

## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1 Bunga Anggrek**

Bunga anggrek merupakan salah satu jenis bunga yang varietasnya sangat banyak tumbuh alami di Indonesia. Sejarah perjalanan bunga anggrek di Indonesia sudah tercatat sejak tahun 1869 saat ditemukan di Borneo. Bunga anggrek sampai sekarang sangat populer di kalangan masyarakat Indonesia karena keanggunan dan keindahannya. Oleh karena itu, bunga anggrek memiliki daya tarik baik dari segi sejarah dan edukasi (Clarissa and Halim, 2019). Anggrek merupakan family terbesar yang menempati 7-10% tumbuhan berbunga yang ada di Dunia Anggrek yang ada di Indonesia diperkirakan terdapat 4.000-5.000 jenis. Indonesia merupakan Negara yang menyimpan kekayaan plasma nutfah anggrek paling besar di Dunia. Dari sekitar 26.000 varietas, Indonesia memiliki sekitar 6.000 varietas tanaman anggrek dunia. Indonesia merupakan Negara tropis dan memiliki kondisi lingkungan yang memenuhi syarat untuk menjamin kehidupan tanaman anggrek. Tanaman anggrek di Indonesia diperkirakan ada sekitar 5.000 jenis, karena anggrek memiliki nilai jual tinggi sehingga kolektor dan pembisnis berniat untuk mengoleksi anggrek sebagai tanaman hias, dikarenakan bunga anggrek memiliki bentuk bunga yang sangat beragam dan memiliki daya tarik untuk dikoleksi. Sehingga banyak kolektor dan pembisnis membuat penangkaran anggrek karena penangkaran juga termasuk dalam konservasi ek-situ dimana konservasi ek-situ mempunyai fungsi utama yaitu sebagai fungsi ekologi serta fungsi social ekonomi dan social budaya (Rinaldi and Rita, 2020).

##### **2.1.1 Anggrek *Dendrobium***

Anggrek *dendrobium* merupakan salah satu kelompok anggrek epifit terbesar didunia, anggrek ini terdiri atas 1.400 spesies. Kata *dendrobium* berasal dari bahasa Yunani "*dendros*" dan "*bios*" yang berarti pohon kehidupan. Bunganya cantik penuh warna-warni dan tahan lama, batang dan daunnya yang

kuat membuat anggrek *dendrobium* digemari banyak orang. *Dendrobium* biasanya berbunga dua kali setahun. *Dendrobium* merupakan anggrek simpodial, yaitu anggrek yang membentuk rumpun dan akar dalam jumlah cukup banyak disetiap batang semunya (AgroMedia, 2008). Berikut ini beberapa jenis dari anggrek *dendrobium* :

a. *Dendrobium Stratiotes*

Kelebihan lain dari **anggrek dendrobium stratiotes** ini adalah rajin berbunga dan tahan lama, bisa sampai 3 bulan dari pertama kali mekar. Ciri khas dari bunga *Dendrobium Stratiotes* ini memiliki bentuk petal seperti tanduk yang sedikit melintir berwarna hijau menyerupai tanduk. Bagian sepalnya berwarna putih, dikombinasi dengan guratan warna ungu berdasar putih pada lidah bunga



Gambar 2. 1 *Dendrobium Stratiotes*

b. *Dendrobium Taurinum* (Anggrek Banteng)

Bunga anggrek banteng termasuk dalam golongan anggrek epifit yang sebagian besar hidup di habitat hutan bakau. Anggrek ini berasal dari Kepulauan Maluku, Indonesia dan Filipina. Dinamakan anggrek banteng karena kelopaknya yang melingkar mirip dengan tanduk banteng. Kelopaknya berwarna lavender yang kemudian berubah ungu menjelang tua, sedangkan putiknya berwarna putih. Bagian tengah bunga berwarna putih sedangkan pinggirannya berwarna ungu gelap. Setiap kali berbunga dapat berkembang hingga 20 bunga bahkan lebih. Bunganya dapat berukuran 5 cm sampai 6,5 cm. Pseudobulb (umbi palsu)

anggrek ini berbentuk silindris berukuran panjang hingga 1,5 cm dan 2,5 cm. Daunnya bulat panjang, lebar, dan mengilap, serta berwarna hijau tua.



Gambar 2. 2 *Dendrobium Taurinum*

c. *Dendrobium Nindii*

*Dendrobium nindii* juga disebut sebagai Nind's Dendrobium, *The Blue Antler Orchid*, *Dendrobium ionoglossum*, *Dendrobium ionoglossum* var. *pomatophilum*, *Dendrobium jofftii*, *Dendrobium toftii*, *Durabaculum ionoglossum*. Anggrek ini memiliki nama latin *Durabaculum nindii* yang termasuk spesies dari marga *Dendrobium*. Spesies ini dideskripsikan oleh Walter Hill pada tahun 1874. *Dendrobium nindii* pertama kali ditemukan di Queensland Utara dan Papua New Guinea. Anggrek ini tumbuh di pepohonan, termasuk bakau dan palem, di rawa-rawa pesisir dan hutan hujan yang terdapat di ketinggian 200 dpl. Di Indonesia, jenis dendrobium inilah yang paling banyak dikenal masyarakat sebagai dendrobium keriting.

SI



Gambar 2. 3 *Dendrobium Nindii*

## 2.2 Pengertian Citra

Citra yaitu suatu komponen yang memiliki peranan begitu penting sebagai suatu bentuk yang berasal dari informasi visual (Furqan, Sriani, and Siregar, 2020). Sedangkan citra menurut kamus Webster yaitu suatu kemiripan, gambaran, dari objek benda, misalnya suatu hasil gambar milik seseorang yang berasal dari kamera tersebut, foto sinar X-thorax yang diambil untuk mewakili gambar dari bagian tubuh seseorang dan lain-lain (Gulo, 2016).

Citra merupakan gambaran dari sesuatu hal yang berupa objek. Citra adalah *output system* dalam perekaman data dan bersifat optic berupa foto yang bersifat analog ataupun sinyal video seperti gambar pada layar televise, atau bersifat digital yang dapat langsung disimpan pada suatu media penyimpanan (Supriadi et al. 2017).

## 2.3 Jenis Citra

Ada dua jenis citra yaitu citra analog dan citra digital, berikut penjelasan mengenai citra analog dan citra digital:

### 2.3.1 Citra Analog

Citra analog adalah citra yang bersifat berkelanjutan, seperti gambar pada monitor televise, lukisan, foto sinar-X, foto yang tercetak dikertas, foto pemandangan, hasil CT scan, gambar-gambar yang terekam pada pita kaset, dan lain-lain merupakan citra analog. Citra analog tidak dapat diproses dikomputer secara langsung dan tidak dapat dipresentasikan didalam komputer. Oleh karena itu agar citra dapat diproses oleh komputer, maka dilakukan konversi citra analog ke citra digital (Sutoyo, 2009).

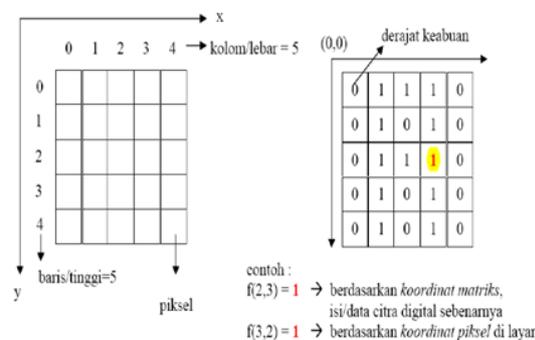
### 2.3.2 Citra Digital

Citra digital merupakan citra yang dihasilkan dari pengolahan dengan menggunakan komputer, dengan cara merepresentasikan citra secara numerik dengan nilai-nilai diskret. Pada umumnya citra digital berbentuk empat persegi panjang, dan dimensi ukurannya dinyatakan dalam tinggi kali lebar atau panjang kali lebar. Sama halnya Proses digitalisasi dalam bentuk data lain, proses

digitalisasi pada citra juga merupakan proses pengubahan suatu bentuk data citra dari yang bersifat analog ke digital. Yang mana proses ini dihasilkan dari peralatan digital yang langsung bisa diproses oleh komputer (Ashari, Latif, and Astuti, 2019).

Citra digital merupakan suatu matriks dimana indeks baris dan kolomnya menyatakan suatu titik pada citra tersebut dan elemen matriksnya (yang disebut sebagai elemen gambar/piksel/piksel/picture element/pels) menyatakan tingkat keabuan pada titik tersebut. Citra digital dinyatakan dengan matriks berukuran  $N \times M$  (baris/tinggi =  $N$ , kolom/lebar =  $M$ ) (Jannah, Santoso, and Christyono, 2018).

