BAB II
TINJAUAN PUSTAKA

2.1. Kajian Pustaka

Penelitian terkait dengan klasifikasi citra sudah banyak dilakukan dan penerapannya di berbagai bidang kehidupan. Penelitian terdahulu menunjukkan bahwa penelitian mengenai klasifikasi pada gambar sangat diperlukan untuk dijadikan sebagai landasan bagi penelitian berikutnya agar hasil yang didapatkan lebih baik lagi. Hal ini juga dapat memudahkan dan membantu penelitian terkait klasifikasi citra berikutnya.

Penelitian dengan judul "*Convolutional Neural Network Untuk Metode Klasifikasi Multi-Label Pada Motif Batik*" dilakukan oleh Taufiqotul Bariyah, Mohammad Arif Rasyidi dan Ngatini. Pada penelitian ini menggunakan 15 motif batik yang dilakukan *resize* menjadi berukuran 350x350 piksel dengan 3000 citra yang terbagi menjadi data latih sebanyak 2700 citra dan data uji 300 citra. Proses *training* dilakukan dengan 100 *epoch* dan didapatkan nilai akurasi 91,41%, nilai *loss* 0,344%, nilai *recall* 86,96%, nilai *precision* 94,5%, dan nilai *f-measure* 90,5%. Peningkatan akurasi pada klasifikasi multi-label ini dapat dilakukan dengan menambah dataset dalam menghindari ketidakseimbangan data, akan tetapi dapat memungkinkan terjadinya kasus *overfitting* pada dataset [10].

Penelitian dengan judul "Klasifikasi Motif Batik Menggunakan *Convolutional Neural Network*" oleh Rizki Mawan. Pada penelitian ini menggunakan 120 data citra batik dengan 3 kelas batik berupa kawung, megamendung, dan parang yang diambil melalui sumber internet seperti *github* dan *fasnina*. Dataset disamakan ukurannya menjadi 250x250 piksel dan dibagi menjadi 90 data latih dan 30 data uji. Hasil yang didapatkan pada model CNN mencapai rata-rata akurasi 65% sedangkan pada model CNN dengan *grayscale* mencapai rata-rata akurasi 70% [6].

Penelitian dengan judul "Pengaruh Dimensi Gambar Pada Klasifikasi Motif Batik Menggunakan *Convolutional Neural Network*" oleh Rizki Mawan, Kusrini dan Hanif Al Fattah. Pada penelitian ini menggunakan tiga motif batik yang populer

yaitu batik megamendung, kawung, dan parang dengan jumlah data sebanyak 120 data yang terbagi dengan perbandingan pembagian dataset 80:20. Penelitian ini membandingkan dimenasi citra yang mempengaruhi hasil dari akurasi model. Dimensi yang digunakan pada penelitian ini adalah 64x64, 128x128, dan 256x256 dengan *epoch* 240. Hasil yang didapatkan berupa akurasi masing-masing dimensi berturut-turut sebesar 92.85%, 85%, dan 80% [20].

Penelitian dengan judul "*Pengenalan Motif Kain Songket Pada Citra Kamera Smartphone Dengan Beragam Sudut Pandang Menggunakan CNN*" dilakukan oleh Muhammad Husein Nashr, Muhammad Fachrurrozi, Eni Triningsih dan Kanda Januar Miraswan. Penelitian ini menambahkan *dropout* dalam meningkatkan nilai akurasi dari data uji dan dapat mempercepat waktu pada pelatihan hingga 2x lebih cepat. Model CNN dilatih antara 200 – 400 *epoch*. Penggunaan *dropout* dapat meningkatkan akurasi data uji. Akan tetapi, nilai *dropout* tinggi dapat mengurangi parameter dan menurunkan kemampuan model dalam *fitting* data uji sehingga nilai *loss* uji menurun saat akurasi model masih tinggi. Hal ini disebabkan karena data latih dan uji yang masih mempunyai *variance* tinggi dan masih dibutuhkan suatu augmentasi ataupun mengumpulkan data lebih banyak [16].

Penelitian dengan judul "*Analisis Pengaruh Tingkat Akurasi Klasifikasi Citra Wayang dengan Algoritma Convolutional Neural Network*" dilakukan oleh Muhammad Resa Arif Yudianti, Kusrini dan Hanif Al Fatta. Penelitian ini menggunakan 400 dataset yang terbagi menjadi 4 kelas dengan ukuran citra yang digunakan 180x180 piksel. Dataset dibagi menjadi data latih dan data uji dengan perbandingan data sebesar 80:20 yang diperoleh melalui *scrapping* dengan *Python*. Penelitian ini menggunakan 3 lapisan konvolusi, 3 lapisan *pooling* dengan menggunakan aktivasi ReLU, dan terakhir 1 lapisan *fully connected layer* dengan aktivasi *softmax*. Hasil percobaan didapatkan nilai akurasi terbaik bernilai 97% dengan presisi sebesar 93% dan *recall* 87% dengan menggunakan kombinasi *grayscale* dan penggunaan *epoch* sebesar 100 yang mana hal tersebut sangat berpengaruh pada peningkatan nilai akurasi dan dapat meningkatkan kecepatan pada proses komputasi tiap stepnya [19].

Penelitian dengan judul "*Optimasi Akurasi Metode Convolutional Neural Network untuk Identifikasi Jenis Sampah*" yang dilakukan oleh Rima Dias Ramadhani, Afandi Nur Aziz Thohari, Condro Kartiko, Apri Junaidi, Tri Ginanjar Laksana dan Novanda Alim Setya Nugraha. Pada penelitian ini menggunakan arsitektur CNN dengan *hyperparameter* berupa *dropout*, *padding* dan *stride*. Dataset berasal dari *google image* yang diambil dengan *extension chrome Fatkun Batch Image Downloader* untuk mendapatkan hasil *scrapping* data yang lebih banyak. Dataset terdiri dari 840 objek sampah organik dan 840 objek sampah anorganik dengan perbandingan data latih dan data validasi adalah 80:20. Penelitian ini menggunakan ukuran citra masukan 150x150 piksel dengan jumlah *epoch* sebanyak 25, *padding* berupa '*same'* dengan dimensi *stride* 2x2. Pada penelitian ini menggunakan arsitektur 3 *layer* konvolusi, menggunakan *maxpooling* pada lapisan *pooling*, *flatten* dan aktivasi *softmax*. Hasil dari optimasi tersebut didapatkan kenaikan pada nilai akurasi model hingga 91,2% yang sebelumnya 67,6% [14].

