

## BAB II

### LANDASAN TEORI

#### 2.1. Tinjauan Pustaka

Pada penelitian ini, penulis meninjau pustaka atau literatur pada penelitian sebelumnya dan yang serupa. Peninjauan pustaka ini dilakukan sebagai bentuk pendukung penelitian yang dilakukan oleh penulis. Berikut dibawah ini tinjauan pustaka yang sudah diteliti sebelumnya dan serupa :

**Tabel 2.1** Tinjauan Pustaka

<b>Penulis</b>	<b>Judul</b>	<b>Metode dan Hasil</b>
Nur Fadlia, Rifki Kosasih (2019)	Klasifikasi Jenis Kendaraan Menggunakan Metode <i>Convolutional Neural Network (CNN)</i>	Hasil uji coba dan evaluasi model terhadap tiga jenis kendaraan menggunakan package Keras menunjukkan akurasi sebesar 94,4% pada tahap pelatihan dan 73,3% pada tahap pengujian.
Hamdani Mubarok (2019)	Identifikasi Ekspresi Wajah Berbasis Citra Menggunakan Algoritma <i>Convolutional Neural Network (CNN)</i>	Yang didapatkan dari hasil penelitian tersebut menunjukkan bahwa algoritma CNN cukup baik dalam melakukanidentifikasi ekspresi wajah dengan hasil akurasi <i>testing</i> sebesar 88,89%.

Tabel 2.2 Tinjauan Pustaka (Lanjutan)

Wulan Anggraini (2020)	<i>Deep Learning</i> Untuk Deteksi Wajah Yang Berhijab Menggunakan Algoritma <i>Convolutional Neural Network (CNN)</i> Dengan <i>Tensorflow</i>	Yang didapatkan dari hasil penelitian tersebut menunjukkan bahwa tingkat keakurasian dari deteksi wajah yang berhijab mendapat persentasi sebesar 90%.
Irzal Ahmad Sabilla (2020)	Arsitektur <i>Convolutional Neural Network (CNN)</i> Untuk Klasifikasi Jenis dan Kesegaran Buah Pada Neraca Buah	Yang didapatkan dari hasil penelitian Untuk tingkat akurasi modifikasi <i>fully connected</i> pada arsitektur CNN yaitu 96,3%, diikuti dengan CNN tanpa modifikasi <i>fully connected</i> yaitu 94%.
Triano Nurhikmat (2018)	Implementasi <i>Deep Learning</i> Untuk <i>Image Classification</i> Menggunakan Algoritma <i>Convolutional Neural Network (CNN)</i> Pada Citra Wayang Golek	Yang didapatkan dari hasil penelitian tersebut menunjukkan bahwa tingkat keakurasian dari implementasi <i>Deep Learning</i> adalah sebesar 93%.
Arham Rahim, Kusrini, Emha Taufiq Luthfi (2020)	<i>Convolutional Neural Network</i> untuk Klasifikasi Penggunaan Masker	Penelitian ini menghasilkan akurasi sebesar 96%. Studi ini menyoroti keefektifan CNN dalam mendeteksi penggunaan masker dengan potensi meningkatkan akurasi melalui algoritma optimasi yang lebih baik.

**Tabel 2.3** Tinjauan Pustaka (Lanjutan)

Rima Dias Ramadhani, dkk (2021)	Optimasi Akurasi Metode <i>Convolutional Neural Network</i> untuk Identifikasi Jenis Sampah	Penelitian ini menghasilkan akurasi awal metode CNN tanpa hyperparameters adalah 67,6%. Setelah dilakukan optimasi, akurasi metode CNN meningkat signifikan menjadi 91,2%.
---------------------------------------	--	--

### 2.1.1 Literatur 1

Penelitian oleh (Fadlia & Kosasih, 2019) membahas pengembangan sistem klasifikasi jenis kendaraan menggunakan metode Convolutional Neural Network (CNN), sebuah aplikasi penting dalam pengenalan objek untuk sistem parkir, pengawasan lalu lintas, dan keamanan. Menggunakan dataset pelatihan yang terdiri dari 120 gambar kendaraan (mobil, sepeda motor, dan sepeda), hasil pengujian menunjukkan akurasi sebesar 94,4% pada tahap pelatihan dan 73,3% pada tahap pengujian. Meskipun terdapat penurunan akurasi pada tahap pengujian, nilai tersebut tetap cukup tinggi untuk aplikasi klasifikasi jenis kendaraan. Dalam meningkatkan akurasi, penelitian merekomendasikan peningkatan jumlah data pelatihan, penggunaan model CNN yang lebih kompleks, dan penerapan metode ekstraksi fitur yang lebih baik. Sistem ini juga memiliki potensi untuk dikembangkan guna mengenali jenis kendaraan yang lebih spesifik, seperti mobil sport, sedan, dan pick-up.