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



Gambar 2. 4 Matriks Citra Digital

(Jannah et al. 2018)

Berdasarkan bentuknya, Citra digital dapat dikelompokkan menjadi 3 jenis, yaitu:

- RGB (*Red, Green, Blue*). Untuk citra RGB masing-masing pixel mempunyai sebuah warna khusus. Warna dideskripsikan oleh kombinasi komponen warna merah (*Red*), hijau (*Green*) dan biru (*Blue*) masing-masing komponen warna mempunyai range antara 0- 255, sehingga total range warna yang digunakan untuk citra RGB adalah 16.777.216.

- b. Citra abu-abu (*Grayscale*). Untuk citra abu-abu masing-masing pixel memiliki nilai normal 0 (hitam) sampai 255 (putih) yang dapat direpresentasikan oleh nilai 8 bit atau 1 byte.
- c. Citra Biner. Setiap pixel hanya mempunyai warna hitam dan putih yang memiliki nilai 0 untuk hitam dan 1 untuk putih.

## 2.4 Pengolahan Citra Digital

Pengolahan citra digital (*Digital Image Processing*) merupakan bidang ilmu yang mempelajari tentang bagaimana suatu citra itu dibentuk, diolah, dan dianalisis sehingga menghasilkan informasi yang dapat dipahami oleh manusia, sedangkan histogram citra adalah representasi grafik yang menyatakan distribusi nilai-nilai warna atau intensitas piksel-piksel di dalam citra. Frekuensi kemunculan nilai intensitas piksel pada suatu citra dapat diketahui melalui pengolahan citra histogram citra tersebut (Ratna, 2020).

### 2.4.1 Operasi Pengolahan Citra

Operasi-operasi yang dilakukan dalam mengolah citra digital banyak macamnya. Namun, secara umum operasi pengolahan citra digital dapat diklasifikasikan dalam beberapa jenis, yaitu :

#### 1. Perbaikan kualitas citra (*Image Enhancement*)

Jenis operasi ini bertujuan untuk memperbaiki kualitas citra dengan cara memanipulasi parameter pada citra. Dengan operasi ini, ciri-ciri khusus yang terdapat dalam citra dapat lebih ditonjolkan. Contoh operasi perbaikan citra :

- a. Perbaikan kontras
- b. Perbaikan tepian objek (*edge enhancement*)
- c. Penajaman (*sharpening*)
- d. Pemberian warna semu (*pseudocoloring*)
- e. Penapisan derau (*noise filtering*)

#### 2. Restorasi Citra

Operasi ini bertujuan untuk menghilangkan kecacatan pada citra. Bedanya dengan perbaikan citra adalah penyebab degradasi gambar diketahui. Berikut adalah contoh restorasi citra:

- a. Penghilangan kesamaran (*debluring*)
- b. Penghilangan derau (*noise*)

### 3. Kompresi Citra

Jenis operasi ini dilakukan agar citra dapat direpresentasikan dalam bentuk yang kompak atau solid sehingga memerlukan memori yang lebih sedikit. Hal yang penting yang harus diperhatikan dalam kompresi gambar adalah ketika gambar dikompres, maka gambar itu harus mempunyai kualitas gambar yang baik.

### 4. Segmentasi Citra

Jenis operasi ini bertujuan untuk memecah suatu citra kedalam beberapa segmen dengan suatu kriteria tertentu. Jenis ini berkaitan dekat dengan pengenalan pola.

### 5. Analisis Citra

Pada operasi ini proses yang dilakukan adalah menghitung besaran kuantitatif dari citra untuk menghasilkan deskripsinya. Teknik analisis citra dengan cara mengekstraksi ciri tertentu untuk membantu dalam identifikasi objek.

Berikut contoh analisis citra :

- a. Deteksi tepi ( *edge detection* )
- b. Ekstraksi batas ( *boundary* )
- c. Representasi daerah ( *region* )

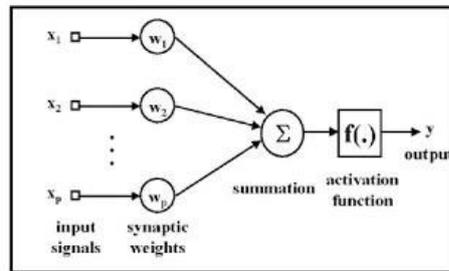
### 6. Rekonstruksi Citra

Pada operasi ini proses yang dilakukan untuk membentuk ulang objek dari beberapa citra hasil proyeksi. Operasi rekonstruksi citra banyak digunakan dalam bidang medis.

## 2.5 *Artificial Neural Network*

*Artificial neural network* (ANN) merupakan metode *machine learning* yang memiliki tiga hingga empat layer. Layer-layer tersebut dinamakan multilayer perceptron (MLP). Bagian dari MLP yaitu, *input layer*, *hidden layer*, dan *output layer*. Tiap layer memiliki banyak neuron. Neuron dapat memiliki input yang

sama, namun bobotnya berbeda. secara sederhana, sebuah neuron dapat dicontohkan pada gambar berikut.



Gambar 2. 5 Neuron pada Artificial Neural Network (Setiawan, 2021)

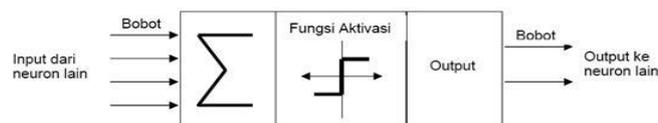
$$V_k = \sum_{j=1}^m w_{kj} x_j \quad (2.2)$$

$$Y_k = \varphi (v_k + b_k) \quad (2.3)$$

Dengan input  $x_1 \dots x_m$ , bobot  $w_{k1} \dots w_{km}$ , bias  $b_k$ , output  $v_k$  merupakan hasil perkalian antara input dan bobot ditambahkan dengan bias, fungsi aktifitas  $\varphi$  dan output setelah aktivasi  $y_k$ . Aktivasi digunakan untuk mengaktifkan dan menonaktifkan neuron (Setiawan, 2021).

a. *Neural Network* (Jaringan Syaraf Tiruan)

Jaringan Syaraf Tiruan (JST) merupakan pemodelan pembelajaran mesin (*Machine Learning*), yang menggunakan pendekatan belajar secara terbimbing (*supervised*) dan pendekatan belajar secara tidak terbimbing (*unsupervised*) (Armansyah, 2021). *Neural network* merupakan kategori ilmu *Soft Computing*. *Neural network* bekerja dengan mengadopsi prinsip dari kemampuan otak manusia yang mampu memberikan stimulasi/ rangsangan, melakukan proses, dan memberikan output (Batubara and Awangga, 2020).



Gambar 2. 6 Struktur Neural Network (Batubara and Awangga, 2020)

Fungsi dari *neural network* diantaranya adalah:

1. Pengklasifikasian pola.
2. Mengatur pola yang didapat dari input kedalam pola baru pada output.

3. Memetakan pola-pola yang sejenis.
4. Pengopyimasi permasalahan.
5. Prediksi.

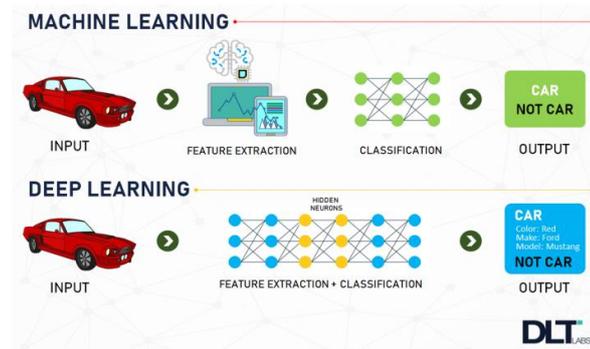
### **2.5.1 Machine Learning**

*Machine learning* merupakan teknik yang dilakukan oleh mesin atau aplikasi dalam mempelajari data untuk tujuan mengelompokkan, mengklasifikasikan ataupun memprediksi masa depan. Dengan kata lain mesin atau aplikasi dapat melakukan berbagai tugas manusia seperti mengelompokkan, mengklasifikasikan sesuatu dalam kategori tertentu, serta melakukan prediksi melalui pembelajaran terhadap data-data yang terpola. (Armansyah and Ramli, 2022). Metode pada machine learning dibagi menjadi 4 yaitu:

1. *Supervised learning*, data yang diujicobakan telah memiliki label.
2. *Unsupervised learning*, data yang diujicobakan belum memiliki label.
3. *Semi supervised learning*, data yang diujicobakan kombinasi dari *supervised* dan *unsupervised*.
4. *Reinforcement learning*, menciptakan sebuah agent yang akan mencari keputusan terbaik.