Penelitian dengan judul "*Identifikasi Spesies Reptil Menggunakan Convolutional Neural Network (CNN)*" dilakukan oleh Olvy Diaz Annesa, Condro Kartiko dan Agi Prasetiadi. Penelitian ini melakukan klasifikasi 14 jenis reptil menggunakan CNN yang dirancang menjadi 8 model arsitektur. Pada setiap model memiliki lapisan konvolusi, jumlah aktivasi *softmax* dan *epoch* yang berbeda pada setiap model serta pada model M.8 dilakukan penambahan *dropout* sebesar 0,5. Pada proses augmentasi memperbanyak citra pada tiap kelas dan membagi data dengan perbandingan data latih dan data ujinya sebesar 90:10. Pada penelitian ini penambahan nilai *dropout* sebesar 0,5 di lapisan keempat pada model M.8 dengan arsitektur 4 lapisan konvolusi dan 4 lapisan pooling berpengaruh dalam peningkatan hasil akurasi dengan probabilitas akurasi sebesar 93% [21].

Penelitian dengan judul "*Performance Analysis of Three Kinds of Neural Networks in the Classification of Mask Images*" oleh Jinkui Chi, Yuxi Liu, Victor Wang dan Jiaxuan Yan. Klasifikasi penggunaan masker dilakukan dengan tiga jaringan CNN klasik, seperti VGG, ResNet, dan DenseNet. Dataset dibagi menjadi data *train*, data validasi, dan data *test* dengan perbandingan 80-10-10 dengan perbandingan eksperimen menggunakan split data menjadi 70-15-15. Penelitian ini

juga mengujikan augmentasi data, teknik regularisasi berupa *dropout* dan *early stopping* serta *hyperparameter* dalam melihat efek dari *overfitting*. Penelitian ini didapatkan cara terbaik dalam meningkatkan performa model dan menurunkan kasus *overfitting* dengan penggunaan pembagian data menjadi 80-10-10 dan penggunaan augmentasi data serta *random dropout*. Ketiga model memiliki nilai akurasi di atas 96% [22].

Ringkasan dari penelitian yang relevan ditunjukan pada Tabel 2.1 berikut ini.

Tabel 2.1 Penelitian Terdahulu

No.	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
1.	*Convolutional Neural Network* Untuk Metode Klasifikasi *Multi-Label* Pada Motif Batik	Menggunakan 15 motif batik dengan CNN dengan jumlah data sebanyak 3000 data dengan 2700 data latih dan 300 data uji.	Klasifikasi multi-label pada 15 citra motif batik. Aktivasi yang digunakan berupa sigmoid dengan optimasi adam serta menggunakan fungsi *binery cross entropy* dalam mengurangi data *loss*.	Nilai akurasi tertinggi di *epoch* ke-92, sedangkan nilai *loss* turun sangat rendah di *epoch* ke-78 dan naik di *epoch* ke-79. Hal ini disebabkan oleh kecepatan *learning rates* yang rendah sehingga data *loss* meningkat secara liner dan memungkinkan terjadinya *overfitting* karena ketidakseimbangan pada dataset.	Penelitian dilakukan dengan mencari dataset lalu melakukan *Preprocessing* dengan *cropping* dan *resizing*. Kemudian membangun model *Convolutional Neural Network* dan dilakukan pengujian serta menghitung hasil akurasi, *recall*, *precision* dan *f-measure*.	Penelitian dengan menggunakan CNN pada klasifikasi multi-label motif batik mencapai akurasi 91,41% dan nilai *loss* sebesar 0.344% dengan menggunakan *epoch* 100.

No.	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
2.	Klasifikasi Motif Batik Menggunakan *Convolutional Neural Network*	Menggunakan jumlah dataset 120 citra batik kawung, megamendung, dan parang.	Penelitian menggunakan 3 motif batik dengan jumlah data citra sebanyak 120 citra berukuran 250x250 piksel.	Arsitektur model yang digunakan tidak dijelaskan secara rinci.	Penelitian menggunakan dataset motif batik populer, yaitu kawung, parang, dan megamendung. Augmentasi menggunakan *grayscale image*.	Model yang menggunakan CNN mencapai rata-rata akurasi 65% sedangkan model kombinasi CNN dengan *grayscale* mencapai rata-rata akurasi 70%.
3.	Pengaruh Dimensi Gambar Pada Klasifikasi Motif Batik Menggunakan *Convolutional Neural Network*	Melakukan perbandingan hasil akurasi berdasarkan dimensi gambar pada klasifikasi motif batik dengan CNN.	Penelitian ini menggunakan 3 motif batik dengan dimensi perbandingan yang digunakan 64x64, 128x128, 256x256 piksel dengan nilai *epoch* 240.	Model *loss* pada data pelatihan dan uji di ukuran 128x128 dan 256x256 piksel mengalami kenaikan pada grafik *loss* test dan penurunan pada grafik *loss* train. Akan tetapi model akurasi mengalami kenaikan.	Penelitian menggunakan dataset motif batik populer yaitu kawung, parang, dan megamendung dengan format ekstensi .jpg yang didapatkan melalui google image, github dan fasnina.com.	Hasil akurasi yang dihasilkan pada ukuran 64x64 sebesar 92.85%, pada ukuran 128x128 sebesar 85% dan pada ukuran 256x256 sebesar 80%.

No.	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
4.	Pengenalan Motif Kain Songket Pada Citra Kamera *Smartphone* Dengan Beragam Sudut Pandang Menggunakan CNN	Melakukan klasifikasi kain songket dengan *Convolutional Neural Network* dan penggunaan fitur SIFT dikombinasikan dengan BoW. Penggunaan *dropout* juga dilakukan dalam meningkatkan tingkat akurasi.	Penelitian ini menggunakan kombinasi fitur SIFT-BoW dan penggunaan *dropout* pada algoritma *Convolutional Neural Network*	Pada *layer* konvolusi tidak dapat mengekstrak fitur penting yang menjadi pembeda antar kelas. Sehingga terjadi *overfitting* dan nilai *loss Testing* meningkat jauh dari *loss Training* yaitu dimulai dari nilai *epoch* 80. Penelitian ini juga tidak menjelaskan ada berapa kali percobaan yang dilakukan dan model yang digunakan.	Dataset dikumpulkan menggunakan data primer. Terdapat 12 motif kain songket. Kemudian data dipecah menjadi data *Training* dan *Testing* kemudian dilakukan pengujian pada beberapa percobaan. Selanjutnya melakukan evaluasi hasil dengan mencari nilai *loss* dan hasil akurasi klasifikasi.	Penelitian ini mampu melakukan klasifikasi pada motif songket dengan hasil akurasi sebesar 93% dengan penggunaan *dropout* senilai 0,9 untuk mengurangi waktu pada *Training* data.
5.	Analisis Pengaruh Tingkat Akurasi	Klasifikasi citra wayang dengan CNN dan	Penelitian ini mencari skenario terbaik dari 24	Tahapan *Preprocessing* tidak dijelaskan	Dataset terdiri dari 4 kelas yang diambil melalui *scrapping*	Hasil berupa Akurasi 97%, presisi 93%, dan

