskavasi dan atrofi pupil saraf optik, serta kerusakan lapang pandang yang khas (Radjamin, 1984). *Glaukoma* disebabkan oleh tekanan *intraokular* (TIO) yang (relatif) tinggi, yang ditandai oleh kelainan lapangan pandang dan *atrofi papil* saraf optik. Jadi, di sini TIO tidak harus selalu (absolut) tinggi, tetapi TIO relatif tinggi untuk individu tersebut. Misal, untuk populasi normal TIO sebesar 18 mmHg masih normal, tetapi pada individu


tertentu tekanan sebesar itu sudah dapat menyebabkan *glaucoma* (Suhardjo, 2007). Contoh foto *fundus Glukoma* terdapat pada **Gambar 2.3**



Gambar 2.3. *Contoh fundus glaukoma*

2.1.5. KATARAK

Katarak adalah setiap kekeruhanan pada lensa mata akibat hidrasi (penambahan cairan) lensa, denaturasi protein lensa atau akibat dari keduanya yang biasanya mengenai kedua mata dan berjalan progresif (Mansjoer, 2009). Kekeruhanan pada lensa tersebut akan mengakibatkan lensa menjadi tidak transparan, sehingga pupil akan berwarna putih atau abu-abu. kekeruhanan pada mata akan tampak dalam berbagai macam bentuk dan tingkat. kekeruhanan ini juga dapat ditemukan pada berbagai lokalisasi di lensa seperti korteks dan nukleus. Pada **Gambar 2.4** merupakan contoh foto *fundus Katarak*.



Gambar 2.4. *Contoh fundus katarak*

2.1.6. AGE-RELATED MACULAR DEGENERATION


Age-Related Macular Degeneration (degenerasi makula terkait usia) atau AMD adalah penyakit yang menyerang pusat penglihatan di retina yakni makula, tanpa penyebab lain pada populasi di atas 50 tahun (American Academy of Ophthalmology, 2015). Pada gambaran *fundus*, makula tampak lebih kuning/pucat (normalnya macula berwarna lebih gelap daripada daerah di sekitarnya) dikelilingi oleh bercak-bercak di sekitar *makula*, dan pembuluh darah tampak melebar. Bercak-bercak ini disebut *drusen*, yaitu tanda yang khas berbentuk bulat, berwarna kekuningan. Secara *histopatologi drusen* terdiri atas kumpulan materi *eosinofilik* yang terletak diantara *epitel pigmen* dan membran *Bruch*, sehingga *drusen* dapat menyebabkan pelepasan *fokal* dari *epitel pigmen* (Suhardjo, 2007). Berikut contoh foto *fundus Age-Related Macular Degeneration* terdapat pada **Gambar 2.5**



Gambar 2.5. Contoh *fundus AMD*

2.1.7. HIPERTENSI OKULI


Hipertensi okuli adalah suatu keadaan di mana tekanan intra *okuli* lebih besar daripada 21 mmHg. Batasan tersering yang dapat diterima untuk tekanan intra *okuli* pada populasi secara umum adalah 10-22 mmHG. Tidak ada efek *glaukomatous* pada pemeriksaan lapang pandangan. Penampakan normal pada *optic disc* dan lapisan serabut saraf. Sudut-sudut terbuka pada *gonioscopy*, tanpa ada riwayat sudut tertutup. Tidak adanya penyakit mata lain yang dapat menyebabkan peningkatan tekanan (Siregar, 2009). Pada **Gambar 2.6** adalah contoh foto *fundus Hipertensi Okuli*.



Gambar 2.6. *Contoh fundus Hipertensi Okuli*

2.1.8. MIOPIA

Miopia atau rabun jauh adalah suatu kelainan refraksi pada mata dimana bayangan difokuskan di depan retina, ketika mata tidak dalam kondisi berakomodasi. Ini juga dapat dijelaskan pada kondisi refraksi dimana cahaya yang sejajar dari suatu objek yang masuk pada mata akan jatuh di depan retina (American Optometric Association, 2006). Ketika mata tidak dalam kondisi berakomodasi. Ini juga dapat dijelaskan pada kondisi *refraksi* dimana cahaya yang sejajar dari suatu objek yang masuk. Perubahan *patologik* pada *miopia degeneratif* antara lain pembesaran bola mata dengan pemanjangan segmen *posterior*, *sklera* *ektatik* tipis, dan *stafiloma posterior*. *Ektasia posterior* atau *stafiloma* bisa melibatkan *polus posterior*, *area makula*, *zona peripapiler*, *area nasal*, maupun *fundus inferior* (Suhardjo, 2007). Pada **Gambar 2.7** merupakan contoh foto *fundus Miopia*.



Gambar 2.7. *Contoh fundus miopia*

2.1.9. COMPUTER VISION

Visi komputer (*Computer Vision*) adalah salah satu teknologi yang paling banyak dipakai pada zaman ini. Teknologi visi komputer ini merupakan salah satu bidang dari teknologi *Artificial Intelligence*. Visi komputer juga merupakan dan kumpulan dari metode-metode untuk mendapatkan, memproses, menganalisis suatu gambar atau dalam arti lain visi komputer, merupakan kumpulan metode-metode yang digunakan untuk menghasilkan angka-angka atau simbol-simbol yang didapat dari gambar yang diambil dari dunia nyata agar komputer dapat mengerti apa makna dari gambar tersebut. Inti dari teknologi visi komputer adalah untuk menduplikasi kemampuan penglihatan manusia kedalam benda elektronik sehingga benda elektronik dapat memahami dan mengerti arti dari gambar yang dimasukkan (Sonka, Hlavac, & Boyle, 2008).