### 2.1.2 Literatur 2

Penelitian oleh (Mubarok, 2019) ini membahas pengembangan sistem identifikasi ekspresi wajah berbasis citra menggunakan algoritma *Convolutional*

*Neural Network* (CNN). Dengan data pelatihan berupa 687 gambar wajah dan tujuh kelas ekspresi, hasil pengujian sistem menunjukkan akurasi sebesar 88,89%. Metode CNN digunakan dalam tahap ekstraksi fitur dan klasifikasi, dengan tahap post-processing menggunakan metode voting. Hasil uji pada 100 gambar wajah menunjukkan kemampuan sistem mengidentifikasi berbagai ekspresi dengan akurasi yang beragam. Sistem ini memiliki potensi aplikasi tinggi dalam identifikasi ekspresi wajah. Dalam meningkatkan akurasi, penelitian merekomendasikan peningkatan jumlah data pelatihan, penggunaan model CNN yang lebih kompleks, dan metode ekstraksi fitur yang lebih baik.

### **2.1.3 Literatur 3**

Penelitian oleh (Widia Anggraini, 2020) dalam "Jurnal Ilmiah Pendidikan Teknologi Informasi" membahas tantangan pengenalan wajah pada individu berhijab. Dengan menggunakan algoritma *Convolutional Neural Network* (CNN) dan *TensorFlow*, sistem ini berhasil mendeteksi wajah berhijab dengan akurasi mencapai 90,4%. Meskipun menghadapi kendala penutupan sebagian wajah oleh hijab, penelitian ini menunjukkan potensi aplikasi yang kuat untuk pengenalan wajah pada individu yang mengenakan hijab. Saran penelitian termasuk perluasan dataset, penggunaan model CNN yang lebih kompleks, dan eksplorasi metode deteksi wajah yang lebih akurat. Kemungkinan pengembangan sistem untuk mengenali jenis hijab tertentu juga diusulkan, memberikan manfaat tambahan dalam aplikasi pengenalan identitas.

### **2.1.4 Literatur 4**

Penelitian oleh (Sabilla, 2020) membahas pengembangan sistem klasifikasi jenis dan kesegaran buah menggunakan arsitektur *Convolutional Neural Network*

(CNN) dalam aplikasi pengenalan objek. Dengan menggunakan dataset pelatihan berupa 1.000 gambar buah (500 gambar buah segar dan 500 gambar buah tidak segar), hasil pengujian sistem menunjukkan akurasi sebesar 95,6%. Metode CNN digunakan dalam tiga tahap, yaitu ekstraksi fitur, klasifikasi jenis buah, dan klasifikasi tingkat kesegaran buah. Pengujian sistem dengan 100 gambar buah menunjukkan kemampuan sistem mengklasifikasikan jenis buah dengan akurasi 95% dan tingkat kesegaran buah dengan akurasi 96%. Sistem ini memiliki potensi untuk aplikasi klasifikasi jenis dan kesegaran buah, dan untuk meningkatkan akurasi, penelitian merekomendasikan peningkatan jumlah data pelatihan, penggunaan model CNN yang lebih kompleks, dan penerapan metode ekstraksi fitur yang lebih baik. Selain itu, sistem dapat dikembangkan untuk mengenali jenis buah yang lebih kompleks, seperti buah-buahan tropis dan buah impor.

### **2.1.5 Literatur 5**

Penelitian oleh (Nurhikmat, 2018) membahas pengembangan sistem klasifikasi citra wayang golek menggunakan algoritma *Convolutional Neural Network* (CNN). Wayang golek, sebagai seni tradisional Indonesia, memiliki karakteristik berupa wayang alus, wayang gagah, dan wayang punakawan. Dengan menggunakan dataset pelatihan berisi 1.000 gambar wayang golek, sistem mencapai akurasi 93% pada pengujian. Metode CNN diterapkan dalam tiga tahap: pra-pemrosesan, ekstraksi fitur, dan klasifikasi. Pengujian sistem dengan 100 gambar wayang golek menunjukkan kemampuan dalam mengklasifikasikan jenis wayang dengan akurasi tinggi untuk setiap kategori. Sistem ini dapat digunakan untuk aplikasi klasifikasi citra wayang golek, dan untuk meningkatkan akurasi, penelitian merekomendasikan peningkatan jumlah data pelatihan, penggunaan

model CNN yang lebih kompleks, dan penggunaan metode pra-pemrosesan yang lebih baik. Selain itu, sistem dapat dikembangkan untuk mengenali jenis wayang golek yang lebih kompleks, mencakup variasi jenis dari berbagai daerah di Indonesia.

