

## BAB II

### LANDASAN TEORI

Dalam penelitian ini terdapat beberapa teori yang digunakan untuk menunjang penelitian, teori-teori tersebut adalah :

#### 2.1. Tinjauan Pustaka

(Putra, Magdalena, dan Fuadah 2019) melakukan penelitian dengan judul '*Classification of Colon Cancer Using the Extraction Method of Principal Component Analysis and Classification Support Vector Machine*'. Penelitian ini bertujuan untuk menerapkan metode ekstraksi ciri *principal component analysis* dan klasifikasi *support vector machine* yang ditujukan untuk klasifikasi kanker usus dengan jumlah dataset sebanyak 108 data dan data uji 60 data, dengan demikian penelitian ini memiliki jumlah akurasi terbesar adalah 74,4%.

(Nour 2018) melakukan penelitian dengan judul '*Classification of Colon Cancer Using K-Nearesr Neighbor (K-NN) Method*'. Penelitian ini bertujuan untuk melakukan identifikasi penyakit kanker usus besar dengan tiga kelas klafisikasi dan menggunakan jumlah dataset sebanyak 198 data yang menggunakan metode *K-Nearesr Neighbor* ( KNN ) dan mendapatkan jumlah nilai akurasi terbesar adalah 68,52%.

(Sun et al. 2016) melakukan penelitian dengan judul '*Scene image classification method based on Alex-Net model*'. Penelitian ini dilakukan untuk menerapkan metode Alexnet pada gambar-gambar yang ada di alam bebas seperti pegunungan, laut, jalan, dan hutan yang bertujuan untuk mengelompokan gambar-gambar tersebut sesuai dengan kategori (gunung, pantai, jalan, dan hutan). Penelitian ini juga melakukan perbandingan akurasi pada metode *Deep Convolution Neural Network* ( DCNN ) yang dilakukan dengan metode HOG dan *K-Nearesr Neighbor* ( KNN ) yang ditunjukkan pada Tabel. akurasi yang diberikan seluruh gambar yang di uji pada ketiga metode tersebut metode DCNN memiliki akurasi yang lebih besar dibandingkan dengan HOG dan KNN.

(Minhas et al. 2019) melakukan penelitian dengan judul '*Shot classification of field sports videos using Alexnet Convolutional Neural Network*'. Penelitian ini

dilakukan dengan tujuan untuk dapat mengklasifikasikan pemotretan video olahraga dengan kategori pemotretan tembakan panjang, sedang, close-up, dan kerumunan dengan menggunakan metode Alexnet. Dengan akurasi rata-rata yang didapatkan sebesar 94,07% dari 10 video yang di uji dan melakukan perbandingan keakurasian dengan metode *standard convolutional neural networks*, *Support Vector Machine*, *K-Nearesr Neighbor*, *Centroid displacement-based K-Nearest Neighbors* (CDNN) dan *ELM classifier* dengan masing-masing rata-rata keakurasiannya adalah 90.885%, 76.64%, 92.5%, 90.75%, 73.45%. yang tidak lebih besar dari akurasi Alexnet.

(Xiao, Yan, dan Deng 2017) melakukan penelitian dengan judul '*Scene classification with improved Alexnet model*'. Penelitian ini dilakukan bertujuan untuk mengklasifikasi gambar pemandangan yang dimana memiliki kedalaman yang cukup besar dan untuk masalah yang terjadi penelitian ini melakukan peningkatan pada metode Alexnet dengan menambahkan beberapa *convolution layer*. Pada kesimpulan tentang peningkatan model Alexnet ini memiliki akurasi klasifikasi 5,17% lebih tinggi dari model ZFNet dan 8,81% lebih tinggi dari model arsitektur Alexnet untuk kategori klasifikasi gambar pemandangan SUN397 yang mengkonfirmasi bahwa model Alexnet yang ditingkatkan mengungguli model lainnya.