2.1.10. AUGMENTATION

Augmentation data merupakan suatu teknik untuk menyelesaikan permasalahan keterbatasan data yang dimiliki pada saat penelitian (Shorten & Khoshgoftaar, 2019). Selain itu *Augmentation* data juga mencegah terjadinya *overfitting*, yaitu variasi data yang digunakan terlalu kompleks sehingga menyebabkan tingginya akurasi pada proses pelatihan namun pada proses pengujian nilai akurasinya rendah (Lever, Krzywinski, & Altman, 2016). Pada proses *Augmentation* terdapat beberapa metode untuk memperbanyak dan meningkatkan variasi citra. Proses *Augmentation* secara umum dibagi menjadi dua teknik yaitu memodifikasi warna citra dan melakukan transformasi geometrik. Dari berbagai macam metode *Augmentation* yang banyak digunakan adalah rotasi dan refleksi.

1. Rotasi

Rotasi adalah proses perpindahan nilai *pixel* suatu citra sebesar α° yang dihitung dari pusat rotasi menggunakan Persamaan berikut :

$$\begin{bmatrix} x_2 \\ y_2 \end{bmatrix} = \begin{bmatrix} \cos \alpha^\circ & -\sin \alpha^\circ \\ \sin \alpha^\circ & \cos \alpha^\circ \end{bmatrix} \begin{bmatrix} x_1 \\ y_1 \end{bmatrix} \quad (2.1)$$

Keterangan:

x_1 : Titik koordinat *pixel* awal sebelum rotasi vertikal

y_1 : Titik koordinat *pixel* awal sebelum rotasi horizontal

x_2 : Titik koordinat *pixel* awal setelah rotasi vertikal

y_2 : Titik koordinat *pixel* awal setelah rotasi horizontal

Di mana suatu *pixel* gambar pada titik koordinat (x_1, y_1) diputar sebesar α° dengan pusat $(0, 0)$ menghasilkan *pixel* gambar dengan titik koordinat (x_2, y_2) .

2. Refleksi

Refleksi adalah proses perubahan posisi nilai *pixel* suatu citra berdasarkan sumbu x dihitung menggunakan Persamaan berikut :

$$\begin{bmatrix} x_2 \\ y_2 \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \begin{bmatrix} x_1 \\ y_1 \end{bmatrix} \quad (2.2)$$

Keterangan:

x_1 : Titik koordinat *pixel* awal sebelum refleksi vertikal

y_1 : Titik koordinat *pixel* awal sebelum refleksi horizontal

x_2 : Titik koordinat *pixel* awal setelah refleksi vertikal

y_2 : Titik koordinat *pixel* awal setelah refleksi horizontal

Di mana suatu *pixel* gambar pada titik koordinat (x_1, y_1) direfleksikan terhadap sumbu x menghasilkan *pixel* gambar dengan titik koordinat (x_2, y_2) .

2.1.11. MACHINE LEARNING

Machine learning merupakan bidang studi yang didasari oleh gagasan bahwa mesin dapat belajar sendiri tanpa diprogram secara eksplisit. Data yang digunakan sistem untuk belajar disebut *dataset*, setiap contoh pelatihan disebut *training set* atau sampel. Semakin banyak data, semakin baik pembelajarannya. Secara umum tipe belajar dari *machine learning* terbagi

menjadi tiga metode yaitu *Supervised Learning*, *Unsupervised Learning*, dan *Reinforcement Learning* (Mitchell, 1997).

1. *Supervised Learning*

Supervised Learning adalah pembelajaran ML untuk menyelesaikan masalah rumit melalui *training* di dalam sistem saraf buatan menggunakan data yang sudah diberikan label. Label adalah *tag* dari data yang digunakan dalam model *machine learning*. *Supervised* lebih banyak digunakan dalam tugas klasifikasi dan regresi.

2. *Unsupervised Learning*

Unsupervised Learning adalah pembelajaran ML dengan menggunakan pola data yang sebelumnya belum terlihat atau belum terpikirkan. Teknik ini digunakan untuk mengidentifikasi pola-pola tersembunyi dalam data *input* yang tidak berlabel dan mengolah informasi melalui karakteristik yang terdapat pada pola tersebut dan biasa digunakan dalam tugas *clustering*.

