

BAB II: TINJAUAN PUSTAKA DAN LANDASAN TEORI

2.1. Tinjauan Pustaka

Penelitian ini dikembangkan dengan tujuan untuk menerapkan model *transfer learning* dalam algoritma *Convolutional Neural Network* untuk mendeteksi penyakit tanaman padi melalui citra daun. Dalam penelitian terdahulu mengenai *image processing* menunjukkan bahwa metode *Convolutional Neural Network* dapat digunakan sebagai metode yang cocok untuk pengklasifikasian gambar. Hasil dari penelitian terdahulu yang telah dilakukan oleh peneliti lain menjadi bahan referensi dari penelitian ini.

Salah satu penelitian terkait pada tahun 2019 yang berjudul “Deteksi Manusia menggunakan Pre-Trained MobileNet untuk Segmentasi Citra Menentukan Bentuk Tubuh” yang ditulis oleh Irma Amelia Dewi dan Farhan Rafiqi. Tujuan dari penelitian tersebut adalah untuk mengetahui rekomendasi pakaian berdasarkan bentuk badannya sehingga pakaian yang digunakan nyaman dan dapat mengekspresikan diri pemakai. Berdasarkan hasil penelitian tersebut diperoleh akurasi deteksi manusia sebesar 97,00% oleh sumber data online dan hasil foto langsung, 82,0% dari Human Detection Database, dan 98,0% dari CrowdHuman. Sistem memiliki jarak optimal pada objek 2 meter dengan ketinggian kamera 0,75 meter yang berdasarkan rata-rata akurasi terbesar sebesar 96,06% dan akurasi hasil deteksi bentuk badan sebesar 82% dari pengujian sebanyak 11 partisipan [27].

Penelitian selanjutnya pada tahun 2020 yang berjudul “*Rice Leaf Diseases Classification Using CNN With Transfer learning*” yang ditulis oleh Shreya Dhosal dan Kamal Sarkar. Tujuan dari penelitian tersebut adalah membuat sistem otomatis dimana petani dapat mengunggah gambar daun berpenyakit untuk mengidentifikasi penyakit pada daun padi yang diunggah. Berdasarkan hasil dari penelitian tersebut dengan menggunakan fine-tuning VGGNet dengan 1509 data pelatihan gambar daun padi dan data pengujian sejumlah 647 gambar menghasilkan akurasi 92,46% [28].

Penelitian selanjutnya pada tahun 2020 yang berjudul “Identifikasi Jenis Kayu menggunakan *Convolutional Neural Network* dengan Arsitektur MobileNet” yang ditulis oleh Hendriyana dan Yazid Hilman Maulana. Tujuan dari penelitian tersebut adalah untuk mengidentifikasi kayu untuk mendapatkan informasi mengenai jenis kayu sehingga dapat menentukan kualitas dan kegunaan kayu tersebut. Berdasarkan hasil dari penelitian tersebut Arsitektur MobileNet pada penelitian ini menghasilkan akurasi *Training* dan *Testing* dalam melakukan identifikasi jenis kayu sebesar 98 % *Training* dan 93,3 % untuk *Testing*, selain itu untuk recall dan presisinya arsitektur MobileNet menghasilkan persentase sebesar 28% untuk recall dan 93% untuk precision nya. Hasil dari pendeteksian jenis kayu dengan metode *Convolutional Neural Network* serta arsitektur MobileNet dapat dinilai bekerja dengan baik [23].

Penelitian selanjutnya pada tahun 2021, yaitu berjudul “*Identification of rice plant diseases using lightweight attention networks*” yang ditulis oleh Junde Chen, Defu Zhang, Adnan Zeb, dan Yaser A. Nanehkaran. Tujuan dari penelitian tersebut adalah untuk mentransfer pengetahuan umum MobileNet V2 yang telah dilatih sebelumnya di ImageNet, dan memasukkannya ke dalam model yang telah dilatih sebelumnya untuk membuat jaringan baru yaitu Mobile-Atten untuk identifikasi tanaman padi penyakit. Berdasarkan hasil penelitian tersebut arsitektur jaringan baru yang disebut Mobile-Atten, yang memiliki ukuran model kecil dan akurasi yang relatif tinggi, untuk melakukan identifikasi jenis penyakit padi. MobileNet V2 dipilih sebagai model tulang punggung dalam metode [29].

Penelitian selanjutnya pada tahun 2021, yaitu berjudul “Penerapan Algoritma *Convolutional Neural Network* Dan Arsitektur MobileNet Pada Aplikasi Deteksi Penyakit Daun Padi” yang ditulis oleh Rizal Amegia Saputra, Sri Wasyianti, Adi Supriyatna dan Dede Firmansyah Saefudin. Tujuan dari penelitian tersebut adalah untuk klasifikasi penyakit daun padi berdasarkan citra menggunakan algoritma CNN dengan arsitektur MobileNet dan ekstraksi fitur. Berdasarkan hasil penelitian tersebut klasifikasi gambar jenis penyakit daun padi menggunakan algoritma CNN dengan arsitektur MobileNet dan Feature Extraction memiliki akurasi yang baik sekali yaitu sebesar 92%, namun karena data yang digunakan cukup kecil

menghasilkan nilai validasi kesalahan tinggi dibanding nilai kesalahan pada proses pelatihan [30].

Penelitian selanjutnya pada tahun 2021, yaitu berjudul “Implementasi *Transfer learning* pada Algoritma *Convolutional Neural Network* Untuk Identifikasi Penyakit Daun Kentang” yang ditulis oleh Abdul Jalil Rozaqi, Andi Sunyoto, dan Muhammad Rudyanto Arief. Tujuan dari penelitian tersebut adalah untuk melakukan perbandingan metode *transfer learning* VGG16, Inception-V3 dan ResNet-50 untuk mencari metode yang terbaik. Berdasarkan hasil penelitian tersebut metode *Transfer learning* VGG-16 memiliki hasil performa klasifikasi yang terbaik dan menghasilkan nilai akurasi tertinggi sebesar 95% [20].

Penelitian selanjutnya pada tahun 2021, yaitu berjudul “Klasifikasi Kualitas Buah Salak dengan *Transfer learning* Arsitektur VGG16” yang ditulis oleh Rismiyati dan Ardytha Luthfiarta. Tujuan dari penelitian tersebut adalah untuk membedakan kualitas buah salak yang diklasifikasikan menjadi dua kelas, kelas bagus dan jelek dengan machine learning. Berdasarkan hasil penelitian tersebut akurasi tertinggi yang diperoleh dari penelitian tersebut adalah 95,83%. Akurasi ini diperoleh dengan menggunakan learning rate = 0,0001 dan momentum 0,9. Presisi dan perolehan model ini adalah 97,2 dan 94,6 [31].

Penelitian selanjutnya pada tahun 2021, yaitu berjudul “Deteksi Penyakit Pada Daun Tanaman Padi Menggunakan Metode *Convolutional Neural Network*” yang ditulis oleh Syaikhul Anam Alidrus, Musthafa Aziz, dan Oddy Virgantara Putra. Tujuan dari penelitian ini adalah membangun model untuk melakukan identifikasi dan klasifikasi jenis penyakit yang diderita oleh daun tanaman padi. Berdasarkan hasil penelitian tersebut klasifikasi jenis penyakit daun tanaman padi dengan menggunakan metode algoritma *Convolutional Neural Network* (CNN) menghasilkan akurasi yang cukup baik. Dengan memperoleh rata-rata akurasi mencapai 92% pada data latih dan 77% pada data validasi. Tingkat akurasi dapat dipengaruhi oleh penggunaan arsitektur dan hyper-parameter yang diterapkan [32].