(Jiang et al. 2019) melakukan penelitian dengan judul '*Fusion of machine vision technology and Alexnet-CNNs deep learning network for the detection of postharvest apple pesticide residues*'. Penelitian ini bertujuan untuk dapat mengetahui sisa pestisida yang terdapat pada apel pascapanen yang memiliki empat residu pestisida yang diberi label sebagai A (*chlorpyrifos*), AB (dua pestisida campuran), B (*carbendazim*), dan K (kontrol tidak aktif), pada proses pendeteksian pada buah apel dilakukan proses ROI untuk segmentasi gambar agar menghilangkan data penting yang berlebihan yang nantinya hasil dari segmentasi ini baru akan dimasukkan pada proses Alexnet. Untuk penelitian ini akurasi yang didapatkan untuk mendeteksi residu pestisida yaitu sebesar 95,35% yang dibandingkan dengan proses *K-Nearesr Neighbor* dan *Support Vector Machine*

yang mendapatkan akurasi deteksi sebesar 43,75% yang dimana nilai ini jauh lebih rendah dari nilai akurasi model Alexnet.

(Shanthi dan Sabeenian 2019) melakukan penelitian dengan judul '*Modified Alexnet architecture for classification of diabetic retinopathy images*'. Penelitian ini bertujuan untuk dapat mengklasifikasi penyakit retinopati diabetik dimana para penderita penyakit diabet dapat kehilangan penglihatan mereka, dengan melakukan pemindaian pada retina sebagai objek yang diteliti maka dapat mengkategorikan kelas-kelas penyandang penyakit diabet pada tingkat yang berbeda-beda. Pada penelitian ini juga arsitektur Alexnet mendapatkan modifikasi yang disesuaikan dengan kebutuhan agar mendapatkan hasil yang lebih baik dengan menjadikan beberapa data gambar fundus sebagai acuan untuk akurasi pada algoritma Alexnet yang kemudian merubahnya agar mendapatkan hasil yang lebih baik dan hasil akhir dari penelitian ini mendapatkan nilai akurasi rata-rata sebesar 96,25%.

(Pal dan Saraswat 2018) melakukan penelitian dengan judul '*Enhanced Bag of Features Using Alexnet and Improved Biogeography-Based Optimization for Histopathological Image Analysis*'. Penelitian ini bertujuan untuk dapat menganalisis gambar histopatologi menggunakan metode Alexnet untuk mengekstraksi fitur dari gambar histopatologi, IBBO digunakan untuk menemukan kata-kata visual yang optimal dari *deskriptor fitur*, metode BOF yang dimodifikasi bersama dengan *Support Vector Machine* digunakan untuk mengklasifikasikan gambar histopatologi. Akurasi yang didapatkan dari tiga lipatan yang di pakai memiliki tingkat akurasi sebesar 92,42%.