No.	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
	Klasifikasi Citra Wayang dengan Algoritma *Convolutional Neural Network*	melakukan beberapa skenario dengan penambahan *Grayscale*, augmenasi dan perbedaan nilai *epoch* tiap skenario.	skenario percobaan yang melibatkan dataset yang masih menggunakan RGB dan *Grayscale*, augmentasi, jumlah *epoch* dan perbandingan data *Training* dan data *Testing*.	dengan rinci dalam penelitian ini.	dari *google image*. Arsitektur yang diguanakn 3 lapisan konvolusi, 3 lapisan *pooling* dengan aktivasi relu dan 1 lapisan *fully connected layer* dengan aktivasi *softmax*. Evaluasi hasil dengan menggunakan *Confusion Matrix Multi-Class*.	*recall* 87% dengan kombinasi augmentasi *grayscale*, penggunaan rasio pembagian dataset 80:20 dan nilai *epoch* sebesar 100. Kombinasi ini sangat berpengaruh pada peningkatan akurasi model klasifikasi.
6.	Optimasi Akurasi Metode *Convolutional Neural Network* untuk Identifikasi Jenis Sampah	Membandingkan hasil pengukuran akurasi algoritma *Convolutional Neural Network* sebelum dan sesudah penambahan *Hyperparameter*	Penelitian ini melakukan perbandingan pengukuran hasil akurasi pada algoritma *Convolutional Neural Network* sebelum dan	Pada penelitian ini terlihat waktu yang dibutuhkan pada saat melakukan pelatihan tiap step *epoch* nya masih terbilang cukup lama.	Dataset diperoleh dari *google image* dengan *extension chrome Fatkun Batch Image Downloader*. *Preprocessing* dilakukan dengan *library ImageDataGenerator*	Model dengan *hyperparameter* menghasilkan kenaikan akurasi model mencapai 91,2% yang sebelumnya sebesar 67,6%. Penambahan

No.	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
		berupa *dropout*, *padding* dan *stride*. Penelitian ini pada konsep akhir dirancang sebuah aplikasi.	sesudah dilakukan penambahan *Hyperparameter* berupa *dropout*, *padding* dan *stride*.		dan dilakukan *resize*, flip dan rotate agar ukuran dan bentuk sama.	*hyperparameter* juga dapat mempercepat waktu *Training* hingga 50% dan dapat membuat model menjadi *goodfit*.
7.	Identifikasi Spesies Resptil Menggunakan *Convolutional Neural Network* (CNN)	Penelitian dilakukan untuk mengidentifikasi 14 jenis reptil dengan CNN.	Penelitian dilakukan dengan membuat 8 model. Pada setiap model menggunakan lapisan konvolusi, jumlah aktivasi *softmax* dan *epoch* yang berbeda serta pada model M.8 dilakukan penambahan *dropout* sebesar 0,5 pada lapisan keempat.	Pada model M.8 masih membutuhkan waktu lama dalam menghasilkan akurasi validasi daripada model lainnya. Model M.8 memiliki penggunaan memori terberat dalam penelitian tersebut.	Pembagian data menjadi data latih dan uji dengan perbandingan 90:10. Pada model M.8 menggunakan arsitektur CNN dengan 4 lapisan konvolusi, 4 lapisan pooling dan menggunakan dropout sebesar 0.5.	Pada penelitian ini menggunakan *dropout* sebesar 0,5 pada pengujian model M.8 ini berpengaruh dalam peningkatan hasil akurasi dengan probabilitas akurasi sebesar 93%.

No.	Judul	Comparing	Contrasting	Criticize	Synthesize	Summarize
8.	Performance Analysis of Three kinds of Neural Networks in the Classification of Mask Images	Penelitian ini menggunakan perbandingan hasil dari arsitektur neural network berupa VGG, ResNet dan DenseNet dalam klasifikasi citra penggunaan masker dengan citra RGB berukuran 224x224 piksel.	Pembagian dataset 80-10-10 dan eksperimen untuk mengamati kinerja model dan overfitting 70-15-15 menjadi data train, data validasi, dan data test. Penelitian ini menggunakan fitur *dropout* dan *early stopping* untuk melihat efek overfitting.	Akurasi pengujian model tertinggi mendapatkan 99% di arsitektur DenseNet akan tetapi masih terjadi overfitting. Sehingga dapat diterapkan beberapa augmentasi data maupun dropout untuk meningkatkan performa model.	Permbagian data menjadi data train, data validasi, dan data test dengan perbandingan 80-10-10. Penggunaan augmentasi data dan dropout dalam menangani kasus overfitting.	Penelitian ini didapatkan preforma model terbaik dan penurunan overfitting dengan pembagian data 80-10-10, penggunaan augmentasi data, dropout, dan *hyperparameter*. Ketiga model memiliki akurasi di atas 96%.

Penelitian utama yang digunakan sebagai landasan pada penelitian ini adalah penelitian dengan nomor urut 4 – 8. Pada penelitian ini membahas terkait penambahan fitur *grayscale* dan *hyperparameter* yang dapat mempercepat proses pelatihan, meminimalkan terjadinya *overfitting*, dan meningkatkan nilai akurasi. Sedangkan penelitian pendukung pada nomor urut 1 – 3 digunakan sebagai penelitian yang menunjang bahwa CNN baik dalam melakukan klasifikasi citra gambar batik.

2.2. Dasar Teori

Landasan teori berisi beberapa pengetahuan yang berkaitan dengan penelitian yang dilakukan untuk membantu peneliti dalam melakukan penelitian. Berikut ini adalah landasan teori yang berkaitan dengan penelitian ini:

2.2.1. Batik

Batik berasal dari kata Bahasa Jawa, yaitu *amba* dan *nitik* yang memiliki arti melempar titik berkali-kali pada kain lebar [10]. Batik merupakan kain bergambar ditulis maupun dicap menggunakan canting dari plat seng atau tembaga, sehingga menghasilkan seni klasik dan artistik pada media kain dengan menggunakan bahan lilin malam yang telah dipanaskan [4]. Lilin tersebut berguna sebagai pembentuk suatu pola perbedaan antara bagian yang diberi warna dan tidak pada kain ketika lilin tersebut dihilangkan. Hingga saat ini, batik terus berkembang dan mengalami pembaruan dalam motif dan model pada setiap daerah [23].

Gambar 2.1 Corak Motif Batik Geometris (Kawung) dan Corak Motif Non-Geometris (Batik Bunga)

Gambar 2.1 menunjukkan motif batik secara umunya terbagi menjadi dua macam, yaitu motif batik geometris dan non-geometris. Motif batik geometris merupakan motif batik yang disusun dengan menggunakan corak yang mengandung unsur garis hingga bangun, contohnya motif kawung [10]. Sedangkan motif batik non-geometris merupakan motif batik yang disusun dengan menggunakan corak non-geometris, contohnya pada corak tanaman, hewan maupun corak candi [10]. Setiap daerah memiliki corak dan motif yang beragam menyesuaikan dengan latar belakang dan ciri khas masing-masing. Selain dikarenakan perbedaan daerah asal, cara pembuatan batik juga menyumbang banyaknya corak dari batik Indonesia [10]. Makna dari batik sendiri memiliki arti yang sangat kental akan kebiasaan adat istiadat Indonesia [24].