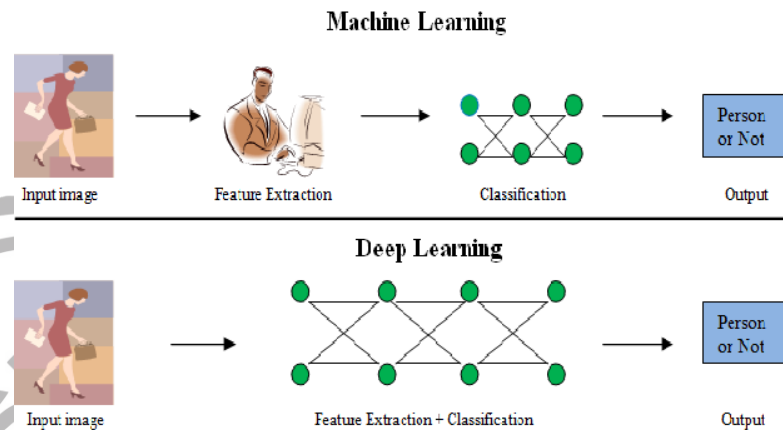
3. *Reinforcement Learning*

Reinforcement Learning adalah pembelajaran ML yang mengumpulkan informasi dengan berinteraksi pada lingkungan dan dapat belajar dari kesalahan untuk mendapatkan balasan atau tanggapan balik positif maupun negatif untuk berkembang, biasanya digunakan pada *logic game* dan mobil otomatis.

2.1.12. DEEP LEARNING

Deep Learning (DL) yang merupakan sebuah teknik berbasis jaringan saraf tiruan telah banyak digunakan dalam beberapa tahun terakhir sebagai salah satu metode implementasi *Machine Learning* (ML) (Ravi, et al., 2017). Salah satu potensi dari *deep learning* adalah mengganti fitur buatan tangan dengan algoritma yang efisien untuk pembelajaran hierarkis *unsupervised* (tanpa pengawasan) atau *semi-supervised feature learning* (semi-diawasi) dan *hierarchical feature extraction* (ekstraksi fitur) (Schmidhuber, 2015).

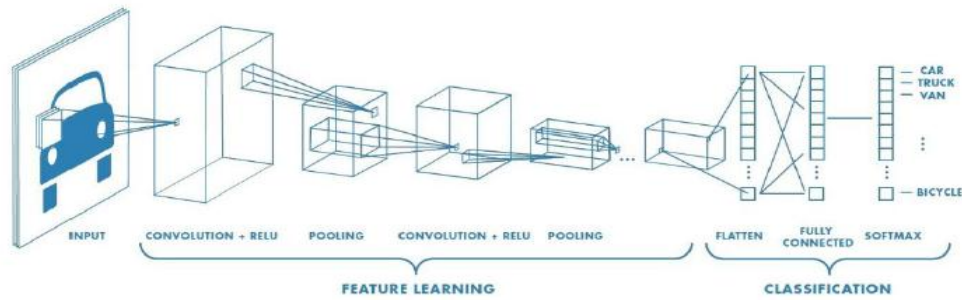
Gambar 2.8 adalah ilustrasi perbedaan *Machine Learning* dan *Deep Learning* (Krishna & Kalluri, 2019).



Gambar 2.8. Perbedaan machine learning dan deep learning
(Krishna & Kalluri, 2019)

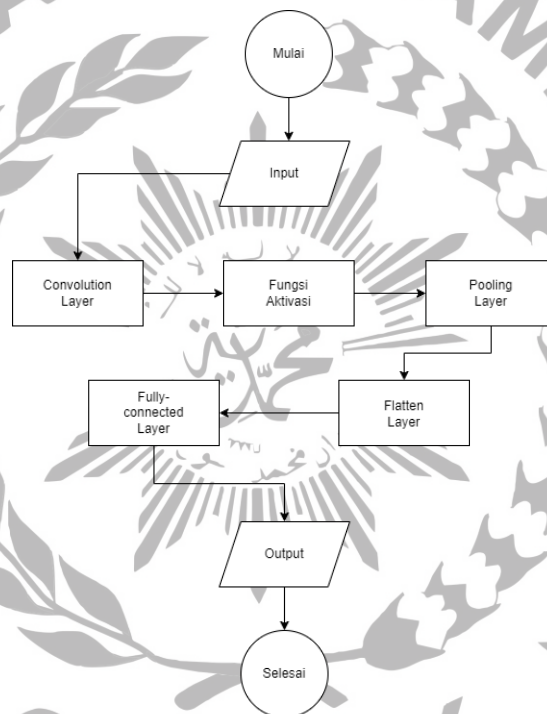
2.1.13. CONVOLUTIONAL NEURAL NETWORK

Convolutional Neural Network (CNN), juga disebut ConvNet, adalah jenis *Artificial Neural Network* (ANN), yang memiliki arsitektur *feed-forward* yang dalam dan memiliki kemampuan generalisasi yang luar biasa dibandingkan dengan *Neural Network* lain. Model CNN yang dalam terdiri dari serangkaian lapisan pemrosesan terbatas yang dapat mempelajari berbagai fitur data *input* (misalnya gambar). CNN dapat mempelajari fitur yang sangat abstrak dari objek khususnya data spasial dan dapat mengidentifikasinya secara lebih efisien (Ghosh, Sufian, Sultana, Chakrabarti, & De, 2020). Berikut adalah jaringan arsitektur *Convolutional Neural Network* :



Gambar 2.9. Arsitektur CNN

(Narejo, Talpur, Memon, & Rahoo, 2020)