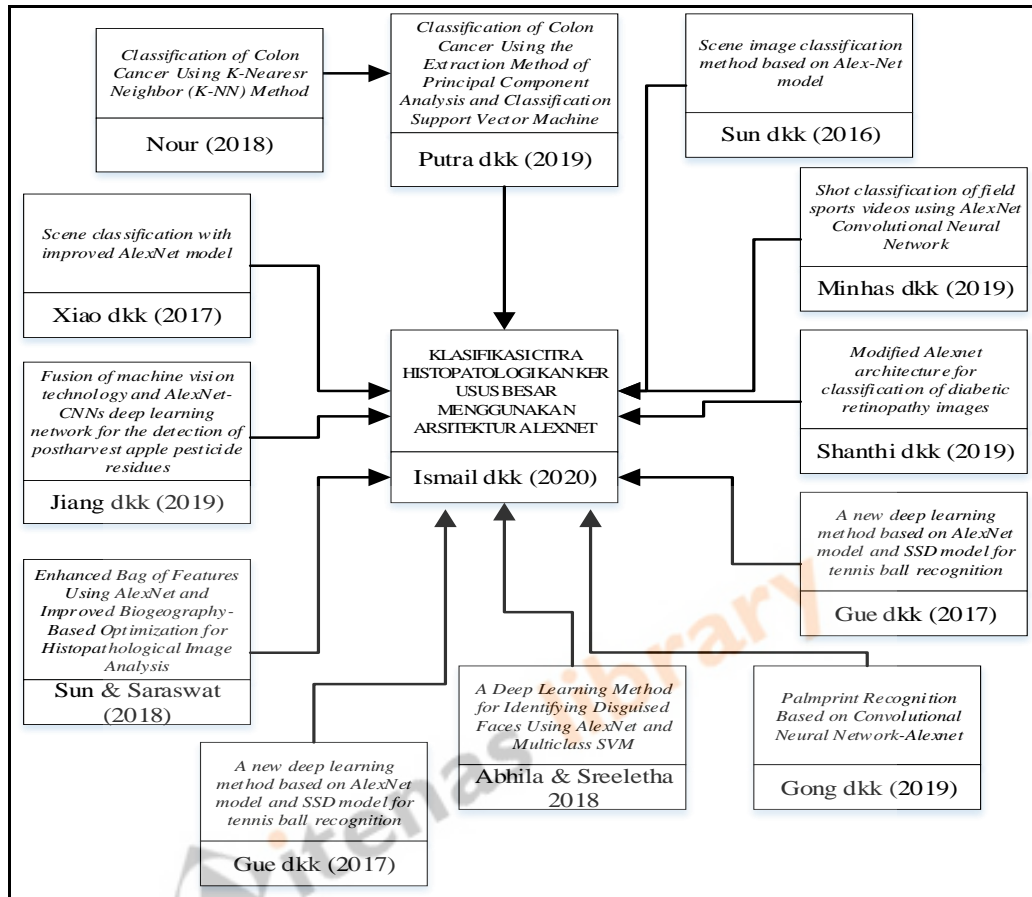
(Abhila dan Sreeletha 2018) melakukan penelitian dengan judul '*A Deep Learning Method for Identifying Disguised Faces Using Alexnet and Multiclass SVM*'. Penelitian ini bertujuan untuk dapat mengenali wajah yang disembunyikan, metode Alexnet digunakan untuk ekstraksi fitur wajah yang kemudian untuk tahap klasifikasi menggunakan metode *Multiclass SVM*. Penelitian ini menggunakan data-data wajah yang ditutupi oleh syal agar dapat menutupi sebagian dari wajahnya dan dilakukan pendeteksian identifikasi wajah yang diberikan pada kesimpulan penelitian untuk akurasi yang didapatkan yaitu akurasi tinggi walaupun tidak ada angka pasti yang tercantum pada kesimpulan akurasi yang didapatkan.

(Gu et al. 2017) melakukan penelitian dengan judul '*A new deep learning method based on Alexnet model and SSD model for tennis ball recognition*'. Penelitian ini bertujuan untuk dapat mengetahui apakah terdapat sebuah bola tenis pada gambar yang kemudian bola tersebut akan dicari posisinya, metode yang digunakan adalah Alexnet yang ditujukan untuk dapat menemukan sebuah bola tenis pada gambar yang di masukan, kemudian bola tersebut akan berusaha ditemukan kembali oleh model *Single Shot multibox Detector* (SSD) yang bertujuan untuk dapat menambah akurasi yang akan didapatkan dengan menggunakan dua model untuk menemukan sebuah bola tenis pada gambar yang dimana metode *Single Shot multibox Detector* (SSD) hanya akan bekerja jika pada proses Alexnet terdapat sebuah bola pada gambar.

(Gong et al. 2019) melakukan penelitian dengan judul '*Palmprint Recognition Based on Convolutional Neural Network-Alexnet*'. Penelitian ini bertujuan untuk meningkatkan keamanan melalui sidik jari atau *palmprint* (penggabungan antara fitur tekstur dengan garis pada telapak tangan) yang dimana menggunakan metode Alexnet sebagai proses ekstraksi fitur dan klasifikasi secara keseluruhan. Alexnet digunakan untuk pengenalan sidik jari dan tingkat pengenalannya dapat mencapai hingga 99,99% pada data uji yang merupakan suatu ide lain yang digunakan untuk pengenalan sidik jari.