Penelitian selanjutnya pada tahun 2022, yaitu berjudul “Klasifikasi Penyakit Daun Padi Menggunakan *Convolutional Neural Network*” yang ditulis oleh Mohtar Khoiruddin, Apri Junaidi, dan Wahyu Andi Saputra. Tujuan dari penelitian ini adalah untuk membantu mengedukasi para petani dalam mengatasi penyakit daun tanaman padi. Berdasarkan hasil penelitian tersebut Hasil akurasi training terbaik ada di epoch 100 dengan akurasi 98% dan dilakukan testing menggunakan confusion matrix dengan 600 data mendapatkan nilai akurasi sebesar 98% dalam melakukan klasifikasi penyakit daun padi [33].

Berdasarkan pemaparan penelitian di atas, ringkasan penelitian yang relevan ditunjukkan pada tabel 2.1 dibawah ini:

Tabel 2.1 Tabel penelitian sebelumnya

No.	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
1.	<p>Deteksi Manusia menggunakan Pre-Trained MobileNet untuk Segmentasi Citra Menentukan Bentuk Tubuh [27]. (2019)</p> <p>(Irma Amalia Dewi dan Farhan Rafiqi)</p>	<p>Pada Penelitian ini dilakukan pengenalan objek pada citra dengan memproses pixel citra sehingga output yang dihasilkan adalah pixel yang sudah terdapat kode pixel hasil deteksi menggunakan metode CNN dengan arsitektur MobileNet</p>	<p>Penelitian ini dilakukan untuk dapat menentukan fashion style yang sesuai dengan bentuk tubuh/postur tubuh yang diperoleh dari perhitungan mengukur tubuh menggunakan kamera</p>	<p>Tidak dilakukan augmentasi untuk memperbanyak data.</p>	<p>Penelitian dilakukan dengan menggunakan metode CNN pada arsitektur MobileNet. Data yang digunakan adalah sebanyak 200 citra yang bersumber dari online, pengambilan foto langsung, dataset Human Detection Database Kaggle, dan CrowdHuman. Alur Penelitian dimulai dengan masuknya input citra. Alur selanjutnya adalah pemotongan batas atas dan bawah objek manusia, perhitungan panjang bagian bahu, pinggang dan pinggul. Kemudian dilakukan klasifikasi berdasarkan panjang bahu, pinggang dan pinggul. Output pada penelitian ini berupa jenis bentuk tubuh dan rekomendasi baju sesuai dengan bentuk tubuh.</p>	<p>Hasil penelitian tersebut diperoleh hasil Sistem memiliki jarak optimal pada objek 2 meter dengan ketinggian kamera 0,75 meter yang berdasarkan rata-rata akurasi terbesar sebesar 96,06% dan akurasi hasil deteksi bentuk badan sebesar 82% dari pengujian sebanyak 11 partisipan.</p>

No.	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
2.	Rice Leaf Diseases Classification Using CNN With <i>Transfer learning</i> [28] (2020) (Shreya Ghosal dan Kamal Sarkar)	Pada penelitian ini dilakukan pembangunan sistem otomatis untuk mendeteksi penyakit pada daun padi. Metode <i>transfer learning</i> CNN arsitektur VGG dipilih sebagai arsitektur pembangun sistem otomatis.	Penelitian ini dilakukan untuk menghasilkan sistem otomatis dimana para petani dapat mengunggah gambar daun yang sakit dan mempostingnya ke server dimana jaringan saraf akan digunakan untuk mengidentifikasi penyakit. Sistem akan melakukan klasifikasi dan memberikan rekomendasi obat yang sesuai dengan penyakit.	Model CNN traditional yang menjadi pembanding tidak dijalankan menggunakan ukuran <i>epoch</i> yang sama.	Penelitian ini dilakukan dengan menggunakan metode <i>transfer learning</i> arsitektur VGG. Jumlah data yang digunakan adalah 1509 data pelatihan diikuti oleh 647 data uji. Gambar yang dikumpulkan diubah ukurannya menjadi 224x224 piksel dan sejumlah teknik augmentasi seperti zoom, rotasi, pergeseran horizontal dan vertikal diterapkan menggunakan ImageDataGenerator. Kemudian data dibagi menjadi data latih dan data uji dengan persentase 70% data training dan 30% data testing. Kemudian dilakukan training, testing dan evaluasi.	Hasil dari penelitian ini adalah model yang dibentuk dapat mengklasifikasikan 92,46% dari gambar uji dengan benar. Transfer Learning menggunakan fine-tuning VGGNet yang telah ditentukan sebelumnya telah sangat meningkatkan kinerja model. Jumlah epoch yang digunakan dihentikan pada 25.
3.	Identifikasi Jenis Kayu menggunakan <i>Convolutional Neural Network</i>	Penelitian ini akan menerapkan metode Convolutional Neural Network dengan arsitektur	Penelitian ini dilakukan untuk mengenali jenis kayu karena keakuratan dalam	Tidak dilakukan augmentasi untuk memperbanyak data.	Pada penelitian ini dilakukan dengan menggunakan metode <i>Convolutional Neural Network</i> dengan arsitektur MobileNets.	Hasil dari penelitian tersebut adalah metode CNN serta arsitektur MobileNet dapat dinilai bekerja dengan baik

No.	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
	dengan Arsitektur MobileNet [23] (2020) (Hendriyana dan Yazid Hilman Maulana)	MobileNets untuk mengenali jenis jenis kayu yang berfokus terhadap seberapa efisiennya arsitektur MobileNets pada domain identifikasi jenis kayu.	mengidentifikasi jenis kayu sangat berpengaruh dalam menentukan fungsinya.		Dataset yang digunakan sebanyak 1000 citra untuk 10 jenis kayu pada tiap jenis diambil 90 citra untuk training dataset dan 10 citra untuk validasi dataset yang diambil dengan menggunakan gawai. Kemudian data yang masuk di <i>training, testing</i> dan evaluasi menggunakan <i>Confusion matrix</i> .	dalam mendeteksi jenis kayu. Arsitektur MobileNet pada penelitian ini menghasilkan akurasi <i>Training</i> dan <i>Testing</i> dalam melakukan identifikasi jenis kayu sebesar 98 % <i>Training</i> dan 93,3 % untuk <i>Testing</i>
4.	<i>Identification of rice plant diseases using lightweight attention networks</i> [29] (2021) (Junde Chen , Defu Zhang , Adnan Zeb, dan Yaser A. Nanehkaran)	Penelitian ini menerapkan Metode Mobile-Atten Network dengan MobileNet V2 sebagai arsitektur dasarnya untuk membangun suatu sistem yang sederhana, cepat, lebih murah, dan akurat untuk mengidentifikasi penyakit tanaman padi secara otomatis.	Penelitian ini dilakukan untuk mengidentifikasi penyakit padi yang selanjutnya akan diimplementasikan dalam sebuah sistem.	Tidak menyebutkan jumlah dataset yang digunakan untuk testing pada dataset lokal maupun publik.	Pada penelitian ini dilakukan dengan menggunakan metode arsitektur jaringan baru yang disebut Mobile-Atten, yang memiliki ukuran model kecil dan relatif akurasi tinggi, untuk melakukan identifikasi jenis penyakit padi. Eksperimen dibagi menjadi dua, pertama eksperimen dilakukan menggunakan dataset <i>public dataset</i> yaitu dengan menggunakan Plant Village	Hasil dari penelitian tersebut menunjukkan kelayakan dan validitas prosedur yang diusulkan, dan berhasil dilakukan untuk mengidentifikasi untuk 12 kelas penyakit tanaman padi yang digunakan dengan identifikasi akurasi mencapai 98.48%.