Pada pulau Jawa, batik dibagi menjadi dua berdasarkan wilayahnya, yaitu batik pesisir dan batik pedalaman [5]. Perbedaannya ada pada corak yang dimilikinya. Batik pedalaman ini berlatarbelakang Hindu dan Kejawen [5].Pada batik pedalam memiliki corak yang simbolis atau perlambangan dan ditandai dengan warna-warna yang dominan, seperti coklat sagon, biru, hitam dan putih [5]. Contoh batik pedalaman ini seperti Batik Solo dan Batik Yogya. Sedangkan pada batik pesisir banyak dipengaruhi oleh budaya Cina, sehingga memiliki bentuk gambar yang lebih naturalis [5]. Batik pesisir lebih didominasi dengan warna biru muda sampai tua, kuning, coklat dan merah contonya seperti Batik Pekalongan [5].

2.2.2. Citra Digital

Citra adalah gambar yang ada pada bidang dua dimensi [16]. Secara sistematis, citra didefinisikan sebagai suatu fungsi berdimensi dua *f(x,y)* dengan variabel *x* dan *y* adalah koordinat dari bidang datar dengan nilai fungsi *f* pada koordinat x dan y disebut dengan intensitas atau disebut dengan level keabuan (*grey level*) dari titik pada gambar [16][25]. Citra digital dibentuk dari kumpulan titik yang biasa disebut dengan piksel yang direpresentasikan sebagai satu kotak kecil yang memiliki posisi pada koordinat tertentu [26]. Pada umumnya terdapat empat jenis citra yang digunakan pada pemrosesan citra, yaitu:

2.2.2.1. Citra Berwarna

Gambar 2.2 Citra Berwarna dan Representasi Warnanya [26]

Citra berwarna biasanya disebut dengan citra RGB. Citra berwarna menyajikan suatu warna yang memiliki beberapa komponen seperti, R

(merah), G (hijau) dan B (biru) yang dapat dilihat pada Gambar 2.2 [26]. Format file yang menyimpan suatu citra berwarna disebut dengan citra 24 bit dengan setiap komponen menggunakan 8 bit yang nilainya berkisar 0 – 255 [26][27]. Sehingga kemungkinan kombinasi warna bisa mencapai 16 juta warna, karena hal ini citra berwarna disebut juga "*true color*" [27].

2.2.2.2. Citra Berskala Keabuan

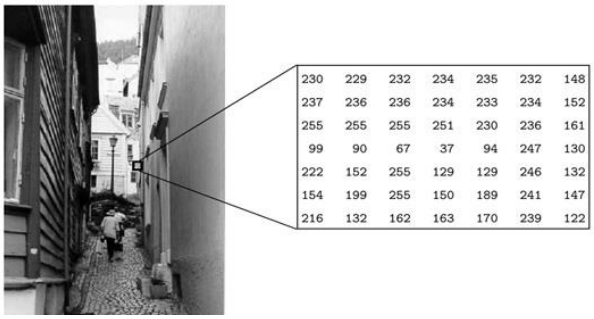

Gambar 2.3 Citra *Grayscale* dan Representasi Warnanya

Citra keabuan memiliki nama lain yaitu citra *grayscale* [26]. Menyesuaikan dengan namanya, citra ini memiliki gradasi dari warna hitam dan putih yang membuat suatu efek warna keabuan. Pada citra ini, warna pada citra dinyatakan sebagai intesitas yang berkisar antara 0 – 255 dengan nilai 0 menyatakan warna hitam dan nilai 255 sebagai warna putih [26]. Gambar 2.3 adalah ilustrasi representasi warna dari citra *grayscale*.

2.2.2.3. Citra Biner

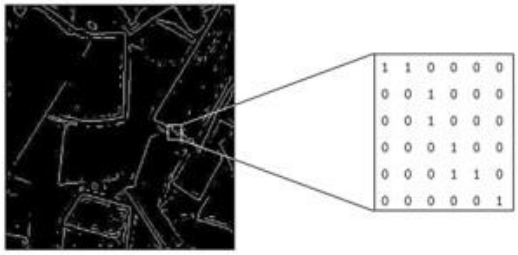

Gambar 2.4 Citra Biner dan Representasi Warnanya

Citra biner merupakan citra dengan tiap pikselnya hanya dinyatakan dengan dua kemungkinan nilai, yaitu nilai 0 (*off*) dan 1 (*on*) [27]. Pada nilai 0 (*off*) dinyatakan sebagai warna hitam sedangkan nilai 1 (*on*) sebagai warna putih. Penyimpanan citra biner dapat menggunakan tipe

double atau uint8 [27]. Jenis citra biner banyak digunakan dalam pengolahan citra, misalnya untuk untuk mendapatkan tepi bentuk pada objek. Representasi warna pada citra biner dapat dilihat pada Gambar 2.4 di atas.

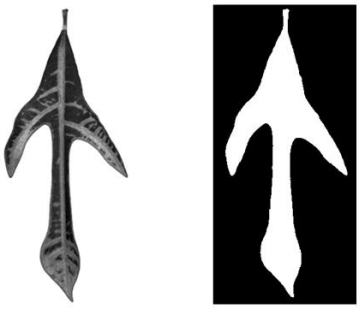

Gambar 2.5 Konversi Citra Daun Keabuan Menjadi Citra Biner [28]

Gambar 2.5 memperlihatkan perbedaan antara citra keabuan dengan citra biner. Gambar sebelah kiri menunjukkan citra daun dengan menggunakan citra *grayscale* sedangkan pada gambar sebelah kanan menunjukkan hasil dari konversi dari citra daun *grayscale* ke citra daun biner.

2.2.2.4. Citra Warna Berindeks

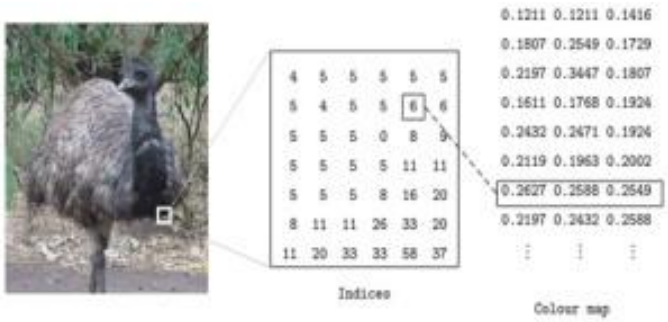

Gambar 2.6 Citra Berindeks dan Representasi Warnanya

Citra warna berindeks berguna pada sisi kenyamanan pada proses penyimpanan dan penanganan file citra tersebut [29]. Citra warna berindeks memiliki peta warna terkait dengan indeks warna dan indeks tersebut hanya menyimpan daftar dari warna-warna yang digunakan pada citra tersebut [29]. Nilai pada setiap piksel citra warna berindeks tidak mewakili warna yang diberikan melainkan hanya sebagai perwakilan dari indeks warna dan

representasi dari warna tersimpan dalam peta warna. Gambar 2.6 adalah ilustrasi representasi warna dari citra berindeks.