### **2.1.6 Literatur 6**

Penelitian oleh (Rahim, Kusriani, & Taufiq Luthfi, 2020) ini bertujuan menerapkan *Convolutional Neural Network* (CNN) dalam mengklasifikasikan penggunaan masker sebagai respons terhadap pandemi COVID-19. Penulis menjelaskan bahwa COVID-19 dapat menyebar melalui droplet yang dihasilkan oleh batuk, bersin, atau berbicara, dan penggunaan masker diidentifikasi sebagai langkah pencegahan yang efektif. Dalam metodenya, penelitian menggunakan CNN dengan empat lapisan *convolutional*, dua lapisan *pooling*, dan satu lapisan *fully connected*. Dataset terdiri dari 1.000 citra wajah manusia dengan dua kelas menggunakan masker dan tidak menggunakan masker. Hasil penelitian menunjukkan bahwa CNN dapat mengklasifikasikan penggunaan masker dengan tingkat akurasi sebesar 96%. Keunggulan penelitian ini terletak pada penggunaan dataset yang cukup besar dan pengoptimalkan parameter CNN menggunakan algoritma *stochastic gradient descent*. Dalam diskusi, penelitian ini disoroti karena memberikan kontribusi penting dalam pengembangan teknologi deteksi penggunaan masker menggunakan pendekatan *machine learning*. Rekomendasi untuk peningkatan akurasi termasuk meningkatkan ukuran dataset, menggunakan lebih banyak lapisan *convolutional*, dan eksplorasi algoritma optimasi yang lebih baik.

### 2.1.7 Literatur 7

Penelitian oleh (Dias Ramadhani, 2021) mengidentifikasi jenis sampah menggunakan metode *Convolutional Neural Network* (CNN) dan menyoroti pentingnya pengelolaan sampah yang baik untuk mengurangi dampak negatif terhadap lingkungan. Sampah diklasifikasikan menjadi organik dan anorganik, di mana penguraiannya dapat diatur oleh mikroorganisme. Pemilahan sampah menjadi organik dan anorganik dapat mempermudah proses pengelolaan. Metode CNN, sebagai cabang dari machine learning, diaplikasikan dalam identifikasi jenis sampah melalui ekstraksi fitur dari citra sampah. Penelitian ini melibatkan optimasi akurasi metode CNN dengan menambahkan beberapa hyperparameters, seperti dropout, padding, dan stride, ke dalam arsitektur CNN. *Hyperparameters* ini berperan dalam mengatur perilaku CNN dan membantu mengatasi overfitting. Dataset penelitian terdiri citra sampah, dengan citra sampah organik dan citra sampah anorganik, yang diambil dari berbagai sumber, termasuk internet dan media sosial. Proses optimasi parameter CNN menggunakan algoritma stochastic gradient descent. Hasil penelitian menunjukkan bahwa akurasi metode CNN dapat ditingkatkan secara signifikan dengan penambahan *hyperparameters*. Akurasi awal tanpa *hyperparameters* sebesar 67,6%, dan setelah dilakukan optimasi, akurasi meningkat menjadi 91,2%. Kesimpulan penelitian menegaskan bahwa penambahan *hyperparameters* dapat berhasil meningkatkan akurasi metode CNN dalam identifikasi jenis sampah. Diskusi dari penelitian menekankan keberhasilan dalam mengoptimalkan akurasi metode CNN untuk identifikasi jenis sampah, yang memiliki implikasi positif dalam pengelolaan sampah secara efektif.

## **2.2. Pisang**

Pisang merupakan salah satu buah yang banyak di konsumsi dan diminati oleh masyarakat, karena buah pisang mempunyai kandungan gizi yang baik, pisang juga mengandung banyak karbohidrat, dimana karbohidrat ini adalah kandungan utama yang paling dibutuhkan oleh tubuh karena diolah didalam tubuh dan menjadikannya energi (Zainul, Rahayu, & Irawati, 2022).

Dengan banyaknya kandungan gizi yang bermanfaat untuk tubuh, pisang juga mempunyai beragam jenisnya, misalnya seperti Pisang Kepok, Pisang Raja, Pisang Ambon, Pisang Muli, Pisang Jantan, Pisang Susu, dan lain sebagainya. Pada penelitian ini hanya akan menggunakan tiga jenis Pisang saja, yaitu Pisang Jantan, Pisang Muli, dan Pisang Kepok.

### **2.2.1 Pisang Jantan**

Pisang jantan adalah salah satu jenis pisang yang banyak di konsumsi oleh masyarakat. Pisang Jantan memiliki bentuk ramping dan memanjang sedikit melengkung buah pisang jantan ini mempunyai panjang sekitar 15-20 cm , memiliki ukuran buah lumayan besar, berwarna kuning terang saat matang, daging buahnya tebal dengan warna putih kekuningan tekstur lembut, dan memiliki rasa manis. Pisang Jantan dapat dikonsumsi langsung ataupun diolah dahulu. (Hartati & Wibowo, 2017)