(Zhang, Pan, dan Xiao 2018) melakukan penelitian dengan judul '*In-vivo Skin Capacitive Image Classification Using Alexnet Convolution Neural Network*'. Penelitian ini bertujuan untuk melakukan analisis gambar kapasitif kulit in-vivo agar dapat mengklasifikasikan karakteristik kulit seperti tingkat hidrasi, tingkat kerusakan, dll. Dengan hasil akurasi yang didapatkan sebesar 98,89% akan tetapi hanya memiliki tingkat persentase prediksi yang tidak terlalu tinggi yaitu sebesar 29,58% dan solusi dari masalah yang didapatkan yaitu meningkatkan jumlah data pelatihan.

Pada Gambar 2.1 merupakan peta penelitian dari tinjauan pustaka :



Gambar 2.1. Tinjauan pustaka

## 2.2. Histopatologi


Histopatologi merupakan sebuah pemeriksaan mikroskopis biopsi atau suatu sampel bedah yang digunakan untuk mempelajari tentang struktur jaringan, distribusi sel dalam jaringan, dan membentuk keteraturan sel untuk diagnosis penyakit. Proses manual ini akan memakan waktu, membutuhkan ahli patologi, dan kemungkinan memiliki banyak variasi ketika digunakan dalam pemeriksaan (Gurcan et al. 2009). Pada saat melakukan sebuah diagnosis penyakit kaitannya sangat penting dengan histopatologi karena merupakan salah satu pertimbangan dalam penegakan diagnosis melalui hasil pengamatan terhadap suatu jaringan yang diduga terganggu. Histopatologi dapat dilakukan dengan cara mengamati jaringan setelah kematian terjadi atau dengan pengambilan sampel jaringan misalnya seperti dalam penentuan kanker usus besar. Dengan melakukan sebuah perbandingan

kondisi jaringan yang sehat terhadap jaringan sampel, sehingga dapat diketahui atau dipastikan apakah suatu penyakit yang diduga benar-benar menyerang atau tidak.


### **2.3. Kanker Usus Besar**

Kanker usus besar atau sering disebut juga dengan kanker kolorektal adalah salah satu jenis kanker yang terjadi di permukaan usus besar (*colon*) dan rectum (bagian usus paling bawah) yang dipengaruhi oleh lingkungan dan gaya hidup yang tidak sehat. *Colon* atau rectum merupakan bagian usus besar pada sistem pencernaan yang berfungsi untuk menghasilkan energi bagi tubuh dan membuang zat yang tidak berguna untuk tubuh. Penyebab terjadinya kanker usus besar bisa dikarenakan oleh berbagai faktor seperti faktor makanan dengan protein dan lemak yang tinggi dan faktor genetik yang terkena usus besar. Kasus kanker usus besar yang sering terjadi yaitu pada usia 40-50 tahun dan rasio kejadian usus besar yaitu 2 : 1 antara laki-laki dan perempuan yang dimana kanker usus besar menjadi kasus kanker terbesar ketiga didunia dan juga kasus kematian terbesar kedua yang disebabkan oleh kanker (Bray et al. 2018).

Kanker usus besar memiliki berbagai kelas yang dapat terjadi yaitu *Adipose* (ADI), *background* (BACK), *debris* (DEB), *lymphocytes* (LYM), *mucus* (MUC), *smooth muscle* (MUS), *cancer-associated stroma* (STR), *colorectal adenocarcinoma epithelium* (TUM). Kanker *adenocarcinoma* adalah jenis kanker usus besar yang paling umum dijumpai dan merupakan salah satu jenis kanker ganas yang terjadi pada epitel mukosa saluran cerna usus besar sampai rectum. Contoh jaringan kanker adenocarcinoma ditunjukkan pada Gambar 2.2. dan jaringan usus besar normal ditunjukkan pada Gambar 2.3.