### **2.5.2 Deep Learning**

*Deep learning* merupakan bagian dari *machine learning* yang melakukan pembelajaran secara hirarki. Metode ini merupakan pengembangan dari *artificial neural network* pada *machine learning*. *Deep learning* melakukan pembelajaran yang terdiri dari banyak layer. Layer awal menghasilkan fitur sederhana hingga layer akhir menghasilkan fitur-fitur yang lebih kompleks. *Deep learning* diaplikasikan pada teknik klasifikasi, clustering, segmentasi ataupun *recognition*. *Deep learning* cocok untuk data yang tidak terartur seperti teks, suara dan citra (Setiawan, 2021).



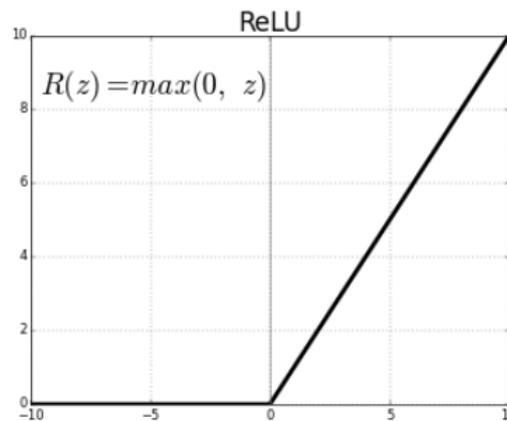
Gambar 2. 7 Machine Learning vs Deep Learning (Setiawan 2021)

*Deep learning* merupakan teknik machine learning yang mengajarkan komputer untuk belajar dari data. *Deep learning* melakukan pembelajaran mendalam dengan data besar dan *network* dengan jumlah *layer* hingga ratusan. Semakin banyak sistem melakukan pembelajaran terhadap data semakin baik sistem melakukan pengenalan. Data dapat dikenali dari fitur-fitur yang dimilikinya. Data dapat terdiri dari citra (*image*), teks, dan suara (*signal*). *Deep learning* dapat melakukan pengenalan dengan akurasi tinggi bahkan dapat melebihi pengenalan yang dilakukan oleh manusia. *Deep learning* membutuhkan dua syarat utama yaitu data besar dan diproses pada komputer dengan *High-Peromance Graphical Processing Unit* (GPU) (Setiawan, 2021).

### 2.5.3 Fungsi Aktivitas

Fungsi aktivitas berfungsi untuk menentukan apakah neuron tersebut harus aktif atau tidak berdasarkan dari *weighted sum* dari inputan. Pada umumnya terdapat 2 jenis fungsi aktivitas pada *neural network* yaitu, linear dan non-linear *activation function* (Batubara and Awangga, 2020).

## 1. ReLU (*Non-Linear*)



Gambar 2. 8 ReLU  
(Batubara and Awangga, 2020)

Aktivitas ReLU pada dasarnya melakukan treshold dari 0 hingga *infinity*. ReLU juga berfungsi untuk menutupi kelemahan yang dimiliki oleh *Sigmoid* dan *Tanh* (Batubara and Awangga, 2020).

## 2. *Softmax*

Fungsi *softmax* adalah fungsi eksponensial yang dinormalisasi untuk mengubah vektor asli D-dimensi dengan nilai riil yang berubah-ubah menjadi vektor probabilitas D-dimensi dengan nilai riil dalam kisaran (0,1). Fungsi *softmax* biasanya diterapkan ke bidang pembelajaran mesin, seperti regresi logistik, jaringan saraf tiruan, pembelajaran penguatan. Fungsi *softmax* dapat digunakan untuk menghitung nilai dari probabilitas untuk semua label.

### 2.5.4 Algoritma *Backpropagation*

Menurut Cilimkovic (2015) *backpropagation* merupakan algoritma untuk mencari nilai minimum dari *loss function* dalam bobot (*weight*) menggunakan teknik yang disebut aturan delta atau gradient descent. Bobot yang meminimalkan *loss function* kemudian dianggap sebagai solusi untuk masalah pembelajaran.

Algoritma *backpropagation* dapat dibagi kedalam empat langkah berikut:

1. Perhitungan *feed-forward*.
2. *Backpropagation* ke lapisan *output*.
3. *Backpropagation* ke lapisan tersembunyi (*hidden*).

#### 4. Pembaruan bobot (*weight*).

Algoritma dihentikan jika ketika nilai fungsi kesalahan sudah cukup kecil.

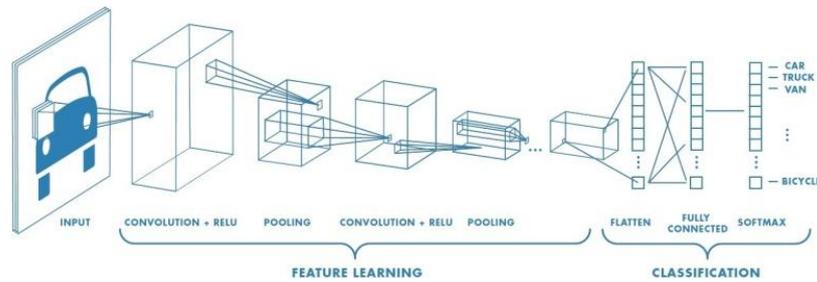
## 2.6 Klasifikasi

Klasifikasi adalah suatu bentuk dari analisis data yang mengekstraksi model untuk menggambarkan atau mengkategorikan kelas dari data. Dalam klasifikasi, pengklasifikasian atau model yang dibangun untuk memprediksi label kelas. Klasifikasi terdiri atas dua langkah atau dua proses, proses pertama adalah proses pembelajaran (proses pengklasifikasian dibangun), yang kedua proses klasifikasi (model yang dibangun digunakan untuk memprediksi label dari data yang telah diberikan).

## 2.7 *Convolutional Neural Network*

*Convolutional neural network* merupakan salah satu jenis *algoritma deep learning* yang dapat menerima input berupa gambar, menentukan aspek atau obek apa saja dalam sebuah gambar yang bisa digunakan mesin untuk belajar mengenali gambar, dan membedakan antara satu gambar dengan yang lainnya (Putro, Awangga, and Andarsyah, 2020). *Convolutional neural network* (CNN) yang sering disebut *convolutional network* (ConvNets) merupakan arsitektur jaringan saraf tiruan yang sedang populer. CNN adalah *multilayer perceptron* yang merupakan salah satu varian dari *deep neural networks* yang sering digunakan sebagai metode untuk mengklasifikasi data citra digital. Saat ini, CNN banyak diaplikasikan kedalam berbagai bidang kehidupan diantaranya, untuk rekomendasi sistem, analisi gambar medis, pemrosesan bahasa natural, *analisis financial time series* (Rahman et al. 2021).

### 2.7.1 Arsitektur *Convolutional Neural Network*



Gambar 2. 9 Arsitektur CNN  
(Rahman et al. 2021)

Arsitektur CNN memiliki dua bagian utama yaitu *Featur Learning* dan *Classification* seperti terlihat pada gambar diatas. *Feature learning* terdiri dari lapisan konvolusi, fungsi aktivasi seperti ReLu (*Rectified Linear Unit*), dan *Pooling*. Lapisan ini sering diulang atau disusun menjadi beberapa lapisan sesuai kebutuhan arsitektur yang dibuat. Bagian klasifikasi terdiri dari *Flatten*, *Fully Connected* dan *Softmax*. Komposisi pemilihan parameter dan menyusun CNN mempengaruhi kinerja jaringan CNN yang dibangun. Pada gambar diatas, dapat dilihat input CNN merupakan sebuah citra ruang parkir agar dapat dikenali apakah ruang parkir berstatus kosong atau terisi (*Free or busy*). Setiap lapisan CNN harus diketahui fungsi dan perannya masing-masing, hal ini akan memudahkan dalam membangun arsitektur baru CNN atau mengeksplotasi arsitektur CNN yang sudah banyak tersedia (Rahman et al. 2021).

### 1. *Input layer*

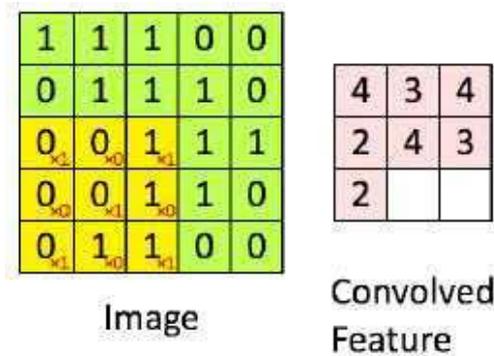
*Input layer* menampung nilai piksel dari citra yang menjadi masukan. Untuk citra dengan ukuran 64x64 dengan 3 channel warna, RGB (*Red, Green, Blue*) maka yang menjadi masukan adalah piksel array yang berukuran 64x64x3 (Putro et al. 2020).