No.	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
					repository yang diambil 20% atau 10.861 gambar untuk memvalidasi keefektifan model. Kedua, eksperimen dilakukan dengan menggunakan dataset lokal dengan jumlah data training sebanyak 200 citra. Selanjutnya masing-masing eksperimen dilakukan evaluasi.	
5.	<p>Penerapan Algoritma <i>Convolutional Neural Network</i> Dan Arsitektur MobileNet Pada Aplikasi Deteksi Penyakit Daun Padi [30] (2021)</p> <p>(Rizal Amegia Saputra, Sri Wasyianti, Adi</p>	<p>Pada penelitian ini menerapkan Algoritma CNN dan arsitektur MobileNet dengan feature extraction dan feature map untuk membangun sebuah aplikasi yang dapat digunakan untuk mengklasifikasi jenis penyakit pada daun padi.</p>	<p>Penelitian ini dilakukan untuk mengklasifikasikan penyakit padi yang selanjutnya akan diimplementasikan dalam bentuk aplikasi android.</p>	<p>Tidak dilakukan augmentasi untuk memperbanyak data, karena dataset yang digunakan hanya 120 data citra.</p>	<p>Pada penelitian ini dilakukan dengan menggunakan metode CNN pada arsitektur MobileNet dengan feature extraction dan feature map. Dataset yang digunakan pada penelitian ini adalah dataset yang bersumber dari UCI Repository yaitu Rice Leaf Diseases Data Set yang memiliki 3 kelas penyakit dengan masing-masing kelas terdiri dari 40 citra data. Data yang terkumpul di training menggunakan 100 epoch dan kemudian di validasi</p>	<p>Hasil dari penelitian tersebut adalah Klasifikasi gambar jenis penyakit daun padi menggunakan algoritma CNN dengan arsitektur MobileNet dan Feature Extraction memiliki akurasi yang baik sekali yaitu sebesar 92%. Percobaan pada aplikasi yang dibangun juga mendapatkan hasil proses pengujian terbukti</p>

No.	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
	Supriyatna, dan Dede Firmansyah Saefudin)				menggunakan Confusion matrix. Data yang telah di validasi kemudian diimplementasikan ke dalam bentuk aplikasi android untuk mendeteksi penyakit daun padi.	dapat mengklasifikasikan jenis penyakit daun padi.
6.	Implementasi <i>Transfer learning</i> pada Algoritma <i>Convolutional Neural Network</i> Untuk Identifikasi Penyakit Daun Kentang [20] (2021) (Abdul Jalil Rozaqi, Andi Sunyoto, dan Muhammad Rudyanto Arief)	Pada Penelitian ini membandingkan model CNN sederhana dan transfer learning VGG-16, Inception-V3 dan ResNet-50 untuk klasifikasi penyakit pada daun kentang	Penelitian ini dilakukan untuk klasifikasi penyakit pada daun kentang dengan menggunakan arsitektur <i>Convolutional Neural Network</i> (CNN).	Ukuran input data yang digunakan terlalu kecil yaitu 150x150 px.	Pada penelitian ini dilakukan perbandingan beberapa model, yaitu model CNN sederhana, model transfer learning VGG-16, Inception-V3 dan ResNet-50. Dataset yang digunakan pada penelitian ini adalah dataset kaggle Plantvillage, dengan jumlah data yang diambil sebanyak 450 data yang terdiri dari 3 kelas data citra. Data yang terkumpul dimasukan ke dalam preprocessing data, ukurannya disamakan menjadi 150x150 px. Kemudian data dibagi menjadi 80:10:10. Data yang telah	Hasil dari penelitian tersebut dibagi menjadi dua hasil. Klasifikasi menggunakan arsitektur CNN yang sederhana menghasilkan performa model klasifikasi yang <i>overfitting</i> . Hasil percobaan klasifikasi menggunakan metode <i>transfer learning</i> menghasilkan model VGG-16 sebagai model dengan hasil yang paling baik, dibuktikan dengan performa model yang stabil dan

No.	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
					dibagi di training menggunakan 4 metode yaitu CNN sederhana, VGG-16, Inception-V3 dan ResNet-50. Kemudian di evaluasi menggunakan <i>Confusion matrix</i> .	akurasi yang paling tinggi dengan jumlah 95%.
7.	Klasifikasi Kualitas Buah Salak dengan <i>Transfer learning</i> Arsitektur VGG16 [31] (2021) (Rismiyati dan Ardytha Luthfiarta)	Penelitian ini menggunakan metode <i>transfer learning</i> arsitektur VGG untuk mengkalsifikasikan buah salak berdasarkan kualitasnya.	Penelitian ini bertujuan untuk membedakan kualitas buah salak dengan machine learning. Salak diklasifikasikan menjadi dua kelas, kelas bagus dan jelek	Tidak dilakukan augmentasi untuk memperbanyak data.	Penelitian ini menggunakan metode <i>transfer learning</i> arsitektur VGG. Data set yang digunakan diambil dari dataset penelitian sebelumnya sejumlah 370 citra yang terdiri dari 190 citra dari kelas bagus, dan 180 citra dari kelas jelek. Dataset yang terkumpul masuk ke tahap preprocessing, ukuran cita diubah menjadi 224x224x3. Kemudian data di training menggunakan arsitektur VGG16 menggunakan 2 skenario momentum yaitu 0 dan 0.9. Kemudian terakhir masuk ke dalam evaluasi model.	Hasil dari penelitian tersebut adalah arsitektur VGG mendapat akurasi tertinggi sebesar 95,83% dengan menggunakan learning rate =0,0001 dan momentum=0,9.

No.	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
8.	<p>Deteksi Penyakit Pada Daun Tanaman Padi Menggunakan Metode Convolutional Neural Network [32] (2021)</p> <p>(Syaikhul Anam Alidrus, Musthafa Aziz, dan Oddy Virgantara Putra)</p>	<p>Penelitian ini dilakukan untuk menerapkan metode algoritma <i>Convolutional Neural Network (CNN)</i> dalam membangun model untuk melakukan identifikasi dan klasifikasi jenis penyakit yang diderita oleh daun tanaman padi.</p>	<p>Penelitian ini dilakukan untuk membangun model untuk melakukan identifikasi dan klasifikasi jenis penyakit yang diderita oleh daun tanaman padi.</p>	<p>Tidak dilakukan testing pada penelitian ini, data hanya di-<i>training</i> dan dilakukan validasi saja.</p>	<p>Penelitian ini menggunakan metode <i>Convolutional Neural Network (CNN)</i>. Data yang digunakan pada penelitian ini berjumlah 900 sample citra yang terbagi menjadi 3 kelas penyakit. Kemudian data dibagi menjadi 720 data training dan 180 data validasi. Kemudian data ditraining menggunakan 50 epoch.</p>	<p>Klasifikasi jenis penyakit daun tanaman padi dengan menggunakan metode algoritma Convolutional Neural Network (CNN) menghasilkan akurasi yang cukup baik. Dengan memperoleh rata-rata akurasi mencapai 92% pada data latih dan 77% pada data validasi. Tingkat akurasi dapat dipengaruhi oleh penggunaan arsitektur dan hyper-parameter yang diterapkan.</p>
9.	<p>Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network [33] (2022)</p>	<p>Penelitian ini menerapkan metode Convolutional Neural Network (CNN) untuk melakukan klasifikasi penyakit pada daun tanaman padi.</p>	<p>Penelitian ini bertujuan untuk membantu mengedukasi para petani dalam mengatasi penyakit daun tanaman padi.</p>	<p>Dataset yang digunakan hanya dataset daun padi yang terkena penyakit, tidak ada dataset sehat. Jika</p>	<p>Penelitian ini menggunakan metode Convolutional Neural Network (CNN). Dataset yang digunakan berasal dari kaggle dengan jumlah 240 data yang terdiri dari 3 kelas penyakit. Data yang telah</p>	<p>Hasil akurasi training terbaik ada di epoch 100 dengan akurasi 98% dan dilakukan testing menggunakan confusion matrix dengan 600 data mendapatkan nilai</p>