Gambar 2.2. Jaringan Usus Normal  
(sumber : Marx Alexander dkk, 2018)



Gambar 2.3. Jaringan Kanker Usus Adenocarcinoma  
(sumber : Marx Alexander dkk, 2018)

#### **2.4. Deep Learning**

*Deep learning* merupakan *subbidang* pembelajaran mesin yang berkaitan dengan sebuah algoritma yang terinspirasi dari struktur dan fungsi otak yang biasa disebut dengan jaringan sarap tiruan (Anon 2019). *Deep learning* merupakan suatu bidang turunan dari metode *machine learning* pada bidang *Artificial Intelligence* yang biasanya digunakan ketika melakukan klasifikasi terhadap objek-objek seperti citra, teks, maupun suara. Hal yang dapat dibedakan pada *deep learning* dan *machine learning* adalah penggunaan jumlah layer pada *deep learning* yang bisa mencapai ratusan layer sehingga dapat disebut '*deep*'. Pendekatan *deep learning*



dapat memungkinkan suatu komputer untuk dapat mempelajari suatu model yang terbilang cukup rumit dengan membangun suatu model yang dapat dikatakan sederhana. (Goodfellow, Bengio, & Courville, 2016)


*Artificial Neural Network* (ANN) merupakan pemodelan dari *deep learning* bentuk umum yang digunakan. Pada generasi pertama ANN hanya terdiri dari *simple layer perceptron* dan model ini terhambat oleh terbatasnya komputasi. Selanjutnya pada generasi kedua ANN terdapat kebaruan dengan menggunakan *backpropagation* yang bertujuan untuk dapat memperbaharui bobot neuron sesuai nilai *error*. Dan dari waktu ke waktu setelah banyak berubah dan kebaruan dari model tersebut mulailah bermunculan metode yang lahir dari dikembangkannya jaringan syaraf tiruan seperti *Convolutional Neural Network* (CNN), dan *Recurrent Neural Network* (RNN). (Minar dan Naher 2018).

## **2.5. Convolution Neural Network**

Algoritma *Convolutional Neural Network* adalah *perceptron multilayer* yang merupakan desain khusus untuk melakukan identifikasi informasi citra dua dimensi yang selalu memiliki lebih banyak lapisan seperti lapisan *input*, lapisan *convolution*, lapisan sampel dan lapisan keluaran. Keuntungan dari algoritma ini yaitu untuk menghindari eksplisit ekstraksi fitur dan secara implisit untuk belajar dari data pelatihan neuron yang sama pada bobot permukaan pemetaan fitur sehingga jaringan dapat belajar secara paralel, mengurangi kompleksitas jaringan, Mengadopsi struktur sub-sampel berdasarkan waktu atau ruang, dapat mencapai tingkat ketahanan, skala, dan deformasi perpindahan, informasi *input* dan topologi jaringan dapat menjadi pasangan yang sangat baik. Ini memiliki keunggulan unik dalam pengenalan suara dan pemrosesan gambar (Liu et al. 2015). CNN termasuk kedalam jenis *deep learning* karena kedalamannya dan juga termasuk pada cabang *machine learning* yang dapat mengajarkan komputer untuk dapat melakukan pekerjaan-pekerjaan manusia (Deng dan Yu 2013), CNN merupakan suatu operasi dari *convolution* yang menggabungkan lapisan-lapisan pemrosesan dengan menggunakan elemen yang beroperasi secara paralel dan salah satu teknik yang terinspirasi oleh sistem sarap biologis (Hu et al. 2016).



Struktur dari *Convolutional Neural Network* (CNN) terdiri atas *input*, ekstraksi fitur, klasifikasi, dan *output*. Dalam proses ekstraksi fitur terdapat beberapa lapisan yang tersembunyi atau sering disebut dengan *hidden layer* yaitu pada proses *convolution*, aktivasi *Rectified Linear Unit* (ReLU), dan *pooling*. CNN bekerja secara hierarki yang dimana pada prosesnya hasil dari lapisan *convolution* pertama akan dijadikan masukan pada lapisan *convolution* selanjutnya dan pada proses klasifikasi terdiri dari *fully-connected* dan *soft-max* yang akan mengeluarkan hasil berupa hasil klasifikasi (Katole et al. 2015). Seperti yang ditunjukkan pada Gambar 2.4.




Gambar 2.4. Convolutional Neural Network  
(Sumber : MathWorks)

## 2.6. Arsitektur Alexnet

Alexnet merupakan arsitektur dari CNN (*Convolutional Neural Network*) yang lahir melalui penelitian yang dilakukan oleh Alex Krizhevsky dkk, dari University of Toronto pada ajang kompetisi ILSVRC (*ImageNet Large Scale Visual Recognition Competition*) yang diadakan oleh ImageNet pada tahun 2012 yang sekaligus memenangkan kompetisi pada tahun tersebut dengan menghasilkan tingkat *error* sebesar 16,4%.