### 2. *Convolution Layer*

*Convolution layer* adalah inti dari CNN. *Convolution layer* menghasilkan citra baru yang menunjukkan fitur dari citra input. Dalam proses tersebut, *convolution layer* menggunakan filter pada setiap citra yang menjadi masukan. *Filter* pada *layer* ini berupa array 2 dimensi bisa berukuran 5x5, 3x1 atau 1x1. Proses *convolution* dengan menggunakan *filter* pada *layer* ini akan menghasilkan *feature map* yang digunakan pada *activation layer* (Putro et al. 2020).

### a. Operasi Konvolusi

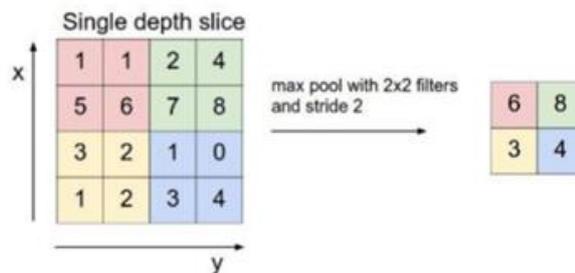
Konvolusi didefinisikan sebagai proses untuk memperoleh satu piksel didasarkan pada nilai piksel itu sendiri dengan melibatkan satu matriks yang disebut kernel yang merepresentasikan pembobotan. Operasi ini menerapkan fungsi output sebagai feature map dari masukan citra dan keluaran ini dapat dilihat sebagai dua argumen bernilai riil. Operasi konvolusi ini ditunjukkan dalam gambar berikut (Ilahiyah and Nilogiri, 2018).



Gambar 2. 10 Operasi Konvolusi  
(Ilahiyah and Nilogiri, 2018)

### b. Pooling Layer

*Pooling layer* adalah lapisan yang menggunakan fungsi yang menggunakan fungsi dengan *feature map* sebagai masukan dan mengolahnya dengan berbagai macam operasi statistik berdasarkan nilai piksel terdekat. Pada mode CNN, lapisan *pooling* biasanya disisipkan secara teratur setelah beberapa lapisan konvolusi. Lapisan *pooling* yang dimasukkan diantara lapisan konvolusi secara berurut-urut dalam arsitektur model CNN dapat secara *progresif* mengurangi ukuran volume output pada *feature map*, sehingga mengurangi jumlah parameter dan perhitungan di jaringan, dan untuk mengendalikan *overfitting*. Lapisan pooling yang paling umum adalah dengan menggunakan filter berukuran 2x2 yang diaplikasikan dengan langkah sebanyak 2 dan kemudian beroperasi pada setiap irisan dari input. Bentuk seperti ini akan mengurangi *feature map* hingga 75% dari ukuran asli. Contoh *operasi max pooling* ditunjukkan dalam gambar berikut (Ilahiyah and Nilogiri, 2018).



Gambar 2. 11 Operasi *Max Pooling*  
(Ilahiyah and Nilogiri, 2018)

#### c. Aktivitas ReLU

Aktivitas ReLU (*Rectified Linear Unit*) merupakan lapisan aktivisasi pada model CNN yang mengaplikasikan fungsi  $f(x) = \max(0, x)$  yang berarti fungsi ini melakukan thresholding dengan nilai nol terhadap nilai piksel pada input citra. Aktivisasi ini membuat seluruh nilai piksel yang nilai kurang dari nol pada suatu citra akan dijadikan 0.

#### d. *Fully-Connected Layer*

*Layer* ini adalah lapisan yang biasanya digunakan dalam penerapan MLP dan bertujuan untuk melakukan transformasi pada dimensi agar data dapat diklasifikasikan secara linear. Setiap neuron pada *convolution layer* perlu ditransformasi menjadi data satu dimensi terlebih dahulu sebelum dapat dimasukkan kedalam sebuah *fully connected layer*. Karena hal tersebut menyebabkan data kehilangan informasi spasialnya dan tidak hanya dapat diimplementasikan di akhir jaringan (Ilahiyah and Nilogiri, 2018).

#### e. *Dropout Regulation*

*Dropout* merupakan sebuah teknik regulasi jaringan syaraf dengan tujuan memilih beberapa neuron secara acak dan tidak akan dipakai selama proses pelatihan, dengan kata lain neuron-neuron tersebut dibuang secara acak. Hal ini berarti bahwa kontribusi neuron yang dibuang akan diberhentikan sementara jaringan dan bobot baru juga tidak diterapkan pada neuron pada saat melakukan *backpropagation*.

#### f. *Aktivasi Softmax*

*Aktivasi softmax* atau *softmax classifier* merupakan bentuk lain dari *algoritma logistic regression* yang dapat digunakan untuk mengklasifikasi lebih dari dua kelas. Standar klasifikasi yang biasa dilakukan oleh *algoritma logistic regression* adalah tugas untuk klasifikasi tugas biner. Pada *softmax* bentuk persamaan yang muncul adalah sebagai berikut.

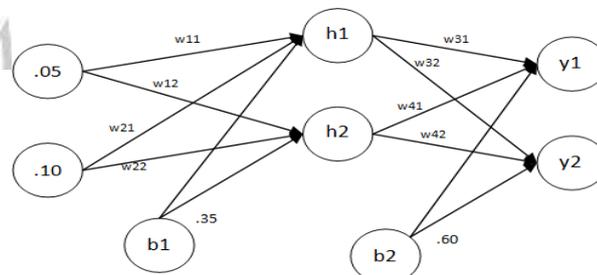
$$F_j(Z) = \frac{e^{z_j}}{\sum_k e^{z_k}} \quad (2.4)$$

Notasi  $f_j$  menunjukkan hasil fungsi untuk setiap elemen ke- $j$  pada vektor keluaran kelas. Argumen  $z$  adalah hipotesis yang diberikan oleh model pelatihan agar dapat diklasifikasi oleh fungsi *softmax*. *Softmax* juga memberikan hasil yang lebih intuitif dan juga memiliki interpretasi probabilistik yang lebih baik dibanding algoritma klasifikasi lainnya. *Softmax* memungkinkan menghitung *probabilitas* untuk semua label dari label yang ada akan diambil sebuah vektor nilai bernilai riil dan merubahnya menjadi vektor dengan nilai antara nol dan satu yang bila semua dijumlahkan akan nilai satu (Ilahiyah and Nilogiri, 2018).

#### g. Cross Entropy Loss Function

*Loss function* atau *cross entropy* merupakan fungsi yang menggambarkan kerugian yang terkait dengan semua kemungkinan yang dihasilkan oleh model. *Loss function* bekerja ketika model pembelajaran memberikan kesalahan yang harus diperhatikan. *Loss function* yang baik adalah fungsi yang menghasilkan error yang diharapkan paling rendah.

### 2.7.2 Penerapan Metode Terkait



Gambar 2. 12 Arsitektur JST Penerapan Metode *Backpropagation*

Memiliki input  $x_1 = 0.05$  dan  $x_2 = 0.10$  serta bias =1 di masing-masing lapisan. Untuk laju pembelajaran (*learning rate*)  $\alpha = 0.5$ . Menetapkan nilai target di lapisan  $y_1=0.01$  dan target di lapisan  $y_2= 0.99$ .

**Tabel 2.1** Nilai Bobot dan Bias Pada *Input Layer* ke *Hidden Layer*

$x_i$ ke <i>hidden</i>	$h_1$		$h_2$	
$x_i$	w11	w21	w12	w22
$i=1,2$	0.15	0.20	0.25	0.30
$I$	$b_1 = 0.35$			

Sementara bobot-bobot yang menghubungkan keluaran lapisan tersembunyi ( $h_1$ ,  $h_2$ ) dengan lapisan keluaran  $y_1$  dan  $y_2$ , sebagai berikut :

**Tabel 2.2** Nilai Bobot dan Bias Pada *Hidden Layer* ke *Output Layer*

<i>hidden</i> ke $y_k$	$y_1$		$y_2$	
$h_j$	w31	w41	w32	w42
$j=1,2$	0.40	0.45	0.50	0.55
$I$	$b_2 = 0.60$			

### Fase *feed forward*

Menghitung net dan keluaran dilapisan tersembunyi.