No.	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
	(Mohtar Khoiruddin, Apri Junaidi, dan Wahyu Andi Saputra)			dilakukan untuk deteksi, semua dapat terdeteksi berpenyakit meskipun daun itu sehat.	terkumpul disamakan ukurannya menjadi 224x224, kemudian data diaugmentasi dan menghasilkan data sejumlah 6000 data. Kemudian data dibagi menjadi 80:10:10. Kemudian data di training menggunakan 4 skenario epoch yaitu 25, 50, 75, dan 100 epoch. Kemudian dilakukan evaluasi data.	akurasi sebesar 98% dalam melakukan klasifikasi penyakit daun padi.

Berdasarkan penelitian terdahulu yang telah dijabarkan di atas, dapat disimpulkan bahwa pemilihan metode MobileNet menghasilkan hasil dan akurasi yang lebih baik dibandingkan dengan metode *transfer learning* lain. Peneliti menjadikan jurnal 1, 3, 4 dan 5 menjadi acuan dalam pelaksanaan penelitian implentasi *transfer learning* dengan arsitektur MobileNet V2 pada algoritma *convolutional neural network* untuk identifikasi penyakit pada daun padi.

2.2. Landasan Teori

2.2.1. Computer Vision

Computer vision atau visi komputer merupakan salah satu teknologi dalam kecerdasan buatan. Menurut Shapiro dan Stockman (2001), *Computer vision* merupakan bidang yang bertujuan membuat keputusan mengenai keadaan dan objek fisik nyata berdasarkan sebuah citra. *Computer vision* juga dapat diartikan sebagai kombinasi antara pengolahan citra dan pengenalan pola [34]. Menurut Milan Sonka, Vaclav Hlavac and Roger Boyle (2008) 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 ke dalam benda elektronik sehingga benda elektronik dapat memahami dan mengerti arti dari gambar yang dimasukkan [35].

Pemahaman gambar pada komputer ini dilakukan dengan menguraikan informasi simbolis dari data gambar dengan menggunakan model yang dibangun dengan bantuan geometri, fisika, statistika, dan teori serta metode-metode lainnya [36]. Visi komputer juga dideskripsikan sebagai suatu teknologi untuk mengotomatisasi dan mengintegrasikan berbagai proses dan representasi untuk menghasilkan persepsi penglihatan [37].

2.2.2. Pengolahan Citra

Pengolahan citra atau *image processing* merupakan bagian dari computer vision. Menurut Efford (2000), pengolahan citra merupakan istilah yang digunakan untuk berbagai teknik yang digunakan untuk memanipulasi dan memodifikasi citra dengan berbagai macam cara. Foto merupakan salah satu contoh gambar dua dimensi yang dapat diolah dengan mudah. Setiap foto yang berbentuk citra digital dapat diolah menggunakan software tertentu [38].

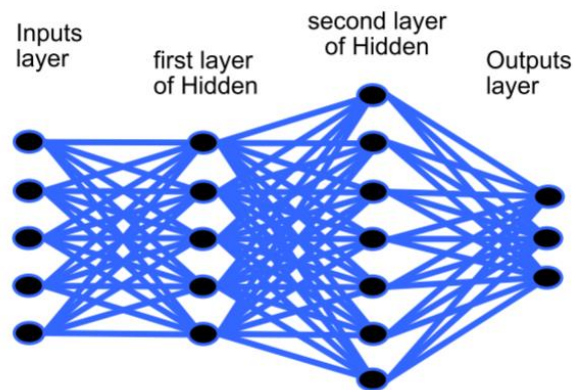
Pengolahan citra merupakan bagian penting yang mendasari berbagai aplikasi nyata, seperti pengenalan pola, penginderaan jarak jauh melalui satelit atau pesawat

udara, dan machine vision. Pada pengenalan pola, pengolahan citra antara lain berperan memisahkan objek dari latar belakang secara otomatis. Selanjutnya, objek akan diproses oleh pengklasifikasi pola. Sebagai contoh, sebuah objek buah dapat dikenali sebagai jeruk, apel, atau pepaya. Pada penginderaan jarak jauh, tekstur atau warna pada citra dapat dipakai untuk mengidentifikasi objek-objek yang terdapat di dalam citra. Pada *machine vision* (sistem yang dapat melihat" dan "memahami" yang dilihatnya), pengolahan citra berperan untuk mengenali bentuk-bentuk khusus yang dilihat oleh mesin. Penggunaan kamera pemantau ruangan merupakan contoh bagian aplikasi pemrosesan citra. Perubahan gerakan yang ditangkap melalui citra dapat menjadi dasar untuk melakukan pelaporan situasi yang terekam [39].

2.2.3. *Deep Learning*

Deep Learning merupakan salah satu sub dari pembelajaran machine yang terdiri dari pemodelan abstraksi tingkat tinggi untuk data yang menggunakan sekumpulan fungsi transformasi non linier yang disusun berlapis-lapis dan mendalam [40]. Lewat sebuah jaringan saraf yang disebut deep belief nets, Geoffrey Hinton merupakan orang pertama yang memperkenalkan *Deep Learning* pada tahun 2006. Seiring berkembangnya GPU atau graphics processing unit pada tahun 2009 ditemukan implementasi *Deep Learning* yang lebih praktis menggunakan GPU, perkembangan *Deep Learning* menjadi semakin cepat. Graphics processing unit merupakan sebuah prosesor atau otak komputer yang khusus digunakan untuk pengolahan grafis yang banyak digunakan pada aplikasi-aplikasi games. Dibandingkan menggunakan proses secara sekuensial menggunakan processor CPU, proses pembelajaran *Deep Learning* jauh lebih cepat prosesnya jika dilakukan secara paralel menggunakan GPU [41].

Deep Learning memiliki keunggulan sangat baik diterapkan di *reinforcement, supervised, unsupervised* dan *semi-supervised learning* dalam berbagai aplikasi pengenalan teks, citra, suara dan sebagainya. Jaringan saraf tiruan/neural network adalah pembangun dasar model pada deep learning. Jika suatu jaringan memiliki lebih dari 3 layer, maka jaringan tersebut termasuk Deep Network seperti yang tampak pada gambar 2.1 [40].



Gambar 2.1 Ilustrasi arsitektur pada deep learning[38].

Banyaknya *hidden layers* lebih penting dibanding lebar jaringan menjadikan *Deep Learning* menjadi penting. Pada permasalahan praktis, seringkali dibutuhkan banyak *hidden layer* agar input dapat menjadi output. Setiap *hidden layer* merepresentasikan input menjadi suatu representasi. Dengan arti lain, antara satu dengan yang lainnya dalam *hidden layer* mempelajari bentuk karakteristik input yang berbeda [42].