2.2.3. Pengenalan Pola

Pengenalan pola merupakan cabang ilmu dari kecerdasan buatan. Menurut Bow pada bukunya *Patter Recognition and Image Processing*, pengenalan pola sendiri proses dalam membuat kelas pada suatu data masukan yang diukur maupun diamati [30]. Menurut Sergios Theodoridis dan Konstantinos Koutroumbas dalam bukunya yang berjudul *Patter Recognition*, pengenalan pola merupakan disiplin ilmu yang memiliki tujuan dalam melakukan klasifikasi objek ke dalam sejumlah kelas atau kategori [31]. Objek ini dapat berupa gambar ataupun bentuk gelombang sinyal atau jenis pengukuran apa pun yang diperlukan dalam klasifikasi [31]. Menurut Hanif Al Fatta, pengenalan pola adalah cabang dari kecerdasan buatan yang difokuskan dalam melakukan klasifikasi suatu objek ke dalam kelas-kelas tertentu untuk menyelesaikan suatu masalah [32].

2.2.4. *Artificial Intelligent*

Kecerdasan buatan atau *artificial Intelligence* (AI) merupakan cara dalam menirukan keserdasan makhluk hidup ataupun benda mati dalam menyelesaikan suatu permasalahan [33]. Menurut Rich (1991) pada penelitian Kusumaningrum (2018) kecerdasan buatan adalah studi yang mempelajari mengenai cara membuat suatu komputer dapat melakukan apa yang dapat dilakukan manusia. Menurut McCarthy (1956) dalam penelitian Kusumaningrum (2018) *artificial Intelligence* (AI) bertujuan untuk mengetahui atau melakukan pemodelan pada proses cara berpikir manusia dan mendesainnya ke dalam suatu mesin sehingga mesin tersebut dapat menirukan perilaku manusia.

2.2.5. *Machine Learning*

Machine Learning merupakan salah satu cabang ilmu kecerdasan buatan (*Artificial Intelligent*) yang berfokus pada pengembangan sistem yang dapat belajar dengan sendirinya tanpa diperlukannya program berulang kali [34]. *Machine learning* menirukan cara manusia atau makhluk yang cerdas dalam mempelajari

berbagai hal. *Machine learning* juga dapat membantu suatu mesin atau komputer dalam memprogram diri mereka sendiri.

Pada dasarnya terdapat empat teknik pengaplikasian yang ada dalam *machine learning*, yaitu:

a. *Supervised Learning* adalah tipe algoritma *machine learning* yang menggunakan dataset yang dikenali atau *training* dataset dalam melakukan prediksi.
b. *Unsupervised Learning* merupakan tipe algoritma *machine learning* untuk mendapatkan suatu kesimpulan dari dataset yang terdiri dari inputan *data labeled response*.
c. *Semi-supervised Learning* adalah gabungan dari teknik *supervised learning* dan *unsupervised learning*. Dataset yang digunakan sebagian sudah memiliki label dan sisanya tidak.
d. *Reinforcement Learning* adalah model yang melakukan proses belajar dengan menggunakan metode *reward* dan penalti [34].

2.2.6. *Deep Learning*

Deep Learning merupakan bidang ilmu baru dalam bidang *machine learning* berbasis Jaringan Saraf Tiruan (JST) dan menyajikan komposisi transformasi dari data nonlinear [35][36]. *Deep Learning* baik digunakan dalam bidang visi komputer, salah satunya pada klasifikasi objek dengan menggunakan suatu citra gambar [37]. *Deep Learning* berkembang dengan adanya teknologi GPU (*Graphics Processing Unit*) *Acceleration*. Pada *Deep Learning*, komputer akan belajar melakukan klasifikasi secara langsung dari data berupa citra gambar atau suara [35]. Pada proses komputasi, selain menggunakan CPU dan RAM, *Deep Learning* juga menggunakan GPU sehingga ketika menemukan data yang besar, proses komputasi akan lebih cepat [35].

2.2.7. *Convolutional Neural Network*

Convolutional Neural Network (CNN atau CNN) adalah salah satu jenis algoritma pada *deep learning* perkembangan *Multilayer Perceptron* (MPL) yang digunakan untuk mengolah data dua dimensi, seperti gambar atau suara [35][36].

CNN adalah contoh dari *supervised learning*, karena menggunakan data latih dan data uji dalam melakukan klasifikasi. Algoritma ini didesain untuk dapat mengolah suatu data berdimensi besar sehingga sudah banyak diaplikasikan pada data berbentuk citra atau gambar [38] [39]. CNN memiliki kedalaman jaringan yang tinggi dan banyak digunakan pada data citra sehingga algoritma ini termasuk ke dalam bagian *deep neural network* [19].

Pada CNN dapat mempunyai banyak lapisan yang tiap lapisan belajar untuk mendeteksi berbagai citra gambar [35]. Pada umumnya terdapat tiga lapisan pokok pada CNN, yaitu lapisan *layer* konvolusi (*convolutional layer*), *pooling layer* dan *fully connected layer* [38]. Pada lapisan *layer* konvolusi dan pooling *layer* disebut sebagai lapisan ekstrasi fitur sedangkan pada lapisan *fully connected layer* adalah lapisan untuk klasifikasi [38]. Secara garis besar, berikut ini adalah bagian-bagian pada arsitektur CNN dapa dilihat pada Gambar 2.7 berikut.

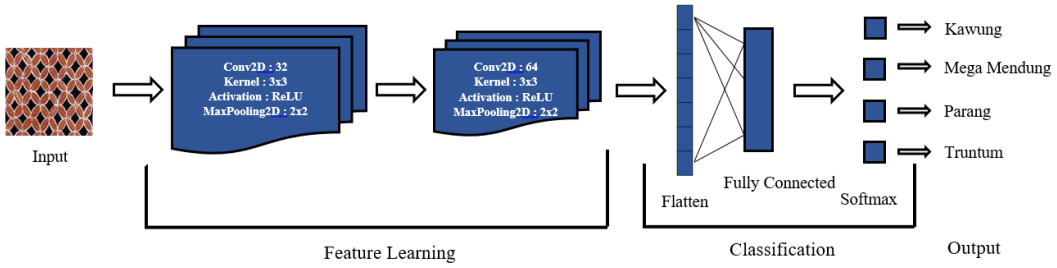

Gambar 2.7 Arsitektur CNN

Pada Gambar 2.7 adalah contoh arsitektur dari algoritma CNN yang dimulai dari input data citra kemudian dilakukan proses konvolusi dengan aktivasi ReLU dan *pooling* dan dilakukan beberapa kali dan masuk ke dalam proses terakhir, yaitu klasifikasi. *Feature Extraction* berguna dalam mendapatkan suatu informasi yang paling relevan dari sebuah citra masukan sehingga klasifikasi dapat dilaksanakan dengan baik [16]. Pada proses *feature extraction*, melakukan proses *encoding* pada sebuah citra menjadi *features* yang direpresentasikan dalam bentuk angka-angka. Pada *feature extraction* dilakukan tahapan lapisan konvolusi dan lapisan *pooling*. Sedangkan pada bagian *classification*, dilakukan tahapan *fully-connected layer* dalam melakukan klasifikasi data.