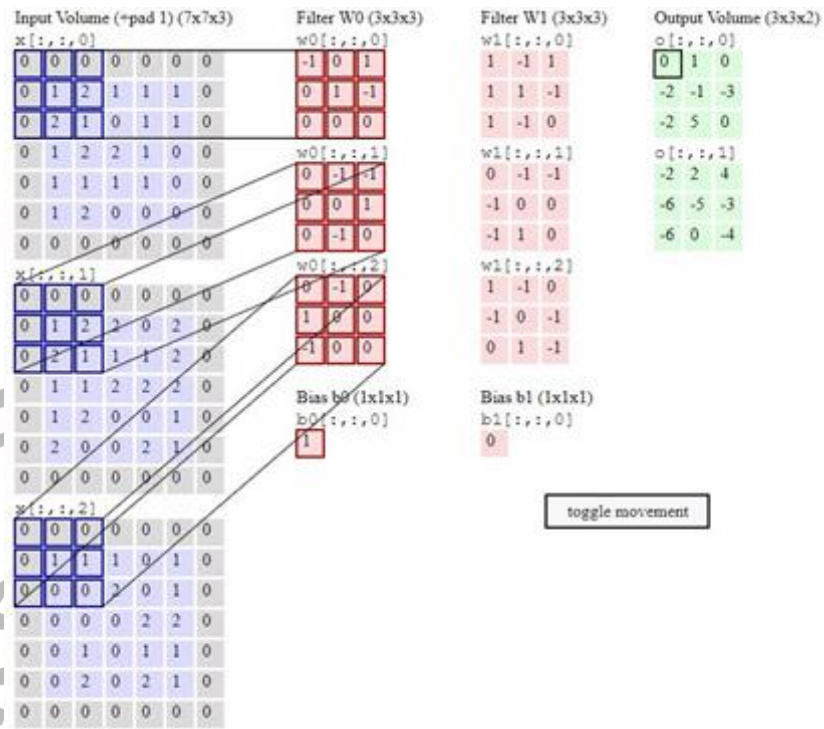
Gambar 2.10. Flowchart CNN

Berdasarkan gambar diatas, Tahap pertama pada arsitektur CNN adalah tahap konvolusi. Tahap ini dilakukan dengan menggunakan sebuah *kernel* dengan ukuran tertentu. Perhitungan jumlah *kernel* yang dipakai tergantung dari jumlah fitur yang dihasilkan. Kemudian dilanjutkan menuju fungsi aktivasi, biasanya menggunakan fungsi aktivasi ReLU (*Rectifier Linear Unit*), Selanjutnya setelah keluar dari proses fungsi aktivasi kemudian melalui proses *pooling*. Proses ini diulang beberapa kali sampai didapatkan peta fitur

yang cukup untuk dilanjutkan ke *fully connected neural network*, dan dari *fully connected network* adalah *output class*.

1. *Convolution Layer*

Convolution layer merupakan bagian dari tahap pada arsitektur CNN. Tahap ini melakukan operasi konvolusi pada *output* dari layer sebelumnya. Layer tersebut adalah proses utama yang mendasari jaringan arsitektur CNN. *Convolutional layer* terdiri dari *neuron* yang tersusun sedemikian rupa sehingga membentuk sebuah filter dengan panjang dan tinggi (*pixels*). Sebagai contoh, layer pertama pada *feature extraction layer* biasanya adalah *convolution layers* dengan ukuran 5x5x3. Panjang 5 *pixels*, tinggi 5 *pixels* dan tebal/jumlah 3 buah sesuai dengan *channel* dari *image* tersebut. Ketiga filter ini akan digeser ke seluruh bagian dari gambar. Setiap pergeseran akan dilakukan operasi “dot” antara *input* dan nilai dari filter tersebut sehingga menghasilkan sebuah *output* atau biasa disebut sebagai *activation map* atau *feature map*. Perhatikan ilustrasi berikut (Sena, 2017):




Gambar 2.11. Ilustrasi perhitungan konvolusi pada Convolution Layer

(Verma, 2020)

2. Fungsi Aktivasi

Fungsi aktivasi merupakan fungsi yang menggambarkan hubungan antara tingkat aktivitas internal (*summation function*) yang mungkin berbentuk linear ataupun *non-linear*. Fungsi ini bertujuan untuk menentukan apakah *neuron* diaktifkan atau tidak. Salah satu fungsi aktivasi yang biasa digunakan dalam CNN adalah fungsi aktivasi ReLU (*Rectified Linear Unit*). Pada dasarnya fungsi ReLU (*Rectified Linear Unit*) melakukan “*reshold*” dari 0 hingga *infinity*. Berikut grafik fungsi ReLU (Sena, 2017):




Gambar 2.12. Fungsi aktivasi ReLU
(Sena, 2017)

3. Layer Normalisasi

Layer normalisasi pada CNN (*Convolutional Neural Network*) adalah teknik yang digunakan untuk mengatur dan menormalkan nilai input dalam jaringan saraf secara efisien. Tujuan utama dari normalisasi adalah untuk meningkatkan stabilitas dan kecepatan konvergensi dalam pelatihan jaringan.