$$h_{in1} = x_1w_{11} + x_2w_{21} + b_1$$

$$h_{in1} = (0.05)(0.15) + (0.10)(0.20) + (1)(0.35) = 0.3775$$

$$h_1 = \frac{1}{1+e^{-0.3775}} = 0.593269992$$

$$h_{in2} = x_1w_{12} + x_2w_{22} + b_1$$

$$h_{in2} = (0.05)(0.25) + (0.10)(0.30) + (1)(0.35) = 0.3925$$

$$h_2 = \frac{1}{1+e^{-0.3925}} = 0.596884378$$

Hitung net dan keluaran dilapisan output  $y_1$  dan  $y_2$  dengan menggunakan  $h_1$  dan  $h_2$  sebagai inputnya.

$$y_{in1} = h_1w_{31} + h_2w_{41} + b_2$$

$$y_{in1} = (0.593269992)(0.40) + (0.596884378)(0.45) + (1)(0.60) = 1.105905967$$

$$y_1 = \frac{1}{1 + e^{-1.105905967}} = 0.75136507$$

$$y_{in2} = (0.593269992)(0.50) + (0.596884378)(0.55) + (1)(0.60) = 1.224921404$$

$$y_2 = \frac{1}{1 + e^{-1.224921494}} = 0.772928465$$

### Fase *Backpropagation*

#### 1. Output $y_k$

Menghitung *error total* di lapisan  $y_k$ , dan karena kita memiliki dua unit output, yaitu  $y_1$  dan  $y_2$ , maka *error totalnya* adalah :

$$E_{ty1} = \sum_{k=1}^n \frac{1}{2} (t_k - y_k)^2 = \frac{1}{2} (t_1 - y_1)^2 + \frac{1}{2} (t_2 - y_2)^2$$

$$E_{ty1} = \sum_{k=1}^n \frac{1}{2} (t_k - y_k)^2 = \frac{1}{2} (0.01 - 0.75136507)^2 + \frac{1}{2} (0.99 - 0.772928465)^2$$

$$= 0.2983711092$$

Untuk mencari *error* kita menggunakan fungsi *Mean Squared Error (MSE)*, yaitu :

$$Error = (E) = \frac{1}{2} (\text{target} - \text{output})^2$$

Maka turunan dari *error* terhadap  $y_1$  adalah  $\frac{\partial E_{y1}}{\partial y_1} = (y_1 - t_1)$

$$\frac{\partial E_{y1}}{\partial y_1} = (0.75136507 - 0.01) = 0.74136507$$

Perlu diketahui juga bahwa  $\frac{\partial y_1}{\partial y_{in1}}$  merupakan turunan dari keluaran  $y_1$  yang berhubungan dengan  $y_{in1}$  yang menuju  $y_1$ , sehingga  $\frac{\partial y_1}{\partial y_{in1}} = y_1 * (1 - y_1)$  maka,

$$\frac{\partial y_1}{\partial y_{in1}} = 0.75136507 * (1 - 0.75136507) = 0.1868156016$$

Karena total net input adalah  $y_{in1}$  dan weight disini adalah  $w_{31}$  dan output hidden adalah  $h_1$ , maka  $\frac{\partial y_{in1}}{\partial w_{31}} = h_1 = 0.593269992$ .

Perubahan bobot jaringan yang didapat adalah sebagai berikut ini:

$$\frac{\partial E_{ty1}}{\partial w_{31}} = \frac{\partial E_{y1}}{\partial y_1} * \frac{\partial y_1}{\partial y_{in1}} * \frac{\partial y_{in1}}{\partial w_{31}}$$

$$\frac{\partial E_{ty1}}{\partial w_{31}} = 0.74136507 * 0.1868156016 * 0.593269992 = 0,0821670405$$

$$\frac{\partial E_{ty1}}{\partial w_{41}} = \frac{\partial E_{y1}}{\partial y_1} * \frac{\partial y_1}{\partial y_{in1}} * \frac{\partial y_{in1}}{\partial w_{41}}$$

$$\frac{\partial E_{ty1}}{\partial w_{41}} = 0.74135607 * 0.1868156016 * 0.596884378 = 0.0826676278$$

Perubahan bobot untuk  $w_{32}$  adalah:

$$\frac{\partial E_{t_2}}{\partial w_{32}} = \frac{\partial E_{y_2}}{\partial y_2} * \frac{\partial y_2}{\partial y_{in2}} * \frac{\partial y_{in2}}{\partial w_{32}}$$

$$\frac{\partial E_{t_2}}{\partial w_{32}} = (-0.217071535) * 0.175510053 * 0.593269992 = -0.0226025406$$

$$\frac{\partial E_{t_2}}{\partial w_{42}} = \frac{\partial E_{y_2}}{\partial y_2} * \frac{\partial y_2}{\partial y_{in2}} * \frac{\partial y_{in2}}{\partial w_{42}}$$

$$\frac{\partial E_{t_2}}{\partial w_{42}} = (-0.217071535) * 0.175510053 * 0.596884378 = -0.0227402423$$

### Bobot bias ( $b_2$ )

Persamaan *error* total  $b_2$  adalah:

$$\frac{\partial E_{t_2}}{\partial b_2} = \frac{\partial E_{y_1}}{\partial b_2} + \frac{\partial E_{y_2}}{\partial b_2}$$

$$\text{Maka } \frac{\partial E_{y_1}}{\partial b_2} = \frac{\partial E_{y_1}}{\partial y_{in1}} * \frac{\partial y_{in1}}{\partial b_2}$$

$$\frac{\partial E_{y_1}}{\partial y_{in1}} = \frac{\partial E_{y_1}}{\partial y_1} * \frac{\partial y_1}{\partial y_{in1}} = (y_1 - t_1) * y_1 * (1 - y_1)$$

$$\frac{\partial E_{y_1}}{\partial y_{in1}} = (0.75136507 - 0.01) * 0.75136507 * (1 - 0.75136507) = 0.1384985615$$

$$\frac{\partial y_{in1}}{\partial b_2} = \text{input} = b_2 = 1$$

$$\frac{\partial E_{y_1}}{\partial b_2} = \frac{\partial E_{y_1}}{\partial y_{in1}} * \frac{\partial y_{in1}}{\partial b_2} = 0.1384985615 * 1 = 0.1384985615$$

$$\frac{\partial E_{y_2}}{\partial b_2} = \frac{\partial E_{y_2}}{\partial y_{in2}} * \frac{\partial y_{in2}}{\partial b_2}$$

$$\frac{\partial E_{y_2}}{\partial y_{in2}} = \frac{\partial E_{y_2}}{\partial y_2} * \frac{\partial y_2}{\partial y_{in2}} = (y_2 - t_2) * y_2 * (1 - y_2)$$

$$\frac{\partial E_{y_2}}{\partial y_{in2}} = (0.772928465 - 0.99) * 0.772928465 * (1 - 0.772928465) = -0.0380982366$$

Jumlahkan total *error* bias  $b_2$  yang juga ikut mempengaruhi *error* di  $y_k$ , yaitu dengan

$$\frac{\partial E_{t_2}}{\partial b_2} = \frac{\partial E_{y_1}}{\partial b_2} + \frac{\partial E_{y_2}}{\partial b_2} = -0.0380982366 * 1 = -0.0380982366$$

### 2. Hidden $h_j$

$$\frac{\partial E_{y_1}}{\partial y_{in1}} = \frac{\partial E_{y_1}}{\partial y_1} * \frac{\partial y_1}{\partial y_{in1}} = (y_1 - t_1) * y_1 * (1 - y_1)$$

$$\frac{\partial E_{y_1}}{\partial y_{in1}} = (0.75136507 - 0.01) * 0.75136507 * (1 - 0.75136507) = 0.138498562$$

Maka *error*  $h_1$  yang diperoleh dari titik output  $y_1$  adalah:

$$\frac{\partial E_{y_1}}{\partial h_1} = \frac{\partial E_{y_1}}{\partial y_{in1}} * \frac{\partial y_{in1}}{\partial h_1} = 0.138498562 * 0.40 = 0.055399425$$

$$\frac{\partial Ey2}{\partial h1} = \frac{\partial Ey2}{\partial yin2} * \frac{\partial yin2}{\partial h1}$$

$$\frac{\partial Ey2}{\partial yin2} = \frac{\partial Ey2}{\partial y2} * \frac{\partial y2}{\partial yin2} = (y_2 - t_2) * y_2 * (1 - y_2)$$

$$\frac{\partial Ey}{\partial yin2} = (0.772928465 - 0.99) * 0.772928465 * (1 - 0.772928465)$$

$$= -0.038098237$$

$$\frac{\partial Ey2}{\partial h1} = \frac{\partial Ey2}{\partial yin2} * \frac{\partial yin2}{\partial h1} = (-0.038098237) * 0.50 = -0.019049118$$