2.1.7.1. *Convolutional layer*

Lapisan ini berguna dalam pendeteksian fitur tertentu pada semua lokasi data citra masukan dan merupakan lapisan yang mengubah suatu data masukan menjadi *feature map* setelah dikonvolusi oleh filter [36]. Pada ilmu matematis, konvolusi sendiri merupakan jumlah hasil kali pada setiap elemen yang bersesuaian atau mempunyai posisi titik koordinat yang sama pada dua matriks atau vektor [19][40].

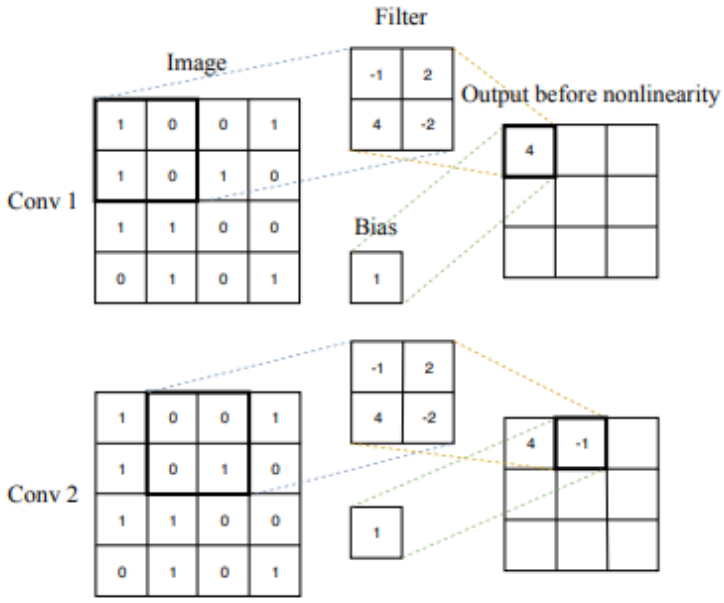

Gambar 2.8 Proses Konvolusi pada Sebuah Gambar [41]

Pada Gambar 2.8 terdapat filter berukuran 2x2 dan sebuah bias yang akan melakukan perkalian dengan citra masukan dari posisi kiri ke kanan, kemudian dari atas ke bawah secara berurutan hingga menghasilkan *feature-map* yang kemudian dikirim menuju *layer* selanjutnya [41].

2.1.7.2. *Pooling Layer*

Pada tahapan *pooling layer* terjadi proses reduksi atau pengurangan ukuran pada data citra [28]. Prinsip kerja *layer* ini dengan adanya suatu filter berukuran dan nilai *stride* tertentu yang kemudian berpindah posisi ke seluruh area *feature map*. Proses ini memiliki tujuan dalam meningkatkan invariansi dari posisi suatu fitur dan mempercepat proses dari komputasi

serta mengontrol adanya *overfitting* [19]. Pada *layer* ini, bertugas dalam mengurangi dimensi *feature map* dan berguna dalam melakukan pengekstrakan pada fitur yang penting dengan variasi posisi citra berbeda-beda sehingga pada proses *training* akan lebih efektif [19]. *MaxPooling* dan *AveragePooling* adalah *pooling* yang sering digunakan. Pada arsitektur model CNN, memilih jenis *pooling layer* yang banyak dapat menguntungkan kinerja model.

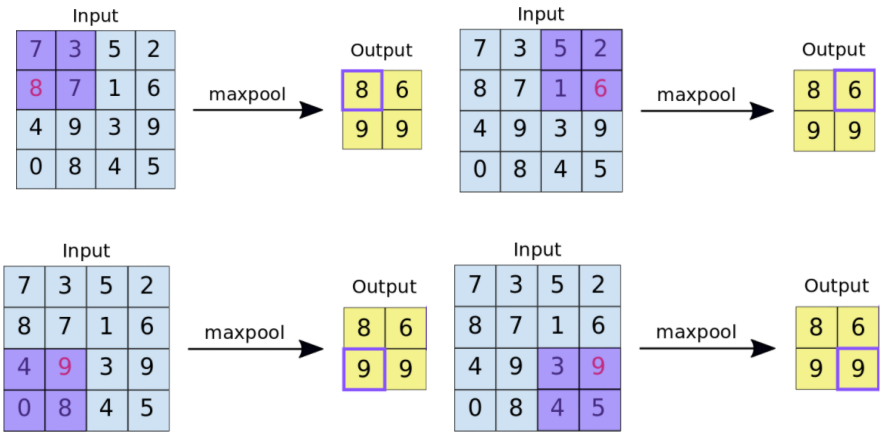

Gambar 2.9 Pooling dengan Menggunakan *MaxPooling* [28]

Pada Gambar 2.9 menunjukkan proses *MaxPooling* dengan menggunakan citra masukan berukuran matriks 4x4 piksel dan menghasilkan sebuah citra keluaran dengan ukuran lebih kecil, yaitu menjadi 2x2 piksel.

2.1.7.3. Fungsi Aktivasi

Fungsi aktivasi adalah suatu fungsi *non-linear* untuk memungkinkan jaringan syaraf tiruan dalam melakukan proses transformasi pada data masukan menjadi dimensi yang lebih tinggi, agar dapat melaksanakan proses pemotongan *hyperlane* yang sederhana. Hal ini memungkinkan dapat dilakukan suatu proses klasifikasi.

a. Aktivasi Fungsi ReLU

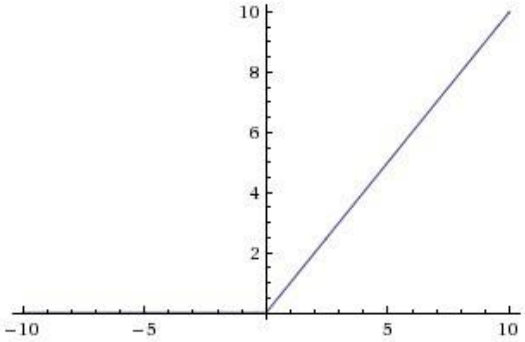

Gambar 2.10 Aktivasi ReLU

Berdasarkan Gambar 2.10 aktivasi ReLU atau *Rectified Linear Unit* adalah aktivasi model CNN yang menerapkan fungsi *f(x) = max(0, x)* yang memiliki arti bahwa fungsi ini melakukan proses *thresholding* dengan menggunakan nilai nol terhadap nilai dari tiap piksel pada gambar masukan [35][42]. Aktivasi ini akan membuat semua nilai piksel pada suatu citra yang bernilai kurang dari nol akan dijadikan bernilai nol. Aktivasi ReLU berfungsi mengurangi waktu dalam proses *Training* dan *Testing* pada jaringan yang memiliki jumlah neuron yang banyak.