Jaringan arsitektur Alexnet lebih dalam dari CNN standar yang terdiri dari 8 *layer* di mana pada *layer* ini dibagi menjadi dua bagian *layer*. Dengan lima *layer* pertama yaitu lapisan operasi *convolution* diikuti oleh tiga lapisan *fully-connected layer* pada *layer* kedua. (Minhas et al. 2019). Pada *fully-connected layer* digunakan sebuah operasi *soft-max* yang berfungsi untuk melakukan klasifikasi citra terhadap label yang sudah ada. Pada ILSVRC studi kasus yang dilakukan adalah *output* dari lapisan terakhir *fully-connected layer* yang menghasilkan 1000 *class label* yang

dilakukan menggunakan operasi *soft-max* 1000 macam (Krizhevsky, Sutskever, dan Hinton 2017). Gambaran arsitektur Alexnet ditunjukkan oleh Gambar 2.5.



Gambar 2.5. Arsitektur Alexnet  
(Sumber : Krizhevsky et al. (2012))

Namun bukan hanya jumlah layer yang sedikit yang membuat Alexnet unik, ada beberapa fitur yang digunakan yang merupakan pendekatan baru untuk *convolutional neural network*

- *Rectified Linear Unit nonlinearity*

Alexnet menggantikan fungsi tanh yang merupakan standar pada waktu itu dengan menggunakan *Rectified Linear Unit* (ReLU). Keuntungan dari penggunaan fungsi ReLU ini yaitu pada saat dalam proses *training* yang dimana pada sebuah *convolutional neural network* yang menggunakan proses ReLU mampu mencapai 25% kesalahan pada data CIFAR-10 enam kali lebih cepat dari pada *convolutional neural network* yang hanya menggunakan tanh

- *Multiple GPUs*


Dulu GPU yang biasa dipakai untuk proses *training* masih berputar-putar dengan menggunakan memori 3 gigabyte dan akan sangat buruk ketika dipakai karena data yang dipakai *training* berjumlah 1,2 juta gambar yang merupakan jumlah yang sangat besar. Kemudian Alexnet memungkinkan untuk menggunakan multi-GPU pada saat proses *training* dengan menempatkan setengah neuron model pada satu GPU dan setengah lainnya pada GPU lainnya. Ini bukan berarti hanya

dapat melatih model yang lebih besar, tetapi juga akan menghemat waktu proses *training*.

- *Overlapping pooling*

*Convolutional neural network* secara tradisional “*pool*” keluaran dari kelompok neuron yang saling berdekatan tanpa *overlapping*. Namun ketika Alexnet memperkenalkan tentang *overlap*, mereka dapat melihat pengurangan pada kesalahan sekitar 0,5% dan menemukan bahwa model dengan *overlapping pooling* umumnya sulit ditemukan untuk *overfit*.

Untuk *overlapping pooling* yang penggunaan proses *max pooling* yang berulang atau bisa disebut dengan tumpang tindih seperti terlihat pada Gambar 2.6 dimana pada proses *convolution 1*, *convolution 2*, dan *convolution 3* terdapat proses *max pooling*.



Gambar 2. 6. Overlapping Pooling

- *Dropout*

*Dropout* merupakan metode yang digunakan Alexnet untuk masalah *overfitting*, teknik *dropout* terdiri dari “mematikan” neuron dengan probabilitas yang sebelumnya sudah ditentukan yang berarti untuk setiap iterasi menggunakan sampel parameter model yang berbeda, yang memaksa untuk setiap neuron harus memiliki fitur yang lebih kuat yang dapat digunakan dengan neuron acak lainnya.