Berdasarkan teknik pembelajarannya, *Deep Learning* dapat dikelompokkan menjadi empat yaitu:

2.2.3.1. *Deep unsupervised learning (DUL)*

Teknik pembelajaran *deep unsupervised learning*, pada prosesnya sekumpulan data yang menjadi input dimodelkan secara otomatis tanpa ada panduan. Maksudnya, data-data yang dipelajari hanya berupa input yang belum diberikan label kelas. Teknik pembelajaran *deep unsupervised learning* ini cocok dan biasa digunakan dalam masalah *clustering* data. *Clustering* merupakan proses pengelompokan sebuah himpunan data input ke dalam sejumlah klaster berdasarkan kriteria tertentu, misalnya tingkat kemiripan dalam suatu kelas. Contoh model *Deep Learning* yang termasuk ke dalam *deep unsupervised learning* adalah: *Autoencoders (AE)*, *Restricted Boltzmann Machines (RBM)*, *Deep Belief Network (DBN)*, *Generative Adversarial Networks (GAN)*, *Recurrent Neural Networks (RNN)*, *Long ShortTerm Memory (LSTM)*, dan *Gated Recurrent Units (GRU)* [41].

2.2.3.2. *Deep Supervised Learning (DSL)*

Teknik pembelajaran deep supervised learning dalam prosesnya menggunakan fungsi yang memetakan data input dengan sejumlah atribut dibangkitkan berdasarkan data berlabel yang diberikan. Data *Training* atau data latih sangat berpengaruh dalam menentukan kualitas hasil pembelajaran. Teknik pembelajaran deep supervised learning ini cocok dan biasa digunakan untuk menyelesaikan masalah klasifikasi dan regresi. Contoh model *Deep Learning* yang termasuk ke dalam *deep supervised learning* adalah: *Deep Neural Networks (DNN)*, *Convolutional Neural Network (CNN)*, *Recurrent Neural Networks (RNN)*, *Long Short Term Memory (LSTM)*, *Gated Recurrent Units (GRU)*, *Restricted Boltzmann Machines (RBM)*, dan *Recursive Neural Tensor Network (RNTN)* [41].

2.2.3.3. *Deep Semi Supervised Learning (DSSL)*

Teknik pembelajaran deep semi supervised learning, menggunakan sampel inputan yang sebagian sudah berlabel dan sebagian lainnya tidak berlabel. Pendekatan jenis ini suatu fungsi atau pengklasifikasi yang tepat dibangkitkan berdasarkan semua sampel input yang diberikan. Contoh model deep semi supervised learning yaitu, *Deep Reinforcement Learning (DRL)*, *Generative Adversarial Networks (GAN)*, *Recurrent Neural Networks (RNN)*, *Long Short Term Memory (LSTM)*, dan *Gated Recurrent Units (GRU)* [41].

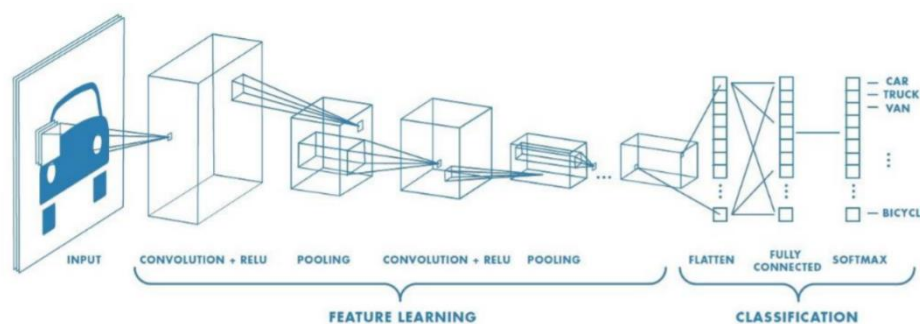
2.2.3.4. *Deep Reinforcement Learning (DRL)*

Teknik pembelajaran *deep reinforcement learning* ini mempelajari suatu kebijakan bagaimana melakukan aksi berdasarkan hasil pengamatan terhadap lingkungan yang ada. Setiap aksi menghasilkan akibat bagi lingkungan tersebut, dan lingkungan memberikan umpan balik (*feedback*) untuk memandu DRL [41].

2.2.4. Convolutional Neural Network

Convolutional neural network atau CNN merupakan metode dalam *Deep Learning* yang telah terbukti mampu secara efisien menangkap representasi bermakna dari kalimat termasuk dalam kasus klasifikasi dan pemodelan bahasa dan

citra [43]. CNN tercipta karena terinspirasi dengan sistem saraf biologis dimana didalamnya tersusun operasi konvolusi yang menggabungkan lapisan-lapisan pemrosesan dengan menggunakan beberapa elemen yang beroperasi secara paralel [44]. Proses pembelajaran di CNN dilakukan melalui skema *Training loop*, dimana pada satu *Training loop* yang memproses seluruh dataset merupakan satu *epoch*. *Convolutional Neural network* dibagi menjadi 2 bagian utama, yaitu fitur *fully connected layer* dan *fitur extraction layer*, yang terlihat seperti pada gambar berikut [45].



Gambar 2.2 Arsitektur Convolutional Neural Network [42].

Tahap pertama dalam arsitektur *Convolutional Neural Network* adalah tahap konvolusi. Tahap konvolusi dilakukan menggunakan kernel dengan ukuran tertentu, tergantung dari jumlah fitur yang dihasilkan. Setelah tahap konvolusi, tahap berikutnya adalah fungsi aktivasi dengan menggunakan aktivasi ReLU. Kemudian terakhir masuk ke proses pooling. Proses tersebut diulangi hingga didapatkan peta fitur yang cukup untuk dilanjutkan ke klasifikasi [46]. Secara umum arsitektur CNN terdiri dari beberapa *layers*, berikut merupakan penjelasannya:

2.2.4.1. *Input Layer*

Input layer mewakili gambar citra masukan. Anggap citra citra masukan berukuran 224×224 px dan berjenis RGB (*Red, Green, Blue*), maka citra inputan ini berupa array multidimensi dengan ukuran $224 \times 224 \times 3$ dengan 3 merupakan jumlah channel yaitu *red, green* dan *blue* [47].

2.2.4.2. *Convolutional Layer*

Convolutional layer atau lapisan konvolusi merupakan pondasi utama untuk membangun CNN. Lapisan konvolusi pada dasarnya digunakan untuk mendeteksi keberadaan fitur dalam citra (tepi, lekukan, tekstur, dll). Sebagai bahan untuk melakukan pengenalan citra, perlu untuk mempertimbangkan berbagai jenis fitur dalam kombinasi satu sama lain sehingga satu lapisan konvolusi biasanya berisi banyak peta fitur yang berbeda [48].

2.2.4.3. *Fungsi aktivasi ReLU*

ReLU adalah fungsi aktivasi dengan fungsi $f(x) = \max(0, x)$ yang membuat seluruh nilai pixel bernilai kurang dari nol pada sebuah citra akan dirubah menjadi nol. Tujuan dari ReLU adalah untuk mengurangi linearitas akibat dari proses konvolusi sehingga CNN lebih mudah untuk mencapai hasil yang optimum [49].