Maka *error* total  $h_1$  yaitu:

$$\frac{\partial Eth1}{\partial h1} = \frac{\partial Ey1}{\partial h1} + \frac{\partial Ey2}{\partial h1} = 0.055399425 + (-0.0190491183) = 0.0363503067$$

$$\frac{\partial h1}{\partial hin1} = h_1 * (1 - h_1) = 0.593269992 * (1 - 0.593269992) = 0.2413007086$$

Menghitung perubahan bobot  $w_{11}$  dan  $w_{12}$

$$\frac{\partial Eth1}{\partial w11} = \frac{\partial Eth1}{\partial h1} * \frac{\partial h1}{\partial hin1} * \frac{\partial hin1}{\partial w11}$$

$$\frac{\partial Eth1}{\partial w11} = 0.0363503067 * 0.2413007086 * 0.05 = 0.0004385677$$

$$\frac{\partial Eth1}{\partial w21} = \frac{\partial Ey1}{\partial h1} * \frac{\partial h1}{\partial hin1} * \frac{\partial hin1}{\partial w21}$$

$$\frac{\partial Eth1}{\partial w21} = 0.0363503067 * 0.2413007086 * 0.10 = 0.0008771355$$

Maka *error* total  $h_2$  yaitu:

$$\frac{\partial Eth2}{\partial w12} = \frac{\partial Eth2}{\partial h2} * \frac{\partial h2}{\partial hin2} * \frac{\partial hin2}{\partial w12}$$

$$\frac{\partial Eth2}{\partial w12} = 0.0413703226 * 0.2406134173 * 0.05 = 0.0004977127$$

$$\frac{\partial Eth2}{\partial w22} = \frac{\partial Eth2}{\partial h2} * \frac{\partial h2}{\partial hin2} * \frac{\partial hin2}{\partial w22}$$

$$\frac{\partial Eth2}{\partial w22} = 0.0413703226 * 0.2406134173 * 0.10 = 0.0009954255$$

*Error* total untuk  $h_1$  dan  $h_2$  untuk perubahan bobot bias  $b_1$  adalah:

$$\frac{\partial Etb1}{\partial b1} = \frac{\partial Eth1}{\partial b1} + \frac{\partial Eth2}{\partial b1}$$

$$\frac{\partial Etb1}{\partial b1} = \left( \left( \frac{\partial Ey1}{\partial y1} * \frac{\partial y1}{\partial yin1} * \frac{\partial yin1}{\partial h1} \right) + \left( \frac{\partial Ey2}{\partial y2} * \frac{\partial y2}{\partial yin2} * \frac{\partial yin2}{\partial h1} \right) \right)$$

$$\frac{\partial Etb1}{\partial b1} = ((y_1 - t_1) * (1 - y_1) * w_{41}) + ((y_2 * (1 - y_2) * w_{24}))$$

$$\frac{\partial Etb1}{\partial b1} = 0.041370323$$

Selanjutnya jumlahkan untuk mendapatkan perubahan bobot bias yaitu dengan

$$\frac{\partial E_{tb1}}{\partial b_1} = \frac{\partial E_{th1}}{\partial b_1} + \frac{\partial E_{th2}}{\partial b_1}$$

$$\frac{\partial E_{tb1}}{\partial b_1} = 0.036350306 + 0.041370323 = 0.77720629$$

### Fase adjusting the weight

$$W_{31}(\text{baru}) = W_{1}(\text{lama}) - \alpha \frac{\partial E_{ty1}}{\partial w_{31}}$$

$$w_{31}(\text{baru}) = 0.40 - 0.5 * 0,0821670405 = 0.3589164798$$

$$w_{41}(\text{baru}) = 0.45 - 0.5 * 0,0826676278 = 0.4086661861$$

$$w_{32}(\text{baru}) = 0.50 - 0.5 * (-0.0226025406) = 0.5113012703$$

$$w_{42}(\text{baru}) = 0.55 - 0.5 * (-0.0227402423) = 0.5613701212$$

$$bias_{2}(\text{baru}) = 0.60 - 0.5 * (0.1004003249) = 0.5497998376$$

Perbaharui bobot-bobot jaringan dilapisan hidden, yaitu  $w_{11}$ ,  $w_{21}$  dan  $w_{12}$ ,  $w_{22}$  serta biasnya. Maka bobot baru yang diperoleh adalah:

$$w_{11}(\text{baru}) = 0.15 - 0.5 * (0.0004385677) = 0.1497807162$$

$$w_{21}(\text{baru}) = 0.20 - 0.5 * (0.0008771355) = 0.1995614323$$

$$w_{12}(\text{baru}) = 0.25 - 0.5 * (0.0004977127) = 0.2497511437$$

$$w_{22}(\text{baru}) = 0.30 - 0.5 * (0.0009954255) = 0.2995022873$$

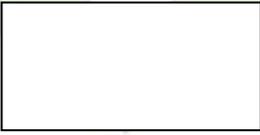
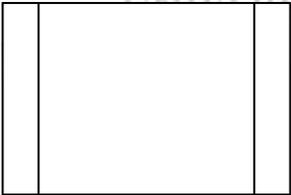
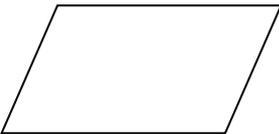
$$bias_{1}(\text{baru}) = 0.35 - 0.5 * (0.077720629) = 0.3111396855$$

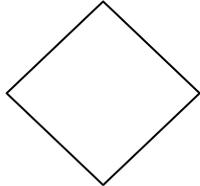
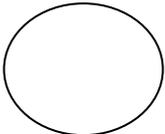
Untuk mengetahui hasilnya, maka akan menghitung kembali jaringan, dengan cara yang sama maka akan didapat keluaran di unit  $y_1 = 0.730947918$  (target = 0,01), sementara output  $y_2 = 0.764609219$  (target = 0.99), dan *error total* berada di nilai 0.285283453. Keadaan ini masih jauh dari harapan, akan tetapi bisa melihat *error total* tampak turun dari sebelumnya. Ini artinya jaringan backprop yang diimplementasikan berhasil melakukan pelatihan. Sebagai tambahan, jika proses pelatihan diteruskan dan disetel sebesar 10.000 epoch, jaringan akan mengenali pola pada epoch yang ke 6800an dengan nilai  $y_1 = 0.016335293$  (target = 0.01), dan  $y_2 = 0.983745585$  (target = 0.99), sementara *error total* akan jauh terjun 0.000100041 pada epoch ke 4000an.

## 2.8 Flowchart

*Flowchart* adalah bagan (*diagram*) yang merupakan bagan dengan seperangkat ikon atau grafik yang menampilkan kegiatan program dari awal sampai akhir (Muhammad Dwi Andika, 2018). Dibawah ini adalah beberapa simbol yang ada pada *flowchart* dapat dilihat pada tabel ini.

**Tabel 2.3** Simbol Pada *Flowchart*

No	Simbol	Nama	Keterangan
1		<i>Terminator</i>	digunakan pada awal dan akhir aliran proses.
2		<i>Process</i>	Fungsinya adalah proses integrasi pengolahan data.
3		<i>Sub Process</i>	Fungsinya untuk menggambarkan subprogram yang bisa berupa prosedur atau fungsi.
4		<i>Input and Output</i>	Simbol yang digunakan sebagai sumber data untuk diproses.

5.		<i>Decision</i>	Simbol yang digunakan untuk keputusan data dengan relasi yang sedang diproses.
6		<i>On Page Connector</i>	Simbol yang digunakan untuk menghubungkan diagram alur dengan halaman lain.
7		<i>Flow</i>	Sebagai arah untuk tujuan program aliran.

## 2.9 Pemrograman Web

Pemrograman web (*web programming*) terdiri dari kata pemrograman dan web. Pemrograman sendiri terdiri dapat diartikan sebagai proses atau cara pembuatan program menggunakan bahasa pemrograman. Bahasa pemrograman merupakan bahasa yang digunakan untuk memberikan intruksi kepada computer sehingga computer dapat memproses dan menampilkan informasi sesuai yang dikehendaki oleh pemrogram. Dengan demikian pemrograman web dapat diartikan sebagai kegiatan pembuatan program atau aplikasi berbasis web menggunakan bahasa tertentu sehingga dapat memproses data dan menghasilkan informasi sesuai yang dikehendaki oleh pemilik website (Abdulloh, 2018).

## 2.10 *Phyton*

*Phyton* adalah bahasa pemrograman tingkat yang sangat populer saat ini, hal tersebut tidak terlepas dari bahasa *phyton* yang dianggap *powerfull* dan mendekati bahasa manusia. *Phyton* merupakan bahasa pemrograman “*interpreter*”, yang artinya kode akan langsung dieksekusi sesuai instruksi yang ditulis dalam bahasa pemrograman atau scripting tanpa sebelumnya mengubahnya menjadi kode objek seperti compiler (Rangkuti et al. 2021).