**Gambar 2.1** Pisang Jantan

### **2.2.2 Pisang Kepok**

Pisang kepok adalah salah satu jenis pisang yang terdapat di Indonesia dan banyak disukai oleh masyarakat Indonesia juga. Pisang kepok memiliki bentuk yang agak gepeng dan persegi dan kulit buahnya tebal. Panjang buahnya sekitar 10-15 cm, dengan diameter sekitar 5-7 cm. Kulit buahnya berwarna hijau cerah ketika masih muda, dan berubah menjadi kuning cerah ketika matang. Daging buahnya berwarna putih kekuningan dan memiliki tekstur yang padat. Rasa buahnya manis dan sedikit asam. (Hartati & Wibowo, 2017)




**Gambar 2.2** Pisang Kepok

### 2.2.3 Pisang Muli

Pisang muli adalah salah satu jenis pisang yang hanya ada di daerah Lampung, muli diambil dari Bahasa daerah Lampung yang artinya gadis yang belum menikah, yang secara etimologi sudah identic dengan Lampung (Nugroho, 2022).

Pisang muli memiliki bentuk yang ramping dan sedikit bulat, dengan panjang sekitar 9-12 cm. Kulit buahnya tipis dan berwarna hijau cerah ketika masih muda, dan berubah menjadi kuning cerah ketika matang. Daging buahnya berwarna putih kekuningan dan memiliki tekstur yang lembut. Rasa buahnya manis dan aromanya khas. (Hartati & Wibowo, 2017)



**Gambar 2.3** Pisang Muli

## 2.3 Citra Digital

Citra digital adalah sebuah representasi numerik (secara umum dikuasai biner) berdasarkan gambar dua dimensi. Sebuah gambar bisa didefinisikan menjadi fungsi dua dimensi  $f(x,y)$  pada mana  $x$  &  $y$  adalah titik koordinat bidang datar, & harga berdasarkan fungsi  $f$  berdasarkan setiap pasangan titik koordinat  $(x,y)$  yg diklaim menggunakan intensitas atau level keabuan (grey level)

berdasarkan suatu gambar. Ketika nilai titik  $x,y$  & nilai intensitas  $f$  terbatas menggunakan nilai diskrit, maka gambar tadi akan bisa dikatakan menjadi sebuah gambaran digital (Gonzales, Rafael, & Woods, 2002).

Berdasarkan penelitian (Putri, 2018) Digital Image atau Citra digital merupakan gambaran elektronika yg diambil berdasarkan beberapa jenis dokumen, yaitu berupa foto, buku, ataupun video & bunyi. Proses yg dipakai buat merubah gambaran analog sebagai suatu gambaran digital diklaim menjadi proses digitasi. Digitasi merupakan proses dimana membarui suatu gambar, teks, atau bunyi yang asal berdasarkan benda bisa dipandang ke pada data elektronika & bisa disimpan dan diperoses buat keperluan yang lainnya.

Dalam sebuah personal komputer , gambaran digital dipetakan sebagai bentuk grid & elemen piksel berbentuk matriks dua dimensi. Setiap piksel-piksel tadi mempunyai nomor yang mempresentasikan channel rona. Angka dalam setiap piksel disimpan secara berurutan sang sebuah personal komputer & tak jarang dikurangi buat keperluan kompresi juga pengolahan tertentu. Sebuah gambaran digital bisa mewakili sang sebuah matriks yg terdiri berdasarkan  $M$  kolom  $N$  baris, dimana perpotongan antara kolom & baris dianggap piksel. ( pixel = picture element ), yaitu elemen terkecil berdasarkan sebuah gambaran. Piksel memiliki 2 parameter, yaitu koordinat & intensitas atau rona. Nilai yang masih ada dalam koordinat  $(x,y)$  merupakan  $f(x,y)$ , yaitu akbar intensitas atau rona berdasarkan piksel pada titik itu. Oleh lantaran itu, gambaran bisa dituliskan kedalam sebuah matriks:

$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & \cdots & f(0,M-1) \\ f(1,0) & f(1,1) & \cdots & f(1,M-1) \\ \vdots & \vdots & \vdots & \vdots \\ f(N-1,0) & f(N-1,1) & \cdots & f(N-1,M-1) \end{bmatrix} \quad (2.1)$$

Berdasarkan persamaan (2.1) diatas, suatu citra  $f(x,y)$  dapat dituliskan kedalam fungsi matematis seperti berikut ini :

Dimana :

$$\begin{aligned} 0 &\leq x \leq M - 1 \\ 0 &\leq y \leq N - 1 \\ 0 &\leq f(x,y) \leq G - 1 \end{aligned} \quad (2.2)$$

$M$  = jumlah piksel baris pada array citra


$N$  = jumlah piksel kolom pada array citra

$G$  = nilai skala keabuan (grayscale)

Besarnya nilai  $M$ ,  $N$ , dan  $G$  biasanya merupakan perpangkatan dari dua seperti yang terlihat pada persamaan (2.3) berikut :

$$M = 2^m ; N = 2^n ; G = 2^k \quad (2.3)$$

Dimana nilai  $m$ ,  $n$ , &  $k$  adalah bilaingan positif. Interval  $(0,G)$  dianggap menggunakan (grayscale). Besarnya nilai  $G$  tergantung dalam proses digitalisasinya. Biasanya keabuan 0 (nol) menyatakan intensitas hitam & 1 (satu) menyatakan intensitas putih. Untuk gambaran 8 bit, nilai  $G$  sama menggunakan  $2^8 = 256$  warna (derajat keabuan) (Nurhikmat, 2018).