2.2.4.4. *Pooling Layer*

Pooling layer adalah bentuk downsampling yang biasanya mengikuti *convolution layer* pada *neural network*. Menerapkan *pooling* ke *feature map*, dapat mengubah ukuran peta dengan ukuran tertentu. *Pooling layer* digunakan untuk mereduksi *feature map*, sehingga mempercepat komputasi karena bobot yang harus di *update* semakin sedikit. Metode paling umum dalam pooling layer adalah *max-pooling*, dimana nilai *maximum* dari wilayah tertentu pada *feature map* diambil [48].

2.2.4.5. *Flatten Layer*

Tahap *flatten layer* dilakukan untuk mengubah *feature map* yang masih berbentuk array multidimensi menjadi *vector* (array satu dimensi) agar dapat digunakan sebagai input pada proses klasifikasi [47].

2.2.4.6. *Fully Connected Layer*

Fully Connected Layer terdiri dari *Input Layer*, *Hidden layer* dan *Output Layer*. Pada *fully connected layer* semua node (neuron) dari *layer* sebelumnya terhubung

menyeluruh dengan node di layer selanjutnya. Pada *hidden layer* terdapat fungsi aktivasi, yang umum digunakan yaitu ReLU, dan begitu pula di output layer, juga terdapat fungsi aktivasi, dalam kasus klasifikasi (yang lebih dari 2 label/kelas/kategori) yang umum digunakan yaitu *Softmax* [47].

2.2.4.7. *Softmax*

Setiap kasus klasifikasi yang menggunakan lebih dari dua kelas, akan digunakan aktivasi *softmax* untuk menghitung kemungkinan dari setiap kelas atas semua kelas yang memungkinkan dan akan membantu untuk menentukan kelas target untuk input citra yang diberikan [47].


2.2.5. *Transfer learning*

Transfer learning atau pre trained model merupakan metode dimana arsitektur *Convolutional Neural Network* yang sudah dilatih dengan suatu dataset sebelumnya yang nantinya dapat digunakan untuk masalah baru, dengan begitu waktu pelatihan model lebih singkat dibandingkan dengan model yang dikembangkan dari awal. Pembelajaran transfer dapat digunakan dalam pembuatan model yang digunakan sebagai ekstraktor fitur tetap dengan menghilangkan lapisan terakhir yang terhubung penuh atau dengan menyempurnakan beberapa lapisan terakhir yang akan bekerja lebih spesifik untuk dataset yang digunakan [50]. *Transfer learning* memungkinkan pelatihan *Deep Learning* mendapatkan akurasi yang tinggi bahkan dengan menggunakan jumlah sampel yang sedikit [51]. Model *transfer learning* memiliki beberapa jenis diantaranya adalah VGG-16, Inception-V3, ResNet-50, MobileNet, dan masih banyak lagi [22].

2.2.6. MobileNet V2

MobileNet merupakan salah satu dari arsitektur *convolutional neural network*. Kelebihan yang dimiliki oleh MobileNet adalah memiliki ketebalan dari filter konvolusi yang sesuai dengan gambar, menjadikannya lebih hemat ukuran dari model yang dibuat. MobileNet mengusulkan konvolusi *depthwise separable* yang dapat dipisahkan secara mendalam, yaitu memisahkan dua konvolusi standar ialah konvolusi *depthwise* dan konvolusi *pointwise*. Tujuan dari layer ini adalah


mengurangi komputasi/agar lebih sedikit parameter, sehingga menghasilkan ukuran model yang lebih kecil [52]. Gambar 2.3 menunjukkan perbedaan antara *normal convolution* dengan *depthwise convolution*.



Gambar 2.3 Normal Convolution vs Depthwise Convolution [49]

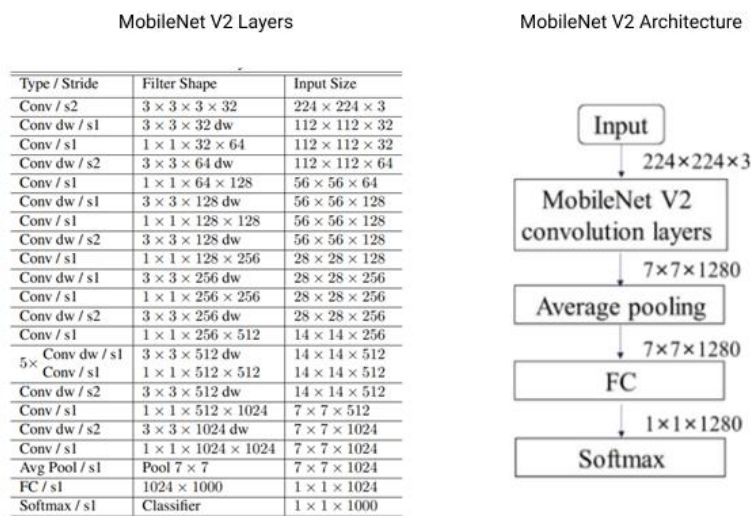
Normal convolution memiliki filter yang melakukan konvolusi terhadap citra inputan dan menghasilkan feature map. Sedangkan pada *depthwise convolution* memiliki filter yang jumlahnya akan sama dengan jumlah *channel* di citra inputan lalu menghasilkan *feature map* yang memiliki jumlah *channel* yang sama dengan jumlah *filter*. Tahap *depthwise convolution* terdapat 3 filter 5x5x1 yang bergeser sebanyak 8x8 kali atau dengan kata lain berarti $3 \times 5 \times 5 \times 1 \times 8 \times 8 = 4.800$. Tahap *pointwise convolution* terdapat 256 filter 1x1x3 yang bergeser sebanyak 8x8 kali atau dalam arti lain berarti $256 \times 1 \times 1 \times 3 \times 8 \times 8 = 49.152$. Maka total perkalian yang dilakukan saat proses konvolusi pada *depthwise separable convolution* ini yaitu $4.800 + 49.152 = 52.952$ [47].

MobileNet V2 merupakan pengembangan dari MobileNet sebelumnya yang mendukung untuk pengenalan visual termasuk klasifikasi, deteksi dan segmentasi. MobileNet V2 dibangun menggunakan konvolusi yang dapat dipisahkan secara mendalam sebagai blok bangunan yang efisien. Terdapat 2 fitur baru yang terdapat pada MobileNet V2 yaitu, *linear bottlenecks between the layers*, dan *shortcut connections between the bottlenecks*. Gambar Block Konvolusi *Linear Bottleneck* dapat dilihat pada gambar 2.4



Gambar 2.4 Block Konvolusi Linear Bottleneck [50]

Fitur *bottlenecks* menyandingkan input dan output antara model, sementara inner layer merangkul kemampuan model untuk mengubah dari konsep tingkat yang lebih rendah seperti piksel ke kategori gambar, deskriptor tingkat yang lebih tinggi. Terakhir, seperti koneksi residual tradisional, *shortcuts* memungkinkan pelatihan yang lebih cepat dan akurasi yang lebih baik. Secara keseluruhan, model MobileNet V2 lebih cepat untuk akurasi yang sama di seluruh spektrum latensi. Sehingga, MobileNet V2 sangat efektif untuk deteksi dan segmentasi objek [53].



Gambar 2.5 Arsitektur MobileNet V2

Secara umum arsitektur MobileNet terbagi menjadi beberapa layers, berikut penjelasannya:

2.2.6.1. Input


Input layer pada arsitektur MobileNet V2 sama dengan arsitektur Convolutional Neural Network yang mewakili gambar citra masukan. Jika citra masukan berukuran 224×224 px dan berjenis RGB (*Red, Green, Blue*), maka citra inputan ini berupa array multidimensi dengan ukuran $224 \times 224 \times 3$ dengan 3 merupakan jumlah channel yaitu *red, green* dan *blue* [47].