*Python* juga berjalan dibanyak platform seperti Linux dan Windows dll. *Python* bersifat *open source*, sehingga masih banyak orang yang berkontribusi

untuk mengembangkan dimana yang hak kekayaan intelektual dipegang oleh PSF. Bahasa python didukung oleh *library library* yang didalamnya menyediakan fungsi analisis data dan fungsi *machine learning*, data *preprocessing tools*, serta visualisasi data. Hal ini membuat *python* menjadi bahasa pemrograman yang populer pada bidang data *science* dan analisis.

Alasan mengapa *python* adalah salah satu bahasa pemrograman yang harus dipelajari adalah sebagai berikut:

1. *Python* merupakan bahasa yang mudah dipelajari serta mudah digunakan.
2. *Python* juga merupakan bahasa yang lebih efisien dibandingkan dengan bahasa pemrograman lain.
3. *Python* merupakan bahasa multifungsi, dimana *python* bisa diterapkan dimana saja mulai dari pemrosesan data/teks, membuat *website*, membuat program jaringan, robotika, sampai dengan kecerdasan buatan.
4. *Python* juga bisa melakukan integrasi dengan bahasa pemrograman lainnya (Pane and Saputra 2020).

## 2.11 Riset Tekait

Untuk mendukung penelitian ini peneliti merujuk beberapa riset terkait tentang metode yang digunakan. Ada beberapa penelitian terkait implementasi *deep learning* dengan metode *convolutional neural network*, diantaranya yaitu:

**Tabel 2.4** Riset Terkait

No	Judul dan Penulis	Penerbit	Hasil Penelitian
1.	Deteksi Dini Kanker Kulit Menggunakan K-Nn Dan Convolutional Neural Network.	Jurnal Teknologi Informasi dan Ilmu Komputer. Vol. 7, No. 2, April 2020,	Pada penelitian ini, terdapat dua usulan metode klasifikasi yang digunakan untuk melakukan deteksi kanker kulit berbasis pengolahan citra digital, yaitu klasifikasi secara regresi dan <i>artificial neural network</i> menggunakan <i>Convolutional Neural Network</i> . Set data

	<p>Oleh (Savera, Suryawan, and Setiawan 2020)</p>	<p>hlm. 373-378 Akreditasi KEMENRIST EKDIKTI, p- ISSN: 2355- 7699No. 30/E/KPT/201 8 e-ISSN: 2528-6579. Sinta 2.</p>	<p>yang digunakan berasal dari International Skin Imaging Collaboration (ISIC) dengan rincian sebagai berikut: 80 citra latih benign, 80 citra latih malignant, 20 citra uji benign, dan 20 citra uji malignant eteksi kanker kulit dengan ekstraksi fitur dan regresi kNN menghasilkan akurasi sebesar 75% dengan true positive rate (precision) sebesar 85% dan true negative rate (specificity) sebesar 72%.Citra kanker kulit yang digunakan dalam klasifikasi menggunakan CNN berjumlah 800, dengan rincian sebagai berikut: 320 citra latih benign, 320 citra latih malignant, 80 citra uji benign, dan 80 citra uji malignant.Didapatkan akurasi sebesar 76,56%.</p>
2.	<p>Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunaka</p>	<p>Jurnal Sitem &amp; Teknologi Inormasi Indonesia. Vol. 3, No. 2, Agustus 218. p-ISSN : 2502-5724; e-ISSN : 2541-5735</p>	<p>Pada penelitian implementasi deep learning pada identifikasi jenis tumbuhan berdasarkan citra daun menggunakan Convolutional Neural Network (CNN) ini digunakan arsitektur CNN dari Krizhevsky et al.(2012) yang disebut dengan AlexNet. Dari hasil pengamatan selama perancangan, implementasi, dan proses uji coba sistem, dapat diambil</p>

	<p>n Convolutional Neural Network. Oleh (Ilahiyah and Nilogiri 2018)</p>		<p>kesimpulan yaitu : (1) Percobaan menggunakan fold cross validation dengan nilai k=10 didapatkan presisi tertinggi pada percobaan pertama dari fold ke 7 yakni dengan nilai akurasi sebesar 90%, (2) Tingkat rata-rata akurasi klasifikasi sistem yang didapatkan dari percobaan fold cross validation dengan nilai k=10 yakni sebesar 85,21%, (3) Sistem yang telah dibuat dapat mengidentifikasi jenis genus tumbuhan dengan nilai akurasi sistem sebesar 90,8%.</p>
3.	<p>KAYU7NET : Identifikasi Dan Evaluasi F-Measure Citra Kayu Berbasis Deep Convolutional Neural Network (Dcnn). Oleh (Risnandar and Prakasa 2020)</p>	<p>Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK) Vol. 7, No. 6, Desember 2020, hlm. 1089-1098 Akreditasi KEMENRIST EKDIKTI, No. 36/E/KPT/2019 p-ISSN: 2355-7699 e-ISSN: 2528-</p>	<p>Penelitian ini menggunakan metode <i>convolutional neural network</i>. Dalam penelitian ini menunjukkan bahwa Kayu7Net memiliki kinerja yang baik, di mana penambahan jumlah dataset dan memperbaiki kualitas citra kayu sangat meningkatkan akurasi sistem identifikasi ini, dari 57,14% menjadi sebesar 95,54%. Kinerja terbaik Kayu7Net menggunakan dataset II dicapai pada model ke-6 untuk input citra kayu ukuran 600 x 600 piksel dan epoch 100. Perhitungan kinerja model ke-6 menunjukkan hasil precision sebesar 95,99%, recall sebesar 95,54%, spesificity sebesar 99,26% dan F-measure sebesar 95,46%.</p>

		6579. Sinta 2.	
5.	Klasifikasi Kanker Serviks Menggunakan Model <i>Convolutional Neural Network</i> (Alexnet). Oleh (Akbar 2021)	Jurnal Informatika dan Komputer Akreditasi KEMENRIST EKDIKTI, No.36/E/KPT/2019 Vol. 4, No. 1, April 2021, hlm. 44-51 p-ISSN: 2614-8897 e-ISSN: 2656-1948. Sinta 4.	Pada Penelitian ini, model <i>convolutional neural network</i> yang digunakan adalah model AlexNet yang akan digunakan untuk mentransformasikan input gambar menjadi label penyakit dari kanker serviks. Dataset yang digunakan merupakan dataset standar yaitu dataset Intel & MobileODT <i>Cervical Cancer Screening</i> . Pengujian arsitektur model AlexNet dilakukan terhadap parameter iterasi (epoch), subset data training untuk mengupdate bobot AlexNet ( <i>minibatch</i> ), laju pembelajaran ( <i>learning rate</i> ), resolusi gambar input yang digunakan sebagai patch pembelajaran AlexNet, dan ukuran dataset. Dari hasil eksperimen didapati bahwasanya akurasi sangat dipengaruhi oleh arsitektur lapisan konvolusi, dimana hasil akurasi terbaik mencapai lebih dari 60% yang diberikan oleh AlexNet dengan lapisan konvolusi ganda. Hal ini menunjukkan model AlexNet memiliki potensi yang hampir sama dengan model standar <i>deep residual network</i> untuk melakukan klasifikasi kanker serviks.
6.	Pengenalan	Komputika:	Hasil penelitian yang telah dilakukan

	<p>Gestur Angka Pada Tangan Menggunakan Arsitektur <i>AlexNet</i> Dan <i>LeNet</i> Pada Metode <i>Convolutional Neural Network</i>. Oleh (Ezar, Rivan, and Setiawan 2022)</p>	<p>Jurnal Sistem Komputer Volume 11, Nomor 1, April 2022, hlm. 19 – 28 . p-ISSN: 2252-9039. e-ISSN: 2655-3198. Sinta 3.</p>	<p>dapat ditarik beberapa kesimpulan. Penggunaan metode <i>thresholding</i> dapat membantu untuk mendeteksi objek gestur angka pada tangan dengan mendapatkan bentuk dari objek dan menghilangkan <i>background</i> objek. Penggunaan <i>pooling layer</i> dengan <i>average pooling</i> dan <i>optimizer RMSprop</i> pada arsitektur <i>AlexNet</i> maupun <i>LeNet</i> mendapatkan akurasi dan f1-score yang tertinggi dalam melakukan klasifikasi gestur angka pada tangan dengan nilai akurasi dan f1-score sebesar 99.45% (<i>AlexNet</i>) dan 99.49% (<i>LeNet</i>).</p>
7.	<p>Pengenalan Ekspresi Wajah Dengan Metode <i>Viola Jones</i> dan <i>Convolutional Neural Network</i>. Oleh (Reynaldo and Maliki 2021)</p>	<p>Jurnal Sistem Komputer Volume 9, Nomor 1, April 2020, hlm. 1 – 9. p-ISSN: 2252-9039. e-ISSN: 2655-3198. Sinta 3.</p>	<p>Pada penelitian ini data yang akan digunakan adalah data gambar yang dibagi menjadi dua jenis yaitu data latih dan data uji. Sumber data dilakukan dengan menangkap ekspresi wajah secara langsung terhadap 42 orang responden. Data latih dan data uji diambil dari 42 orang sebagai subjek 21 orang berekspresi bahagia, sedih terkejut, takut, marah, muak dan 21 orang lainnya berekspresi netral. Masing-masing data diambil sebanyak 15 citra perorang. Total jumlah data keseluruhan adalah 2205. Berdasarkan hasil pengujian dengan confusion</p>