b. Aktivasi Fungsi *Softmax*

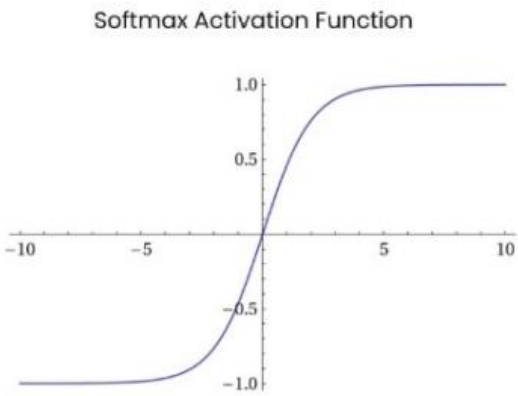

Gambar 2.11 Aktivasi *Softmax*

Berdasarkan Gambar 2.11 aktivasi fungsi *softmax* adalah fungsi untuk melakukan suatu perhitungan kemungkinan pada setiap kelas

yang memiliki kemungkinan tertinggi akan dijadikan sebagai prediksi hasil akhir [29]. Aktivasi *softmax* adalah bentuk lain dari *logistic regression* [43][44]. Standar klasifikasi pada *logistic regression* biasanya untuk melakukan klasifikasi lebih dari dua kelas sehingga memungkinkan dapat menghitung nilai kemungkinan pada semua kelas [35].

c. Flattening

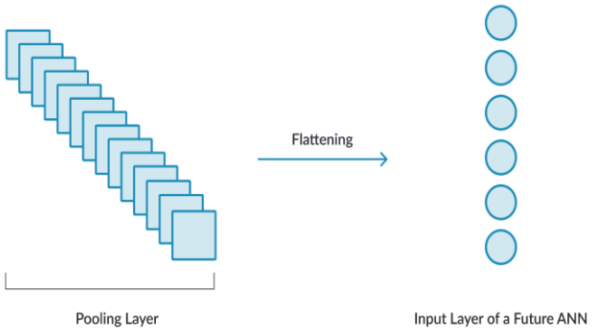

Gambar 2.12 *Flattening* [45]

Berdasarkan Gambar 2.12 *flattening* adalah operasi pembentukan ulang suatu fitur ataupun matriks masukan pada vektor satu dimensi. *Flattening* melakukan perubahan *feature map* hasil dari *layer* sebelumnya ke dalam vektor satu dimensi sehingga *feature map* tersebut dapat digunakan sebagai masukan untuk proses *fully connected layer* [17].

2.1.7.4. *Fully Connected Layer*

Fully-Connected Layer menerapkan *multilayer perceptron* dan melakukan proses transformasi dimensi suatu data sehingga dapat diklasifikasi secara liner [46]. Pada hasil akhir dari proses *feature extraction* masih dalam bentuk multidimensional *array* dan masih diperlukan proses *flatten* [19]. Hasil keluaran pada lapisan ini dapat membedakan fitur yang mendominasi dengan fitur yang kurang berpengaruh pada citra dan melakukan klasifikasi dengan teknik klasifikasi yang digunakan (*softmax*) [19].

2.1.7.5. Evaluasi Hasil

Evaluasi hasil dari model yang telah dilatih dapat dihutung nilai akurasi, presisi, dan *recall* dengan menggunakan *Confusion Matrix Multi-Class*. *Confusion Matrix Multi-Class* merupakan sebuah matriks yang dapat memberikan gambaran terhadap tingkat akurasi dan presisi dari suatu model. Dimensi pada *Confusion Matrix Multi-Class* mempunyai kelas lebih dari 2 sehingga ukuran matriknya lebih dari 2x2 tabel matriks. *Confusion Matrix* berisi terkait dengan informasi tentang nilai yang berdasarkan nilai aktualnya dengan nilai hasil dari prediksi maupun klasifikasi pada setiap kelasnya [47]. Gambaran mengenai *Confusion Matrix Multi-Class* dapat dilihat pada Tabel di bawah ini.

Tabel 2.2 *Confusion Matrix Multi-Class*

		Prediksi			
		A	**B**	**C**	**Total Aktual**
Aktual	**A**	TP (A)	FN (A) / FP (B)	FN (A) / FP (C)	nA (A)
	B	FN (B) / FP (A)	TP (B)	FN (B) / FP (C)	nA (B)
	C	FN (C) / FP (A)	FN (C) / FP (B)	TP (C)	nA (C)
Total Prediksi		nP (A)	nP (B)	nP (C)	N

Keterangan:

N	=	Jumlah banyaknya dataset
nA	=	Jumlah data actual untuk suatu kelas
nP	=	Jumlah data prediksi untuk suatu kelas
TP (*True Positive*)	=	Kondisi dimana data diprediksi bernilai positif dan benar sesuai dengan nilai actual
FN (*False Negative*)	=	Kondisi dimana data diprediksi bernilai negatif tetapi nilai aktualnya positif
FP (*False Positive*)	=	Kondisi dimana data diprediksi positif tetapi nilai aktualnya negatif

Perhitungan kinerja model dapat dilakukan dengan menghitung nilai dari *accuracy*, *precision*, dan *recall*. *Accuracy* merupakan presentase

dari ketepatan sistem saat bekerja pada klasifikasi data baru. *Precision* merupakan jumlah dari kelompok data yang relevan dari jumlah data yang ditemukan pada sistem. *Recall* merupakan alat ukur dalam tingkat efektivitas suatu sistem yang dibuat [4][19].

Berdasarkan Tabel 2.2 dapat dihitung nilai dari accuracy, presicion, dan *recall*. *Accuracy* dapat dihitung dengan menjumlahkan semua nilai TP kemudian dibagi dengan banyaknya data atau penjumlahan semua nilai pada kolom tabel. Perhitungan *accuracy* dapat dilihat pada Persamaan 2.5 di bawah ini.

$$Accuracy = \frac{\mathrm{TP\ (A)+TP\ (B)+TP\ (C)}}{\mathrm{N}} \tag{2.5}$$

Kemudian nilai dari *precision* dapat dihitung dengan nilai prediksi yang benar pada suatu kelas dibagi dengan total dari nilai prediksi yang ada pada kelas tersebut. Perhitungan *precision* dapat dilihat pada Persamaan 2.6 di bawah ini.

$$\mathrm{Precision} = \frac{\mathrm{TP\ (A)}}{\mathrm{nP\ (A)}} \tag{2.6}$$

Nilai *recall* dapat dihitung dengan nilai prediksi yang benar pada suatu kelas dibagi dengan total dari nilai aktual yang ada pada kelas tersebut. Perhitungan *recall* dapat dilihat pada Persamaan 2.7 di bawah ini.

$$\mathrm{Recall} = \frac{\mathrm{TP\ (A)}}{\mathrm{nA\ (A)}} \tag{2.7}$$

2.2.8. Teknik Regularisasi

Teknik regularisasi merupakan teknik untuk memodifikasi suatu model pada *neural network* untuk mengurangi *generalization error*. Ada beberapa jenis regularisasi yang dapat digunakan pada proses *training neural network* sebagai berikut:

2.2.8.1. L2-Regularization

L2-regularization disebut juga *ridge regression* atau *weight decay*. Teknik ini menambahkan nilai *norm penalty* pada suatu *objective function*.