**Gambar 2.4** Representasi Citra Digital Dalam 2 Dimensi

(Nurhikmat, 2018)

## **2.4 *Machine Learning***

Machine learning adalah cabang dari kecerdasan buatan yang memungkinkan komputer untuk belajar dari data dan pengalaman tanpa harus secara eksplisit diprogram. Secara sederhana, ini adalah teknologi yang memungkinkan mesin untuk mengenali pola dan membuat keputusan berdasarkan data.

Machine learning, sebagai suatu disiplin ilmu dalam bidang kecerdasan buatan, mengalami perkembangan pesat dan memberikan solusi efisien untuk berbagai tantangan dalam klasifikasi, regresi, klustering, dan pendeteksian anomali di berbagai sektor. Sebagai contoh, dalam bidang kesehatan, pengenalan sel yang tidak normal dari citra CT Scan dapat memberikan bantuan signifikan kepada para dokter dalam proses diagnosis pasien. Penerapan machine learning dalam pengenalan jenis dan lokasi objek dari video digital atau citra satelit telah merambah ke berbagai bidang, termasuk keamanan wilayah, periklanan, manajemen bencana alam, dan sistem transportasi cerdas. Keberagaman aplikasi potensial dari machine learning telah mengilhami sejumlah besar penelitian dan pengembangan model serta teknologi baru, yang tercermin dalam jumlah publikasi dan prototipe produk teknologi cerdas yang terus bertambah. (Heryadi & Wahyono, 2020).

## **2.5 *Image Processing (Pengolahan Gambar/Citra)***

Pengolahan gambaran atau Image Processing merupakan suatu sistem dimana proses dilakukan menggunakan masukan (input) berupa gambaran (image) & hasilnya (output) jua berupa gambaran (image). Pada awalnya pengolahan gambaran ini dilakukan untuk memperbaiki kualitas gambaran, tetapi

menggunakan berkembangnya global komputasi yang ditandai menggunakan semakin meningkatnya kapasitas & kecepatan proses personal komputer , dan keluarnya ilmuilmu personal komputer yang memungkinkan insan bisa merogoh liputan menurut suatu gambaran maka image processing nir bisa dilepaskan menggunakan bidang computer vision (Hendy Mulyawan, M Zen Hadi Samsono, Setiawardhana, 2016).

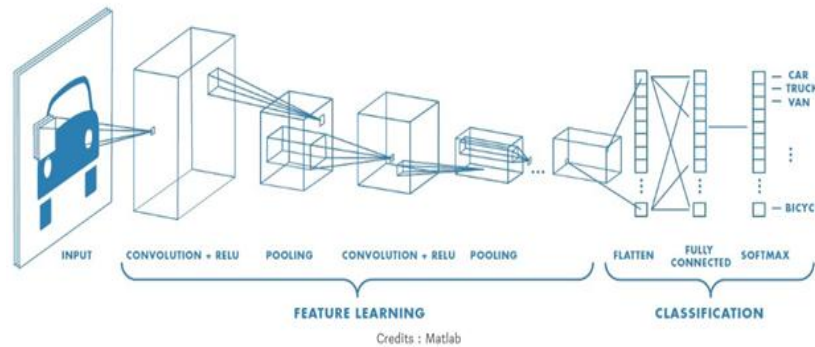
Pengolahan gambaran merupakan suatu proses pengolahan gambaran menggunakan memakai personal komputer sebagai sebuah gambaran yg mempunyai kualitas yang lebih baik. Tujuan menurut pengolahan gambaran ini merupakan memperbaiki kualitas suatu gambaran sebagai akibatnya bisa diinterpretasi menggunakan gampang oleh manusia atau atau sebuah mesin (personal komputer ) (Nurhikmat, 2018).

## **2.6 *Convolutional Neural Network***

*Convolutional Neural Network* adalah salah satu jenis neural network yang umumnya dipergunakan buat pengolahan data image (Santoso & Ariyanto, 2018). Convolutional Neural Network (CNN) merupakan salah satu prosedur pemecahan paling terkenal dipergunakan buat deep learning, sebuah machine learning yang contoh pembelajarannya dikhususkan untuk melakukan penjabaran pribadi di media 2 dimensi mirip gambar, video, teks atau suara. prosedur pemecahan CNN akan sangat bermanfaat khususnya ketika dipergunakan buat mencari pola pada suatu gambar lalu mengenali objek di gambar tersebut.