### 2.5.1. Data Processing

*Data processing* merupakan proses yang sangat penting untuk *deep learning* terutama untuk *neural network*, saat akan melakukan proses data pelatihan sangat penting untuk melakukan proses *preprocessing* terlebih dahulu. Tujuan *preprocessing data* adalah untuk menjadikan data mentah agar lebih mudah untuk diterima oleh *neural network*. Pada tahap awal proses *preprocessing* adalah melakukan *resize* untuk mengubah ukuran citra dengan memperkecil ukuran citra

menjadi ukuran 244x244 piksel. Hal ini dilakukan karena ukuran 224x224 dapat menjangkau sepenuhnya sisi terkecil dalam pelatihan dan untuk menyamakan ukuran dari setiap citra yang digunakan selama proses *training* dan pengujian (Simonyan dan Zisserman 2015). Kemudian melakukan *Normalized* data yaitu normalisasi piksel citra dengan mengubahnya mejadi nilai piksel antara 0 sampai 1.

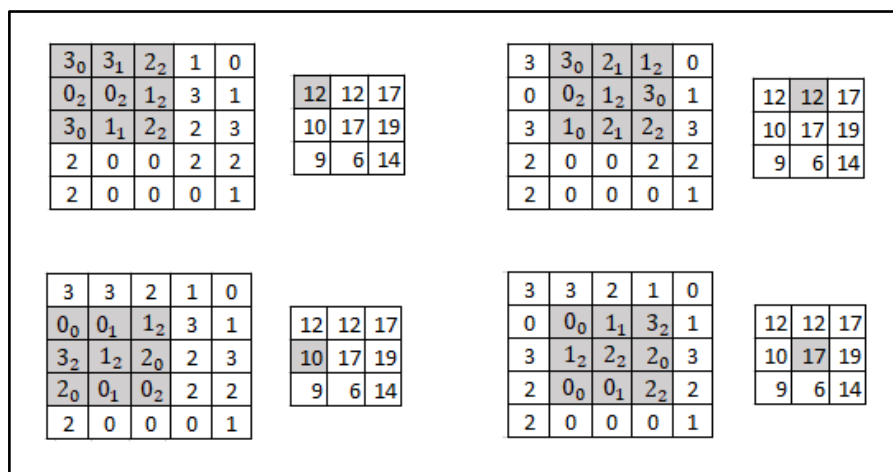
$$\boxed{\text{Img}/=255} \dots\dots\dots(2.1)$$

Dimana :

Img = nilai matriks dari citra

### 2.5.2. Convolution Layer

*Convolution layer* merupakan blok pertama dalam proses *Convolution Neural Network* (CNN) yang didalamnya terdapat beragam filter yang diinisialisasikan secara acak untuk melakukan *convolution* yang berfungsi sebagai ekstraksi fitur yang digunakan untuk mempelajari representasi fitur dari suatu citra. *Convolution* didefinisikan sebagai suatu proses agar dapat memperoleh suatu piksel yang didasarkan pada nilai piksel itu sendiri dan tetangganya dengan melibatkan operasi matriks yang disebut kernel (Kusumanto, Tompunu, dan Pambudi 2011). Keluaran dari hasil *convolution* pertama akan dijadikan masukan untuk *convolution* selanjutnya (Castelluccio et al. 2015). Pada Gambar 2.7 merupakan ilustrasi dari operasi *convolution*.



Gambar 2.7. Ilustrasi Operasi Convolution

(Sumber : (Dumoulin and Visin 2016))

### 2.5.3. Rectified Linear Unit ( ReLU ) Layer


*Rectified Linear Unit* (ReLU) merupakan suatu lapisan pada model *Convolution Neural Network* (CNN) dengan fungsi aktivasi  $f(x) = \max(0, x)$  (Mukhopadhyay dan Mukhopadhyay 2018), yang dimana fungsi ini dapat dikatakan sebuah proses *thresholding* dengan menjadikan nilai *input* bernilai 0. Nilai *output* dari neuron bisa dinyatakan bernilai nol jika masukannya bernilai *negative* dan jika nilai masukannya bernilai *positive* maka keluarannya akan tetap sama dengan nilai awal atau tidak diubah menjadi nilai lain (Kim et al. 2016). Ilustrasi operasi ReLU dapat dilihat pada Gambar 2.8.

$$f(x) = \max(0, x) \begin{cases} x, & \text{if } x \geq 0 \\ 0, & \text{if } x < 0 \end{cases} \dots\dots\dots(2.2)$$