4. Pooling Layer

Pooling merupakan pengurangan ukuran matriks dengan menggunakan operasi *pooling*. *Pooling* layer biasanya berada setelah *convolution*. Pada dasarnya *pooling* layer terdiri dari sebuah filter dengan ukuran dan *stride* tertentu yang akan secara bergantian bergeser pada seluruh area *feature map*. Bentuk lapisan *pooling* umumnya dengan menggunakan filter dengan ukuran 2x2 yang diaplikasikan dengan langkah sebanyak dua dan beroperasi pada setiap irisan dari *input*-nya. Berikut ini adalah contoh gambar operasi *max-pooling* (Sena, 2017):




Gambar 2.13. Operasi max-pooling layer

(Raghuveer, Kumar, Sri, & Habeeb, 2019)

5. Flatten Layer

Flatten Layer adalah lapisan proses di mana *output* dari layer sebelumnya akan diubah menjadi 1 dimensi atau vektor (Guillemot, Heusele, Korichi, Schnebert, & Chen, 2020) yang nantinya dilanjutkan pada *fully-connected layer*.




Gambar 2.14. Proses klasifikasi pada CNN

(Bui, 2020)

6. Fully-Connected Layer

Fully-Connected Layer adalah sebuah lapisan dimana semua neuron aktivasi dari lapisan sebelumnya terhubung semua dengan neuron di lapisan selanjutnya sama seperti halnya dengan *neural*

network biasa. Pada dasarnya lapisan ini biasanya digunakan pada MLP (*Multi Layer Perceptron*) yang mempunyai tujuan untuk melakukan transformasi pada dimensi data agar data dapat diklasifikasikan secara linear. Pada **Gambar 2.15** merupakan visualisasi *Fully-Connected Layer*.



Gambar 2.15. *Visualisasi Fully-Connected Layer*

(Verma, 2020)

Perbedaan antara lapisan *Fully-Connected* dan lapisan konvolusi biasa adalah neuron di lapisan konvolusi terhubung hanya ke daerah tertentu pada *input*, sementara lapisan *Fully-Connected* memiliki neuron yang secara keseluruhan terhubung. Namun, kedua lapisan tersebut masih mengoperasikan dot produk, sehingga fungsinya tidak begitu berbeda (Sena, 2017).

2.1.14. TRANSFER LEARNING

Transfer learning adalah metode menggunakan jaringan saraf yang sudah dilatih sebelumnya lalu mengurangi jumlah parameter dengan cara mengambil beberapa bagian dari model yang sudah dilatih untuk digunakan dalam mengenali model baru (Abas, Ismail, Yassin, & Taib, 2018). Didasari oleh fakta bahwa manusia dapat menerapkan pengetahuan yang dipelajari sebelumnya untuk memecahkan masalah baru dengan lebih cepat dan dengan solusi yang lebih baik. Jaringan saraf sangat bergantung pada jumlah data untuk mencapai kinerja yang tinggi. Berikut adalah alasan mengapa *transfer learning* digunakan :

1. Masalah data, *deep learning* membutuhkan banyak data untuk bisa mendapatkan hasil yang baik. Membutuhkan banyak waktu untuk mendapatkan data berlabel jika dilakukan oleh manusia dalam mengambil gambar dan memberi label satu-per-satu.
2. Masalah komputasi, bahkan jika sudah mempunyai puluhan ribu data gambar untuk menyelesaikan masalah yang dimiliki, secara komputasi untuk melatih jaringan saraf yang dalam menggunakan puluhan ribu gambar tersebut akan sangat mahal membutuhkan waktu berhari-hari menggunakan GPU dan perlu dilakukan proses berulang untuk mendapatkan hasil yang memuaskan.


2.1.15. VGG

VGG adalah salah satu arsitektur CNN paling populer, yang diperkenalkan pada tahun 2014. VGG memperkenalkan total 6 konfigurasi CNN yang berbeda, di antaranya VGG-16 dan VGG-19 adalah yang paling sukses (Ghosh, Sufian, Sultana, Chakrabarti, & De, 2020).

1. VGG-16

VGG-16 merupakan varian dari model VGG yang terdiri dari 16 layer. VGG-16 adalah *convolutional neural network* yang dilatih menggunakan gambar dari *database* ImageNet yang terdiri kumpulan

data lebih dari 14 juta gambar yang termasuk dalam 1000 kelas. Model ini mencapai akurasi pengujian 92,7% dan menjadi top 5 di ImageNet (Simonyan & Zisserman, 2014). **Gambar 2.16** adalah tampilan arsitektur VGG-16 .



Gambar 2.16. Arsitektur VGG-16

(Smeda, 2019)

Tabel 2.1. Arsitektur VGG-16

Layer	Type	Output Shape
input_1	InputLayer	None, 224, 224, 3
block_conv1	Conv2D	None, 224, 224, 64
block_conv2	Conv2D	None, 224, 224, 64
block1_pool	MaxPooling2D	None, 112, 112, 64
block2_conv1	Conv2D	None, 112, 112, 128
block2_conv2	Conv2D	None, 112, 112, 128
block2_pool	MaxPooling2D	None, 56, 56, 128
block3_conv1	Conv2D	None, 56, 56, 256
block3_conv2	Conv2D	None, 56, 56, 256
block3_conv3	Conv2D	None, 56, 56, 256
block3_pool	MaxPooling2D	None, 28, 28, 256

block4_conv1	Conv2D	None, 28, 28, 512
block4_conv2	Conv2D	None, 28, 28, 512
block4_conv3	Conv2D	None, 28, 28, 512
block4_pool	MaxPooling2D	None, 14, 14, 512
block5_conv1	Conv2D	None, 14, 14, 512
block5_conv2	Conv2D	None, 14, 14, 512
block5_conv3	Conv2D	None, 14, 14, 512
block5_pool	MaxPooling2D	None, 7, 7, 512
batch_normalization	BatchNormalization	None, 7, 7, 512
flatten	Flatten	None, 25088
fully_connected_layer	Dense	None, 2048
fully_connected_layer_1	Dense	None, 256
dropout	Dropout	None, 256
fully_connected_layer_2	Dense	None, 7