CNN dipakai buat melakukan pembagian terstruktur mengenai data yang berlabel menggunakan memakai metode supervised learning. Pada supervised learning sasaran yg dibutuhkan menurut input yang diterima jaringan sudah

diketahui sebelumnya (Warsito, 2009). Arsitektur CNN Neural network terdiri menurut aneka macam layer & beberapa neuron dalam masing-masing layer. Kedua hal tadi bisa dipengaruhi memakai anggaran yg niscaya & berlaku bhineka dalam data yang berbeda.



**Gambar 2.5** Arsitektur Convolutional Neural Network

(Nurhikmat, 2018)

Secara teknis, CNN adalah sebuah arsitektur yang dapat dilatih dan terdiri dari beberapa tahap. Masukan (*input*) dan keluaran (*output*) dari setiap tahap adalah terdiri dari beberapa array yang biasa disebut feature map. Setiap tahap terdiri dari tiga layer yaitu konvolusi, fungsi aktivasi *layer* dan *pooling layer* (Nurhikmat, 2018). Untuk menghitung *Feature Map* dapat menghitungnya dengan persamaan (2.4) dibawah ini :

$$w_1 \times h_1 \times d_1$$

$$w_2 \times h_2 \times d_2$$
(2.4)

Keterangan :

w : Lebar citra

h : Tinggi citra

d : Jumlah kanal RGB

CNN memiliki 4 hyperparameter seperti jumlah filter  $K$ , ukuran bidang reseptif atau  $F$ , lebar langkah atau  $S$ , dan zero padding  $P$ . Nantinya akan ada volume keluaran yang dihitung, dengan persamaan (2.5) dibawah ini :

$$\begin{aligned}
 w_2 &= \frac{(w_1 - F + 2P)}{S} + 1 \\
 h_2 &= \frac{(h_1 - F + 2P)}{S} + 1 \\
 d_2 &= k
 \end{aligned}
 \tag{2.5}$$

Keterangan :

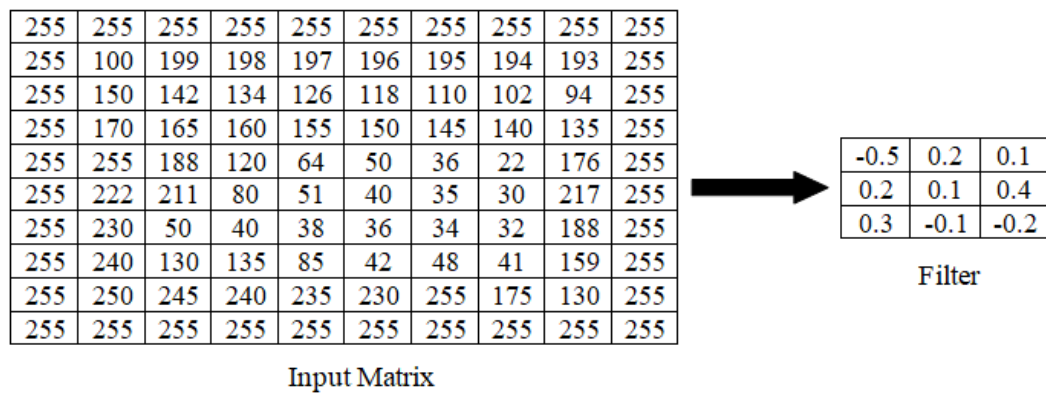
- w : Lebar citra
- h : Tinggi citra
- F : Ukuran bidang reseptif
- K : Ukuran matriks filter
- P : Ukuran padding
- S : Stride
- d : Jumlah kanal RGB

### 2.6.1 *Feature Extraction*

Keunggulan menurut CNN merupakan arsitektur yang bisa mengenali keterangan prediktif suatu objek (gambar, teks, rabat suara, & sebagainya) bila hanya objek tadi bisa diposisikan dimana saja dalam input. Keterlibatan CNN di *feature extraction layer* merupakan dalam *convolution & pooling layer*. *Convolution* bekerja menggunakan prinsip *sliding window & weight sharing* (mengurangi kompleksitas perhitungan). *Pooling layer* dipakai buat merangkum keterangan yang didapatkan untuk mengurangi ukuran dimensi dari hasil konvolusi. Sedangkan vektor output menurut beberapa operasi *Convolution & pooling* dalam multilayer perceptron dikenal menjadi *fully-connected layer* yg dipakai buat melakukan suatu pekerjaan (misal klasifikasi).

#### a. *Convolutional Layer*





**Gambar 2.6 Convolutional Layer**

Dapat dijelaskan bahwa dalam gambar 2.6 merupakan contoh proses konvolusi dengan input berupa citra satu channel. Pada gambar tersebut, sebuah citra berukuran 10x10 piksel direpresentasikan sebagai matriks. Pada layer konvolusi pertama, filter yang digunakan berukuran 3x3 dengan bobot yang telah ditentukan. Dan pada gambar 2.7 berikut merupakan hasil dari proses konvolusi.