Dimana :

$f(x)$  = nilai ReLU activation

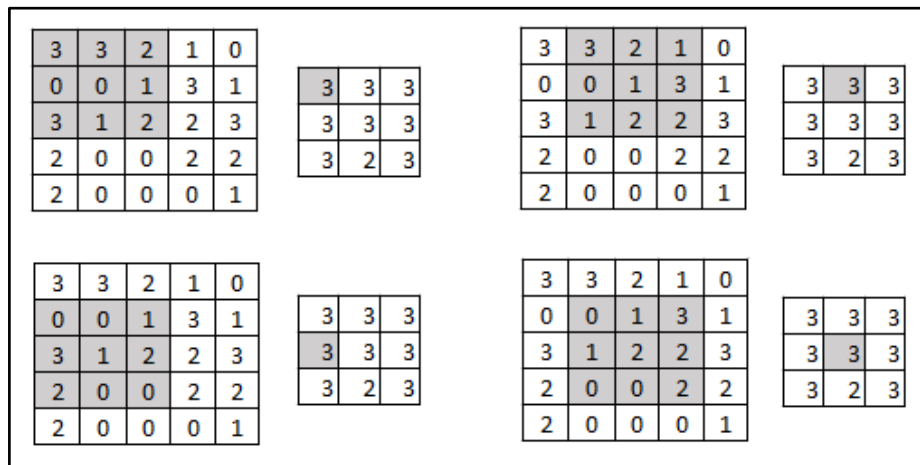
$x$  = nilai matriks citra



Gambar 2.8. Ilustrasi Operasi ReLU

### 2.5.4. Pooling Layer


*Pooling layer* merupakan lapisan yang menggunakan masukan dengan *feature map* dan proses yang dilakukan dalam *pooling* menggunakan berbagai macam operasi *statistic* berdasarkan dengan nilai piksel terdekat. Terdapat dua jenis *pooling* yang biasanya sering digunakan yaitu *average pooling* dan *max pooling* (Bejiga et al. 2017) dengan perbedaan pada *average pooling* nilai yang diambil adalah nilai rata-rata, sedangkan pada *max pooling* adalah nilai maksimal (Zhi et al. 2016). Pada Gambar 2.9 merupakan ilustrasi dari operasi *max pooling*.



Gambar 2.9. Ilustrasi Operasi Max Pooling  
(Sumber : (Dumoulin dan Visin 2016))

### 2.5.5. Fully Connected Layer

*Fully Connected layer* merupakan lapisan yang biasanya digunakan dalam penerapan *Multi Layer Perceptron* dan ditujukan untuk melakukan proses transformasi pada dimensi data agar dapat diklasifikasikan secara linear dan merupakan kumpulan dari hasil proses *convolution* (Hijazi et al. 2015). *Input* dari proses ini merupakan keluaran dari proses sebelumnya yang digunakan untuk menentukan fitur yang paling berkorelasi dengan kelas-kelas tertentu seperti terlihat pada Gambar 2.10, dan fungsi dari lapisan ini sendiri adalah untuk menggabungkan semua node menjadi satu dimensi (Albelwi dan Mahmood 2017).



Gambar 2.10. Ilustrasi Fully-Connected  
(Sumber : MathWorks)

### 2.5.6. Soft-max Activation

*Soft-max* merupakan lapisan terakhir yang digunakan untuk proses klasifikasi hasil akhir karena proses-proses sebelumnya menghasilkan suatu nilai yang diinterpretasi sebagai nilai probabilitas dan untuk ini fungsi *soft-max* akan

menghasilkan *output* yang merupakan kisaran nilai antara 0 sampai 1, dengan jumlah probabilitas keseluruhan adalah 1 (Vedaldi dan Lenc 2015).

$$\hat{y} = \frac{\exp(x_i)}{\sum_j \exp(x_j)} \dots\dots\dots(2.3)$$

Dengan :

$\hat{y}$  = hasil dari fungsi softmax

$x_i$  = kelas ke  $i$  ( $i=1,2\dots$ ). pada penelitian ini memakai 2 kelas