2.1.16. GOOGLE COLABORATORY (COLAB)

Google Colab *environment* dari Google yang digunakan untuk menjalankan program. Colab adalah salah satu produk dari Google yang berbasis cloud dan dijalankan melalui browser. Colab menyediakan processor dengan spesifikasi tinggi (GPU dan TPU) dengan tujuan memudahkan para researcher menjalankan program yang membutuhkan spesifikasi tinggi secara online (Bisong, 2019). Google menyediakan GPU (*graphics processing unit*) yang bisa digunakan secara gratis dengan tipe Nvidia K80s, P4s, T4s, dan untuk versi berbayar akan mendapatkan tipe V100 dan P100s.

2.1.17. CONFUSION MATRIX

Confusion matrix merupakan suatu metode yang digunakan untuk melakukan perhitungan akurasi pada konsep *data mining* (Rosandy, 2016). *Confusion matrix* berisikan informasi mengenai hasil klasifikasi aktual dan telah di prediksi oleh sistem klasifikasi. Performa dari sistem tersebut

biasanya dievaluasi menggunakan data dalam sebuah matriks. Salah satu *Confusion-matrix* yang kerap digunakan dalam pengukuran dapat dilihat pada

Gambar 2.17

		Kejadian Sebenarnya	
		P	N
Hipotesis Kejadian	P	True Positive	False Positive
	N	False Negative	True Negative

Gambar 2.17. Confusion Matrix

(Tom, 2006)

Berdasarkan gambar di atas terdapat beberapa nilai di dalam matriks yaitu “*True Positive*” (*TP*), “*True Negative*” (*TN*), “*False Positive*” (*FP*), dan “*False Negative*” (*FN*), seluruh kemungkinan kejadian sebenarnya positif (*P*) dan seluruh kemungkinan kejadian sebenarnya negatif (*N*). Nilai tersebut dapat digunakan untuk menghitung akurasi dengan persamaan berikut :

$$Accuracy = \frac{TP + TN}{P + N} \quad (2.3)$$

Akurasi digunakan sebagai parameter sebagaimana akurat suatu model melakukan klasifikasi. Sementara untuk menghitung tingkat presisi prediksi kejadian dapat digunakan persamaan berikut :

$$Precision = \frac{TP}{TP + FP} \quad (2.4)$$

Presisi menggambarkan seberapa tepat suatu model memprediksi kejadian positif dalam serangkaian kegiatan prediksi. Perhitungan presisi biasanya bermanfaat pada pengembangan model prediksi hujan di suatu daerah. Selain presisi dan akurasi, untuk dapat melihat lebih detail lagi kinerja

suatu sistem, *recall* atau sensitivitas sistem terhadap suatu kelas juga dapat dilihat. *Recall* dapat dihitung dengan menggunakan persamaan berikut :

$$Recall = \frac{TP}{TP + FN} \quad (2.5)$$

2.2. LANDASAN PENELITIAN

1. Setiawan, (2019) dengan judul “PERBANDINGAN ARSITEKTUR CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI FUNDUS” (Setiawan, 2019).

Pada penelitian tersebut dilakukan perbandingan klasifikasi menggunakan 9 arsitektur CNN yaitu Alexnet, VGG16, VGG19, GoogLeNet, Inception-V3, ResNet50, ResNet101, IncResNetV2, dan Squeezenet. Penelitian tersebut dilakukan menggunakan data set MESSIDOR. Hasil dari penelitian tersebut didapatkan Arsitektur VGG16 menunjukkan akurasi 92,31% dengan sensitivitas 90,7% dan spesififikasi 94%.

Berdasarkan penelitian yang dilakukan oleh setiawan, maka pada penelitian ini dilakukan implementasi CNN dengan arsitektur VGG-16 pada dataset yang berbeda yaitu dataset dari klinik mata XYZ.

2. Handono et al., (2020) dengan judul “IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK (CNN) UNTUK DETEKSI RETINOPATI DIABETIK” (Handono, Anggraeny, & Rahmat, 2020).

Pada penelitian tersebut difokuskan untuk klasifikasi penyakit mata *retinopati diabetik* saja dengan menggunakan data set dari MESSIDOR yang berjumlah 900 data. Adapun arsitektur yang digunakan adalah rancangan dari penelitian tersebut dimana berisi tiga set kombinasi konvolusi yang masing – masing set akan berisikan lapisan konvolusi, ReLU, dan lapisan *pooling*. Hasil penelitian yang didapatkan kurang sesuai untuk mendeteksi *Retinopati Diabetik* karena memiliki rata – rata akurasi hasil pengujian sebesar 57,6%.