2.2.6.2. MobileNet V2 Convolutional Layers

MobileNet V2 memiliki tiga jenis convolutional layers/ lapisan konvolusi yaitu *depthwise convolution*, *1x1 convolution linearity*, dan *1x1 convolution non linearity* [54]. *Depthwise convolution* merupakan hasil faktorisasi dari konvolusi standar. Konvolusi 1×1 atau disebut *pointwise convolutional* yang digunakan untuk menggabungkan seluruh hasil konvolusi *depthwise convolution* [55]. Konvolusi 1×1 linearity menggunakan ReLU sebagai fungsi aktivasinya, sedangkan dalam *1x1 convolution non linearity* tidak lagi menggunakan fungsi aktivasi, karena jika digunakan lagi jaringan dalam hanya memiliki kekuatan pengklasifikasi linier pada bagian volume bukan nol dari domain keluaran [54].

2.2.6.3. Average Pooling

Pooling layer yang digunakan dalam arsitektur MobileNet V2 adalah average pooling. Average pooling merupakan operasi pooling yang menggunakan rata-rata sebagai feature map. Average pooling menerjemahkan gambar dengan jumlah kecil tidak secara signifikan mempengaruhi nilai dari sebagian besar keluaran yang dikumpulkan [56]. Sebagai contoh terlihat pada gambar 2. 5. Rata-rata angka dalam warna oranye adalah 2,75 ini adalah penyatuan rata-rata dengan filter *hyperparameter* =2 langkah =2 [57].



Gambar 2.6 Contoh Average Pooling [54]

2.2.6.4. Fully Connected

Pada MobileNet V2 digunakan *Fully Connected Layer* untuk klasifikasi. *Fully Connected Layer* pada arsitektur MobileNet V2 sama dengan *Fully Connected Layer* pada CNN yang terdiri dari *Input Layer*, *Hidden layer* dan *Output Layer*. Pada *hidden layer* terdapat fungsi aktivasi, yang umum digunakan yaitu ReLU, dan begitu pula di *output layer*, juga terdapat fungsi aktivasi, dalam kasus klasifikasi (yang lebih dari 2 label/kelas/kategori) yang umum digunakan yaitu *Softmax* [47].

2.2.6.5. Softmax

Softmax pada arsitektur MobileNet V2 sama dengan *softmax* pada arsitektur CNN. Setiap kasus klasifikasi yang menggunakan lebih dari dua kelas, akan digunakan aktivasi *softmax* untuk menghitung kemungkinan dari setiap kelas atas semua kelas yang memungkinkan dan akan membantu untuk menentukan kelas target untuk input citra yang diberikan [47].

2.2.7. Keras

Keras merupakan API dengan jaringan saraf tingkat tinggi, membantu jalannya *Deep Learning* dan kecerdasan buatan yang dirancang konsisten dan sederhana. Keras dibangun di atas TensorFlow 2, keras merupakan kerangka kerja berkekuatan industri yang dapat menskalakan ke kluster besar GPU atau seluruh pod TPU. Keras mencakup setiap langkah alur kerja machine learning, mulai dari manajemen data hingga pelatihan *hyperparameter* hingga solusi penerapan. Memanfaatkan kemampuan penerapan penuh platform TensorFlow, model keras dapat di export ke javascript untuk dijalankan langsung di browser dan di export ke TFLite untuk dijalankan di IOS dan android [22].

2.2.8. TensorFlow

Tensorflow adalah koleksi software open source untuk komputasi numerik yang menggunakan grafik aliran data. Node pada grafik menunjukkan operasi matematika, sedangkan tepi-tepi grafik menunjukkan susunan data multidimensi (Tensor) yang dikomunikasikan antar tepi grafik. Arsitekturnya yang fleksibel dapat dimanfaatkan untuk menerapkan komputasi ke satu atau beberapa CPU atau GPU pada desktop, server, atau perangkat seluler dengan cukup menggunakan satu API. TensorFlow awalnya dikembangkan oleh para peneliti dan engineer yang bekerja di Google Brain Team dalam organisasi riset Machine Intelligence Google, untuk keperluan menjalankan machine learning dan riset jaringan deep neural network. Namun, sistem ini juga cukup umum untuk diterapkan pada aneka domain lainnya. TensorFlow ini digunakan sebagai backend dari Keras, yang artinya adalah TensorFlow sebagai bagian belakang layar dari sebuah aplikasi atau website dengan menggunakan bahasa pemrograman Python dan dikombinasikan dengan *library* Keras dari *Deep Learning* [58].

2.2.9. Augmentasi Data

Augmentasi data merupakan suatu cara yang digunakan untuk meningkatkan keragaman data yang tersedia secara signifikan, tanpa benar-benar mengumpulkan data baru untuk model pelatihan. Teknik augmentasi data seperti *cropping*,

padding, *zoom*, *rotate*, *shear range* dan *horizontal flipping* biasanya digunakan untuk melatih *large neural network* [59]. Beberapa operasi yang digunakan pada augmentasi data diantaranya meliputi *cropping*, *flipping*, *rotating*, dan *resizing*. *Cropping* dilakukan untuk memotong satu bagian dari citra. *Flipping* yaitu perubahan orientasi citra secara *horizontal*, *vertical*, atau keduanya. *Rotating* yaitu memutar citra terhadap titik pusat dalam derajat, baik searah atau berlawanan jarum jam. *Resizing* adalah mengubah resolusi citra [60].

2.2.10. *Epoch*

Epoch atau dalam bahasa Inggris dapat diartikan sebagai masa diartikan sebagai satu putaran penuh pelatihan (*Training*) terhadap seluruh *set data Training*. Tidak ada penjelasan yang pasti terkait jumlah *epoch* yang digunakan untuk mendapatkan hasil yang optimal, karena hasil akan berbeda untuk dataset yang berbeda. Namun dapat digunakan sebagai acuan, hentikan *epoch* saat nilai loss tidak turun lagi atau nilai akurasi tidak mengalami kenaikan yang signifikan [47].

2.2.11. Python

Python adalah bahasa pemrograman interpretatif multiguna dengan filosofi perancangan yang berfokus pada tingkat keterbacaan kode. Python diklaim sebagai bahasa yang menggabungkan kapabilitas, kemampuan, dengan sintaksis kode yang sangat jelas, dan dilengkapi dengan fungsionalitas pustaka standar yang besar serta komprehensif. Python merupakan salah satu bahasa pemrograman tingkat tinggi (*high level language*). Python dirancang untuk memberikan kemudahan bagi programmer melalui segi efisiensi waktu, kemudahan dalam pengembangan dan kompatibilitas dengan sistem. Python bisa digunakan untuk membuat aplikasi standalone (berdiri sendiri) dan pemrograman *script (scripting programming)* [61].

Python merupakan bahasa pemrograman dinamis yang mendukung pemrograman berbasis objek. Python didistribusikan dengan beberapa lisensi yang berbeda dari beberapa versi. Namun pada prinsipnya Python dapat diperoleh dan dipergunakan secara bebas, bahkan untuk kepentingan komersial. Karena lisensi

Python tidak bertentangan baik menurut definisi Open Source maupun General Public License (GPL) [62].