62	195	179	179	179	179	179	179	166	109
127	133	92	91	91	90	89	89	79	-9.7
97	82	60	55	49	44	38	33	76	14
83	64	115	111	97	83	81	45	75	84
126	87	111	85	27	3.5	7.1	13	43	84
119	143	76	10	-4.1	11	8.9	70	119	63
117	59	38	-47	24	23	13	74	127	28
120	53	17	63	46	35	33	110	162	28
124	108	90	138	117	131	131	115	187	74
204	126	127	128	129	130	126	114	143	63

**Gambar 2.7 Hasil Konvolusi**

#### *b. Activation Relu*

Setelah melalui proses konvolusi, selanjutnya prosesnya adalah Fungsi aktivasi yang digunakan adalah reLu. Fungsi Activation ReLU pada prosesnya membuat pembatas pada bilangan nol, artinya apabila  $x \leq 0$  maka  $x = 0$  dan apabila  $x > 0$

maka  $x = x$ . Pada gambar 2.8 merupakan hasil dari proses setelah fungsi aktivasi reLu.

62	195	179	179	179	179	179	179	166	109
127	133	92	91	91	90	89	89	79	0
97	82	60	55	49	44	38	33	76	14
83	64	115	111	97	83	81	45	75	84
126	87	111	85	27	3.5	7.1	13	43	84
119	143	76	10	0	11	8.9	70	119	63
117	59	38	0	24	23	13	74	127	28
120	53	17	63	46	35	33	110	162	28
124	108	90	138	117	131	131	115	187	74
204	126	127	128	129	130	126	114	143	63

**Gambar 2.8** Fungsi Aktivasi reLu

### c. Pooling Layer

*Layer* ini terdapat sesudah *convolutional layer*. Terdiri berdasarkan sebuah filter menggunakan berukuran & stride eksklusif yang akan bergeser dalam semua activation map. Pooling yang dipakai merupakan *max & average pooling*. Misal kita pakai *average pooling* 2 x 2 menggunakan stride dua, maka disetiap pergeseran filter, nilai maksimum dalam area 2 x 2 pixel tadi yang akan dipilih, sedangkan *average pooling* akan menentukan nilai rata-ratanya. *Pooling layer* dipakai buat meningkatkan kecepatan komputasi lantaran parameter yg wajib pada update semakin sedikit & mengatasi *overfitting*. Sebelum melakukan pooling, dapat digunakan zero padding sehingga matriks hasil pooling berukuran 5x5. Pada Gambar 2.9 merupakan hasil dari proses *average pooling*.

129	135	135	134	89
81	85	68	49	62
119	71	10	23	77
87	29	32	57	86
140	120	126	121	116

**Gambar 2.9** Pooling Layer.

#### d. *Normalization layer*

*Normalization layer* (lapisan normalisasi) bermanfaat untuk mengatasi perbedaan rentang nilai yang signifikan pada citra masukan. Para ahli telah mengusulkan banyak jenis lapisan normalisasi (*normalization layer*). Namun, waktu ini lapisan *normalization* tak banyak digunakan secara simpel karena dampaknya yang cukup kecil atau bahkan tidak terdapat sama sekali.

#### d. *Fully connected layer*

Pada lapisan yang terhubung secara penuh (*fully connected layer*), setiap neuron mempunyai koneksi penuh ke seluruh aktivasi pada lapisan sebelumnya. Hal ini sama persis menggunakan yang terdapat dalam MLP. Model aktivasinya pun sama persis menggunakan MLP, yaitu komputasi menggunakan suatu perkalian matriks yang diikuti menggunakan bias offset.

Lapisan *fully connected layer* merupakan suatu lapisan yang terbentuk menurut formasi output proses konvolusi. Lapisan ini mempunyai input & proses sebelumnya buat memilih fitur manakah yang mempunyai interaksi atau hubungan menggunakan kelas tertentu. Selain itu fungsi yang diperoleh menurut *fully connected layer* berfungsi buat menyatukan seluruh node sebagai satu dimensi (Nurhikmat, 2018).

#### e. *Softmax Classifier*

*Softmax classifier* merupakan generalisasi buat beberapa kelas. *Softmax classifier* menaruh hasil yg sedikit lebih intuitif (probabilitas kelas yang dinormalisasi) & jua mempunyai interpretasi probabilistik yang akan eksklusif dijelaskan (Rosebrock, 2016). Tujuan menurut lapisan ini yaitu buat memprediksi hasil pembagian terstruktur mengenai pada bentuk nilai

probabilitas, dimana nilai probabilitas kelas terbesar adalah hasil prediksi kelas yang diperoleh. Softmax juga menaruh output yang lebih intuitif & mempunyai output interpretasi probabilistik yang lebih baik dibandingkan menggunakan prosedur pemecahan pembagian terstruktur mengenai lainnya. Softmax memungkinkan peneliti buat menghitung nilai probabilitas buat seluruh label. Hasil menurut label yang ada, akan diambil sebuah vektor nilai yg memiliki nilai riil & menggantinya sebagai vektor menggunakan nilai antara nol & satu. apabila seluruh output dijumlah maka akan bernilai satu.