Dari penelitian yang dilakukan Handono diketahui arsitektur yang di rancangan kurang bisa mendeteksi *retinopati diabetik*. Sehingga pada

penelitian ini dilakukan menggunakan arsitektur VGG-16 yang sudah dilatih menggunakan data set ImageNet yang kemudian dilakukan *transfer learning* untuk mendeteksi penyakit mata.

3. Cahya et al., (2021) dengan judul “Klasifikasi Penyakit Mata Menggunakan *Convolutional Neural Network* (CNN)” (Cahya, Hardi, Riana, & Hadiyanti, 2021).

Pada penelitian tersebut klasifikasi dilakukan pada mata normal, *katarak*, *glaukoma* dan *retina disease*. Adapun data set yang digunakan berasal dari Jr2ngb dengan jumlah 610 yang terbagi ke 4 kelas normal, *katarak*, *glaukoma* dan *retina disease*. Adapun arsitektur yang digunakan pada penelitian ini adalah Alexnet. Pelatihan dilakukan dengan parameter epoch 150 mendapatkan hasil akurasi 98.37%.

Dari penelitian yang dilakukan oleh Cahya diketahui penelitian tersebut mendapatkan akurasi 98.37% dari menggunakan arsitektur Alexnet. Pada penelitian ini dilakukan menggunakan arsitektur VGG-16 yang sudah dilatih menggunakan data set ImageNet yang kemudian dilakukan *transfer learning*. Adapun data set yang akan digunakan berasal dari Kaggle yang berisi 7 kelas penyakit mata yang akan diklasifikasi.

4. Azizah, (2021) dengan judul “KLASIFIKASI PENYAKIT DIABETIC RETINOPATHY MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN) MODEL DEEP RESIDUAL NETWORK (RESNET)” (Azizah, 2021).

Pada penelitian tersebut difokuskan untuk klasifikasi penyakit mata *retinopati diabetik* saja dengan menggunakan data set dari MESSIDOR. Penelitian tersebut dilakukan dengan membandingkan arsitektur ResNet18, ResNet50 dan ResNet101. Dari hasil yang diperoleh, ResNet101 mendapatkan hasil terbaik dengan akurasi 90.18%, sensitivitas 87.69% dan spesifikasi 96.37%.

Dari penelitian yang dilakukan oleh Azizah diketahui penelitian tersebut mendapatkan akurasi 90.18% dari menggunakan arsitektur ResNet101. Pada penelitian ini dilakukan menggunakan arsitektur VGG-16.

Selain itu penelitian ini dilakukan identifikasi terhadap 7 penyakit mata yaitu *Age related Macular Degeneration*, *Cataract*, *Diabetes*, *Glaucoma*, *Hypertension*, *Myopia*, Normal.

5. Wiliam & Lubis, (2022) dengan judul “KLASIFIKASI PENYAKIT MATA MENGGUNAKAN CNN” (William & Lubis, 2022).

Pada penelitian tersebut dilakukan untuk mengidentifikasi 5 kelas yaitu Normal, *Retinopati Diabetik*, Glaukoma, Katarak, dan *Retinopati Hipertensi* yang berasal dari *dataset Larxel*. “*Ocular Disease Recognition*”. Dengan jumlah 2913 citra. Penelitian tersebut dilakukan dengan menggunakan arsitektur VGG16 dan mendapatkan hasil 91%.

Dari penelitian yang dilakukan oleh Wiliam & Lubis diketahui penelitian tersebut mendapatkan akurasi 91% dari menggunakan arsitektur VGG16 terhadap 5 kelas. Pada penelitian ini dilakukan menggunakan arsitektur VGG-16. Selain itu penelitian ini dilakukan identifikasi terhadap 7 penyakit mata yaitu *Age related Macular Degeneration*, *Cataract*, *Diabetes*, *Glaucoma*, *Hypertension*, *Myopia*, Normal yang berasal dari data citra *fundus*.

6. Indraswari et al., (2022) dengan judul “Deteksi Penyakit Mata Pada Citra Fundus Menggunakan Convolutional Neural Network (CNN)” (Indraswari, Herulambang, & Rokhana, 2022).

Pada penelitian tersebut dilakukan menggunakan arsitektur MobileNetV2 dengan metode *transfer learning*. Data set yang digunakan Adapun data set yang digunakan berasal dari Jr2ngb dengan jumlah 610 yang terbagi ke 4 kelas normal yang akan dikelompokkan menjadi 2 kelas yaitu normal dan tidak normal. Penelitian tersebut mendapatkan akurasi sebesar 72%, *precision* sebesar 72%, *recall* sebesar 72%, dan *F1-score* sebesar 72%.

Dari penelitian yang dilakukan oleh Indraswati diketahui penelitian tersebut mendapatkan akurasi 72% dari menggunakan arsitektur MobileNetV2. Adapun penelitian tersebut dilakukan untuk identifikasi antara mata normal dan tidak. Pada penelitian ini dilakukan menggunakan VGG-16 dengan metode *transfer learning* untuk melakukan 7 kelas penyakit mata

yaitu *Age related Macular Degeneration, Cataract, Diabetes, Glaucoma, Hypertension, Myopia, Normal*.