Pemberian *norm* dilakukan hanya terhadap bobot saja dikarenakan besarnya suatu bobot mempengaruhi interaksi antar fitur. Bobot yang besar dapat berpengaruh terhadap sedikit perubahan fitur masukan maka diperlukannya penalti pada bobot tersebut. Semakin besar nilai bobot, maka semakin besar penalti begitupun sebaliknya [48].

2.2.8.2. *Dropout*

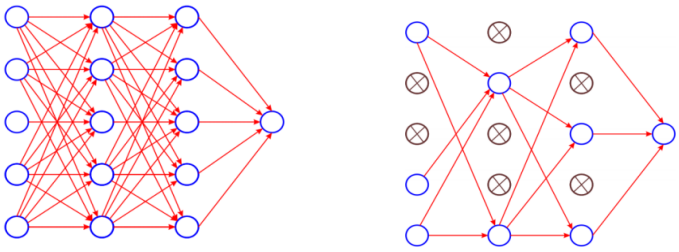

Gambar 2.13 Sebelum dilakukan *Dropout* (kiri) dan Setelah dilakukan *Dropout* (kanan) [28]

Dropout merupakan metode yang cukup sederhana dalam menghindari adanya *overfitting* pada jaringan saraf tiruan hingga *Deep Learning* dan juga mempercepat proses learning [38][17]. *Dropout* dapat menghilangkan secara sementara suatu *neuron* yang berupa *Hidden Layer* ataupun *Visibe Layer* pada jaringan. Hal ini dapat dilihat pada Gambar 2.13 di atas.

2.2.8.3. Augmentasi Data

Augmentasi data merupakan teknik pembuatan suatu data baru dengan memfaatkan data yang ada. Salah satu contoh penggunaan augmentasi data pada data citra adalah dilakukannya *flip*, *random cropping*, hingga rotasi pada citra asli. Augmentasi data dilakukan untuk mengurangi kasus *overfitting* karena biasanya data citra asli masih memiliki *noisy* sehingga membuat model tidak condong terhadap data yang terlalu ideal [48].

2.2.8.4. *Early Stopping*

Teknik ini dapat digunakan untuk mencegah *overfitting*. *Early stopping* merupakan teknik untuk memberhentikan proses pembelajaran

ketika terdapat perbedaan performa antara *training* dan *validation* melebihi batasan yang ditentukan [48].

2.2.9. *Hyperparameter*

Hyperparameter merupakan parameter yang dapat diubah atau disesuaikan agar dapat mengontrol proses pelatihan pada model. Contoh dari *hyperparameter* yang sering digunakan adalah *stride*, *padding*, *batch size*, fungsi aktivasi, jumlah *epoch*, dan jumlah *neuron* setiap lapisan [48]. Berikut penjelasan dari jenis dari *hyperparameter* yang digunakan pada penelitian ini:

2.2.9.1. *Stride*

Stride merupakan parameter yang digunakan untuk menentukan jumlah dari perpindahan suatu filter. Pemindahan posisi berapa piksel secara horizontal kemudian vertikal pada filter menyesuaikan dengan nilai dari *stride* yang digunakan. Semakin kecil nilai pada *stride* maka informasi yang didapatkan akan semakin banyak, akan tetapi waktu yang dibutuhkan dalam komputasi akan semakin lama. Penggunaan dari nilai kecil pada *stride* tidak selalu menghasilkan performa model yang bagus [18].

2.2.9.2. *Padding*

Padding atau *zero padding* merupakan parameter yang digunakan sebagai penentuan jumlah piksel bernilai 0 yang dimasukkan ke dalam setiap sisi dari citra masukan. Hal ini dilakukan untuk memanipulasi dimensi pada keluaran *layer* konvolusi. Dimensi keluaran menjadi sama seperti dimensi masukan atau tidak berkurang banyak. Padding dapat digunakan *layer* konvolusi secara mendalam dan memiliki banyak fitur yang di-*extract* dan dapat membuat performa pada model lebih meningkat.

2.2.10. Bahasa Pemrograman Python

Python adalah bahasa pemrograman yang cukup sederhana dan singkat. Bahasa pemrograman Pyhton adalah bahasa dengan perancangan yang fokus pada tingkat keterbacaan suatu kode yang ditulis [49]. Python juga mendukung pemrograman yang multi paradigma seperti pemrograman berorientasi objek, pemrograman fungsional dan *imperative program*. Python dapat digunakan pada

keperluan pengempangan perangkat lunak. Python dapat berjalan pada sistem operasi seperti; Linux/Unix, Windows, Java Virtual Machine, Amiga, Symbian (untuk produk Nokia) dan lain sebagainya.

2.2.11. Teknik Sampling

Teknik sampling atau pengambilan sampel dibagi menjadi dua yaitu *probability sampling* dan *non probability sampling*. *Probability Sampling* merupakan teknik pengambilan sampel yang memberikan kesempatan yang sama kepada setiap anggota populasi untuk dipilih menjadi sampel. Contoh dari *probability sampling* yaitu *simple random sampling*, *stratified random sampling*, *systematic sampling*, dan *cluster sampling* [12].

Non Probability Sampling merupakan suatu teknik pengambilan sampel yang tidak memberikan kesempatan yang sama kepada setiap anggota populasi yang dipilih menjadi sampel. Teknik pengambilan sampel ini diantaranya sampling *incidental*, sampling kuota, *snowball sampling*, dan *purposive sampling* [12]. *Purposive Sampling* adalah suatu metode sampling atau pengambilan sampel non random sampling yang mana peneliti memastikan pengutipan ilustrasi dengan menggunakan metode untuk menentukan identitas khusus yang cocok dengan tujuan dari penelitian sehingga diharapkan dapat menanggapi kasus pada penelitian tersebut [12]. Menurut Otoatmodjo (2010) *purposive sampling* adalah pengambilan ilustrasi yang bersumber pada suatu pertimbangan tertentu mengenai sifat-sifat dari populasi maupun identitas yang dikenalnya. Menurut Sugiyono (2010) *purposive sampling* adalah metode untuk memastikan ilustrasi dari penelitian dengan sebagian pertimbangan tertentu yang memiliki tujuan agar informasi yang didapatkan dapat lebih representative [12].