## **2.7 Ekstraksi Ciri Warna RGB**

Pada prinsipnya, setiap gambar terbentuk dari piksel-piksel yang mempunyai ukuran intensitas warna masing-masing, sebaran warna pada setiap piksel ditunjukkan oleh histogram. Histogram memilih distribusi piksel yang didasarkan pada intensitas *gray-level* yang dimiliki pada masing-masing piksel. Penerapan histogram sebagai metode ekstraksi ciri didasarkan pada perbedaan sebaran piksel pada masing-masing gambar, dimana proses pertama pada ekstraksi ciri warna diawali dengan merubah tingkat warna RGB menjadi tingkat keabuan. Lalu, nilai warna keabuan dari masing-masing piksel yang Menyusun gambar dikelompokkan menjadi 8 kelompok rentang nilai piksel warna. Setiap kelompok mempunyai jumlah anggota kemudian dinormalisasi dengan cara dibagi dengan hasil perkalian Panjang dan lebar gambar (Sugiartha, Sudarma, & Widyantara, 2017).

## 2.8 Python

*Python* merupakan suatu bahasa pemrograman tingkat tinggi yang berjalan dengan sebuah sistem inteprated dan juga dapat dipakai untuk berbagai jenis tujuan. Mengapa disebut sebagai bahasa pemrograman tingkat tinggi karena perintah atau kode yang digunakan sangat mirip dengan bahasa manusia.

## 2.9 Pengujian *Confusion Matrix*

*Confusion Matrix* merupakan sebuah metode yang biasa dipakai buat perhitungan *accuracy*, *recall*, *precision*, & *error rate*. Dimana, *precision* mengevaluasi kemampuan sistem buat menemukan peringkat yang paling relevan, & didefinisikan menjadi presentase dokumen yang pada retrieve & sah-h Sahih relevan terhadap query. *Recall* mengevaluasi kemampuan sistem buat menemukan seluruh item yang relevan menurut koleksi dokumen & didefinisikan menjadi presentase dokumen yang relevan terhadap query. *Accuracy* adalah perbandingan perkara yang diidentifikasi sah menggunakan jumlah semua perkara dan *error rate* adalah perkara yang diidentifikasi galat menggunakan jumlah semua kasus (Arini, Wardhani, & Octaviano, 2020).

**Tabel 2.4** *Confusion Matrix*

	<b>Positif</b>	<b>Negatif</b>
<b>Positif</b>	<b>TP</b>	<b>FP</b>
<b>Negatif</b>	<b>FN</b>	<b>TN</b>

Isi dari tabel *confusion matrix* ada 4, yaitu :

- a) *True Positive*, kondisi dimana kelas yang sebenarnya adalah benar dan hasil prediksi juga mengatakan benar.
- b) *False Negative*, kondisi dimana kelas yang sebenarnya seharusnya adalah benar tapi hasil prediksi mengatakan salah.

- c) *True Negative*, kondisi dimana kelas yang sebenarnya adalah salah dan hasil prediksi juga mengatakan salah.
- d) *False Positive*, kondisi dimana kelas yang sebenarnya seharusnya salah, tetapi hasil prediksi mengatakan benar.

Persamaan yang akan dipakai dari data berdasarkan confusion matrix merupakan akurasi, presisi, recall & f-score. Berikut penjelasannya dibawah ini :

a. *Accuracy*

Akurasi adalah pengukuran seberapa sah sebuah sistem bisa mengklasifikasi berdasarkan keseluruhan. Akurasi bisa dihitung memakai Persamaan (2.6).

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (2.6)$$

b. *Precision*

Precision adalah rasio berdasarkan true positive menggunakan jumlah true positive & false positive. Precision yang tinggi menampakan model yang di-label positif merupakan memang positif. Precision dpaat dihitung menggunakan Persamaan (2.7).

$$Precision = \frac{TP}{FP + TP} \quad (2.7)$$

c. *Recall*

Recall adalah rasio berdasarkan true positive menggunakan jumlah true positive & false negative. Recall yang tinggi menampakan bahwa kelas berhasil dikenali. Recall bisa dihitung menggunakan persamaan (2.8).

$$Recall = \frac{TP}{TP + FN} \quad (2.8)$$

d. *F-Score*

Selain akurasi, precision dan recall, confusion matrix jua bisa dipakai buat menghitung F-Score yang bertujuan buat menghitung kombinasi berdasarkan precision dan recall. F-Score akan memakai harmonic mean berdasarkan precision dan recall. F-Score bisa dihitung menggunakan persamaan (2.9).

$$F\text{-Score} = 2 \cdot \frac{\text{precision} \cdot \text{recall}}{\text{Precision} + \text{recall}} \quad (2.9)$$