7. Marcella et al., (2022) dengan judul “Klasifikasi Penyakit Mata Menggunakan *Convolutional Neural Network* Dengan Arsitektur VGG-19” (Marcella, Yohannes, & Devella, 2022)

Penelitian ini mengangkat topik terkait dengan klasifikasi dengan menggunakan objek penyakit mata pada manusia. Penelitian ini menggunakan dua pilihan *optimizer* yaitu SGD dan Adagrad. Data yang digunakan sebanyak 601 citra yang terdiri dari 430 citra latih, 50 citra validasi, dan 121 citra uji dengan total 4 kelas. Metode yang digunakan pada penelitian ini adalah metode *Convolutional Neural Network* (CNN) dengan arsitektur VGG-19, dengan input berupa citra yang telah melalui proses *preprocessing* yaitu *resize* dan metode CLAHE (*Contrast Limited Adaptive Histogram Equalization*) dari citra penyakit mata. Skenario pengujian terdiri dari 8 skenario dengan *Optimizer* dan *ClipLimit* yang berbeda-beda. Hasil pengujian tertinggi didapatkan pada skenario pertama yaitu dengan menggunakan *optimizer Adagrad* dan *clipLimit* sebesar 1,0 dengan nilai *accuracy* yang didapatkan sebesar 65,29%, *precision* sebesar 66,53%, *recall* sebesar 65,29%, dan *f1-score* sebesar 65,40%.

8. Noprisson., (2022) dengan judul “Fine-Tuning Model Transfer Learning VGG-16 Untuk Klasifikasi Citra Penyakit Tanaman Padi” (Noprisson, 2022).

Penelitian ini bertujuan membuat analisis kinerja klasifikasi penyakit tanaman padi *convolution neural network* (CNN) dengan arsitektur VGG16 menggunakan *fine-tuning*. Untuk memproses dataset dan mengelompokkan data menjadi empat kelas (*brownspoty, healthy, hispa, dan leafblast*), penelitian ini menggunakan beberapa tahapan metodologi. Tahapannya antara lain data *preparation, feature extraction, training, comparing* dan *evaluating model*. Sebagai hasil, VGG16 *without fine tuning* mendapatkan akurasi 50.88% sedangkan VGG 16 *with fine tuning* mendapatkan akurasi 63.50% pada proses *traning*. Pada proses validasi, VGG16 *without fine tuning* mendapatkan akurasi 52.50% sedangkan VGG16 *with fine tuning*

mendapatkan akurasi 62.08%. Pada proses *testing*, VGG16 *without fine tuning* mendapatkan akurasi 54.19% sedangkan VGG16 *with fine tuning* mendapatkan akurasi 62.21%.

9. Agustin et al., (2020) dengan judul “Deep Learning-based Method for Multi-Class Classification of Oil Palm Planted Area on Plant Ages Using Ikonos Panchromatic Imagery” (Agustin, Tjandrasa, & Ginardi, 2020).

Penelitian ini mengusulkan sebuah metode berbasis *deep-learning convolutional neural network* untuk mengklasifikasikan perkebunan kelapa sawit di usia produktif. Citra yang digunakan dalam penelitian ini adalah citra satelit Ikonos dengan pita pankromatik saja yang memiliki spasial rasio 1m. Areal perkebunan diklasifikasikan menjadi non-kelapa sawit, areal kelapa sawit dengan umur muda, dewasa, dan tua. Penelitian ini mengusulkan metode klasifikasi multi-kelas untuk perkebunan kelapa sawit berdasarkan umur tanaman menggunakan *convolutional neural network* (CNN). Studi ini melakukan perbandingan pada tiga model arsitektur CNN yaitu AlexNet, VGG16, dan VGG19. Dari tiga model tersebut dibuat dua *fine-tune* sehingga penelitian ini membandingkan AlexNet *fine tune* 1, AlexNet *fine tune* 2 VGG16 *fine tune* 1, VGG16 *fine tune* 2, VGG19 *fine tune* 1, dan VGG19 *fine tune* 2. Akurasi tertinggi diperoleh dengan menggunakan mesin klasifikasi CNN model VGG19 *fine-tune* 2 dari yang diusulkan, yaitu sebesar 94,74%.

10. Tanuwijaya et al., (2021) dengan judul “Modifikasi Arsitektur VGG16 untuk Klasifikasi Citra Digital Rempah-rempah Indonesia” (Tanuwijaya & Roseanne, 2021).

Penelitian ini membuat sebuah model klasifikasi dengan menggunakan *convolution neural network* dengan arsitektur VGG 16 yang dimodifikasi. Arsitektur modifikasi VGG 16 memiliki 10-layer yang terdiri dari 7-layer convolution dan 3- layer fully connected. Untuk fase latih model modifikasi VGG 16 ini menggunakan datasets rempah yang disediakan oleh Kaggle. Validasi model yang digunakan adalah akurasi, *loss*, *precision*, dan *recall* untuk membandingkan model mana yang memiliki nilai yang terbaik. Untuk model modifikasi VGG 16 yang dibuat untuk melakukan klasifikasi,

mendapatkan hasil evaluasi rata-rata akurasi sebesar 81%, nilai recall sebesar 76%, dan nilai precision sebesar 81% untuk fase training dan untuk fase validasi, akurasi sebesar 85%, nilai recall sebesar 80%, dan nilai precision sebesar 84%. Jadi dengan model modifikasi VGG 16 dapat disimpulkan bahwa model mampu memprediksi rempah-rempah lebih baik dari model Alexnet.