2.2.12. Confusion Matrix

Menurut Han dan Kamber *Confusion matrix* merupakan suatu alat yang digunakan untuk menganalisa seberapa baik pengklasifikasi mengenali tuple dari kelas yang berbeda. *Confusion matrix* memberikan output berupa nilai performa klasifikasi berdasarkan objek berupa akurasi, precision dan recall. Pengukuran kinerja menggunakan *Confusion matrix* terdapat empat istilah representasi hasil proses klasifikasi yaitu, *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)* dan *False Negative (FN)*. Gambar berikut merupakan visualisasi *Confusion matrix* [63].

Tabel 2.2 Visualisasi *Confusion matrix* [58]

		Actual Value	
		1 (Positive)	0 (Negative)
Predicted Value	1 (Positive)	TP(True Positive)	FP (False Positive) Type 1 Error
	0 (Negative)	FN (False Negative) Type 2 Error	TN (True Negative)

2.2.13. Padi

Padi adalah tanaman sumber karbohidrat yang dijadikan sumber pangan oleh sebagian besar masyarakat dunia Berdasarkan dari klasifikasinya padi termasuk ke dalam golongan famili rumput-rumputan (poaceae) dengan nama genus oryza dan juga termasuk jenis tanaman biji-bijian (serealia). Di negara Indonesia padi dapat tumbuh sepanjang musim [64]. Tanaman padi memiliki kemampuan beradaptasi yang baik sehingga membuat tanaman ini tersebar dari dataran rendah hingga ke dataran tinggi yaitu mulai dari 0 hingga 1.500 mdpl pada suhu 19°C sampai 27°C di tanah subur maupun tanah kritis, rawa-rawa hingga lahan kering serta pada daerah tropis sampai subtropis pada garis lintang 45° LU sampai 45° LS dengan intensitas penyinaran yang penuh tanpa adanya perlindungan atau naungan. Pada

masa pertumbuhannya, tanaman padi terkhusus padi sawah membutuhkan air yang banyak. Curah hujan yang dibutuhkan untuk pertumbuhan tanaman padi adalah sekitar 1.500 sampai 2.000 mm/tahun atau sekitar 200 mm/bulannya. Di daerah dengan irigasi yang cukup baik, tanaman padi ditanam sebanyak tiga kali dalam waktu satu tahun, sedangkan di daerah yang tidak memiliki irigasi maka perlu memperhatikan kondisi dari curah hujan tahunan [65].

Penyakit pada padi merupakan salah satu faktor kendala dalam peningkatan produksi padi. Penyakit yang sering muncul pada tanaman padi adalah sebagai berikut:

2.2.13.1. *Hawar Daun Bakteri (Bacterial leaf blight)*



Gambar 2.7 Penyakit Hawar Daun pada Padi

Sumber: (Rice Leaf Diseases Dataset, Kaggle Dataset)

Penyakit hawar daun bakteri (HDB) merupakan salah satu penyakit pada tanaman padi. Penyakit ini disebabkan oleh bakteri *Xanthomonas oryzae* pv. *oryzae* (Xoo). Patogen ini dapat menginfeksi tanaman padi pada semua fase pertumbuhan tanaman dari mulai persemaian sampai menjelang panen. Penyebab penyakit (patogen) menginfeksi tanaman padi pada bagian daun melalui luka daun atau lubang alami berupa stomata dan merusak klorofil daun. Hal tersebut menyebabkan menurunnya kemampuan tanaman untuk melakukan fotosintesis yang apabila terjadi pada tanaman muda mengakibatkan mati dan pada tanaman fase generatif mengakibatkan pengisian gabah menjadi kurang sempurna.

Bila serangan terjadi pada awal pertumbuhan, tanaman menjadi layu dan mati, gejala ini disebut kresek. Gejala kresek sangat mirip dengan gejala sundep yang

timbul akibat serangan penggerek batang pada fase tanaman vegetatif. Pada tanaman dewasa penyakit hawar daun bakteri menimbulkan gejala hawa (blight). Baik gejala kresek maupun hawar, gejala dimulai dari tepi daun, berwarna keabu-abuan dan lama-lama daun menjadi kering. Bila serangan terjadi saat berbunga, proses pengisian gabah menjadi tidak sempurna, menyebabkan gabah tidak terisi penuh atau bahkan hampa. Pada kondisi seperti ini kehilangan hasil mencapai 50-70 persen [66].

2.2.13.2. *Bercak Daun Coklat Sempit (Leaf Smut)*



Gambar 2.8 Penyakit Bercak Daun Coklat Sempit pada Padi

Sumber : (Rice Leaf Diseases Dataset, Kaggle Dataset)

Penyakit Bercak Daun Coklat Sempit atau Narrow Brown Leaf Spot (Leaf Spot) merupakan penyakit yang disebabkan oleh patogen *C. oryzae*. Patogen ini menyebabkan bintik coklat sempit pada permukaan daun tanaman padi, efek serangan dari patogen ini mengakibatkan munculnya lesi memanjang dengan pinggir yang berwarna gelap dengan pusat yang keabu-abuan. Lesi yang muncul berkisar 1-10 mm x 1 -1,5 mm pada permukaan daun dan 15- 45 mm x 1-2 mm pada tulang daun yang bervariasi pada tiap kultivar tanaman padi [32]. Jamur *C. oryzae* memiliki aerial mycelium. Jamur ini berwarna coklat, pendek, sederhana dan langsung tumbuh dari permukaan benih kebanyakan satu atau dalam dua atau tiga grup. Mycelium hyaline ke olive cerah, konidiofor coklat dan semakin cerah di ujung, memiliki tiga septa atau lebih dan tidak bercabang [67].

2.2.13.3. *Tungro*



Gambar 2.9 Penyakit Tungro pada Padi

Sumber : (Leaf Rice Disease, Kaggle Dataset)

Tungro merupakan penyakit yang disebabkan oleh infeksi ganda dari 2 jenis virus yang berlainan. Kedua virus yang dimaksud adalah Rice Tungro Spherical Virus (RTSV) dan Rice Tungro Bacilliform Virus (RTBV). Patogen penyakit tungro paling efektif ditularkan oleh wereng hijau *Nephotettix virescens* Distant. Kehilangan hasil karena serangan penyakit tungro bervariasi bergantung pada saat tanaman terinfeksi, lokasi dan titik infeksi, musim tanam dan jenis varietas. Semakin muda tanaman terinfeksi, maka semakin besar persentase kehilangan hasil yang ditimbulkan. Kisaran kehilangan hasil pada stadia infeksi dari 2-12 minggu setelah tanam (MST) antara 90-20% [68].

2.2.13.4. Hawar pelepah daun (*Sheath Blight*)



Gambar 2.10 Hawar pelepah daun (*Sheath Blight*) pada padi

Sumber : (A Dataset of Rice Leaf Disease Classification for Bangladeshi Local Rice, Mendeley Data)

Hawar pelepah daun (*Sheath Blight*) merupakan penyakit pada tanaman padi yang disebabkan oleh jamur *Rhizoctonia solani* Kuhn. Tanaman padi yang terserang penyakit ini memiliki kemungkinan besar mengalami penurunan produktivitas. Indonesia sendiri memiliki persentase sebesar 6-52% untuk tingkat keparahan tanaman padi akibat penyakit hawar pelepah daun [69]. Beberapa faktor yang mempercepat berkembangnya Infeksi penyakit hawar pelepah daun ini adalah suhu udara dan kelembapan tinggi, sumber inokulum penyakit hawar pelepah selalu tersedia, dan pemberian pupuk nitrogen atau urea dengan kadar yang tinggi. [70].