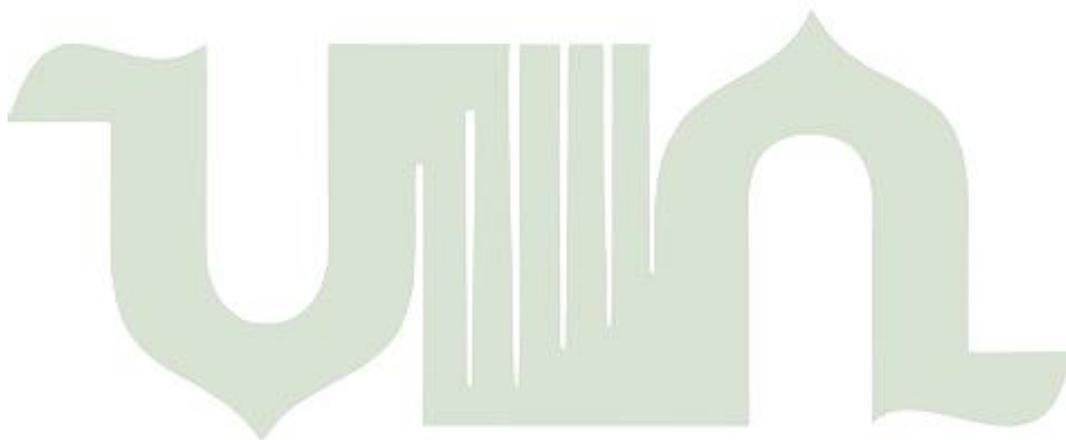
			matrix yang telah dilakukan, sesuai dengan arsitektur CNN yang diusulkan dengan parameter epoch 10 dan learning rate 0,001 diperoleh akurasi sebesar 96,14%.
8.	Pengenalan Jamur Yang Dapat Dikonsumsi Menggunakan Metode Transfer Learning Pada Convolutional Neural Network. Oleh (Haksoro, dan Setiawan, 2021)	Jurnal Teknik Elektro, Teknologi Informasi dan Komputer. Vol. 5, No. 2, Desember 2021, hal. 81-91 ISSN 2598-3245 (Print), ISSN 2598-3288 (Online). Sinta 3.	Pada penelitian ini, digunakan 9 jenis jamur yang akan dikelompokkan menjadi dua kelas. Kesembilan jenis jamur tersebut diantaranya adalah empat jenis jamur yang dapat dikonsumsi dan lima jamur yang tidak bisa dikonsumsi karena beracun. Empat jamur yang dapat dikonsumsi total jumlah keseluruhan datanya ialah 642 gambar. Sedangkan lima jamur beracun jumlah total datanya ialah 642 gambar, data gambar jamur keseluruhan berjumlah 1284 gambar jamur. kemudian dibagi berdasarkan kelompok dataset yang akan digunakan sebagai data latih dan data uji. Perbandingan untuk setiap kelas jamur yang dapat dikonsumsi dan yang tidak adalah 70% sebagai data latih dan 30% sebagai data uji untuk masing-masing kelas. Berdasarkan hasil penelitian pada dataset jamur dapat disimpulkan bahwa penggunaan metode <i>Transfer Learning Convolutional Neural Network</i> mampu memberikan hasil akurasi sebesar 92,19% dalam

			<p>pengklasifikasian jamur yang bisa dikonsumsi dengan yang tidak. Dengan hasil tersebut, dapat dikatakan bahwa penelitian ini dapat membantu manusia dalam mengenali jamur yang beracun dengan yang tidak.</p>
9.	<p>Perbandingan Arsitektur <i>LeNet</i> dan <i>AlexNet</i> Pada Metode <i>Convolutional Neural Network</i> Untuk Pengenalan <i>American Sign Language</i>. Oleh (Ezar, Rivan, and Riyadi 2021)</p>	<p>Jurnal Komputer Terapan Vol. 7, No. 1, Mei 2021, 53 – 6. e- ISSN : 2460-5255 (Online)   p-ISSN : 2443-4159 (Print). Sinta 3.</p>	<p>Penelitian ini membandingkan arsitektur <i>LeNet</i> dan <i>AlexNet</i> pada metode CNN. Data yang diperlukan berkaitan dengan penelitian yang akan dikerjakan yaitu gambar dari <i>American Sign Language</i>. Penggunaan jumlah data pada penelitian dibagi menjadi 2 skema, untuk skema pertama menggunakan 100 gambar per kelas (total 2.400) dengan pembagian 80% data training, 10% data validation, dan 10% data testing. Pada skema kedua menggunakan 1.000 gambar per kelas (total 24.000) dengan pembagian 80% data training, 15% data validation, dan 5% data testing. Hasil secara keseluruhan dari skema pertama, <i>LeNet</i> menghasilkan nilai <i>accuracy</i> 48,33%, <i>precision</i> 50,98%, dan <i>recall</i> 48,33% dengan waktu 23,6 detik, sedangkan <i>AlexNet</i> menghasilkan nilai <i>accuracy</i> 32,58%, <i>precision</i> 37,17%, dan <i>recall</i> 32,58% dengan waktu 132,8 detik. Pada skema kedua, <i>LeNet</i> menghasilkan nilai</p>

			<p><i>accuracy</i> 92,47%, <i>precision</i> 92,88%, dan <i>recall</i> 92,47% dengan waktu 230 detik, sedangkan AlexNet menghasilkan nilai <i>accuracy</i> 91,62%, <i>precision</i> 92,07%, dan <i>recall</i> 91,60% dengan waktu 1.355,4 detik.</p>
10.	<p>Classification Of Rice Plant Diseases Using the Convolutional Neural Network Method. Oleh (Priyanka and Kumara, 2021)</p>	<p>LONTAR KOMPUTER VOL. 12, NO. 2 AUGUST 2021 p-ISSN 2088-1541 e-ISSN 2541-5832. Sinta 2.</p>	<p>Penelitian ini merancang sebuah aplikasi untuk mengklasifikasikan penyakit padi berdasarkan warna dan tekstur daun dan menggunakan metode <i>Convolutional Neural Network</i>. Penelitian ini dilakukan pada penyakit padi dengan akurasi 95,24% menggunakan 100 epoch dan menggunakan augmentasi data rentang zoom dan rentang geser. Klasifikasi penyakit padi menggunakan metode CNN dalam dua tahap yaitu proses pelatihan dan pengujian. Dalam penelitian ini, setiap kelas menggunakan 15 data citra penyakit untuk proses pelatihan dan pengujian.</p>
11.	<p>Herbal Plant Detection Based On Leaves Image Using Convolutional Neural Network</p>	<p>Jurnal Ilmu Pengetahuan Dan Teknologi Komputer. Vol.6.No.1 August 2020. ISSN: 2685-8223. Sinta 3.</p>	<p>Penelitian mengembangkan pengenalan tanaman daun herbal menggunakan metode <i>Convolutional Neural Network</i> dengan arsitektur mobile net. Dataset sebanyak 500 citra untuk 5 jenis daun. Dimana 90 gambar digunakan untuk pelatihan dan 10 gambar untuk validasi dataset.akurasi terbaik dengan 400 citra</p>

	With Mobile Net Architecture. Oleh (Purnama and Primakara, 2020)		untuk data latih dan 100 citra untuk data pengujian yaitu 79,4%. Pada penelitian ini nilai akurasinya adalah 86,7%. Nilai presisi adalah 86,4% dan recall adalah 26%.
12.	Klasifikasi Citra Buah Menggunakan Convolutional Neural Network. Oleh (Maulana and Rochmawati, 2019)	Journal of Informatics and Computer Science. Volume 01 Nomor 02, 2019. ISSN : 2686-2220	Penelitian ini mengembangkan arsitektur CNN yang menggunakan objek citra buah-buahan sebagai data uji. Akurasi yang didapatkan dari proses testing yang menggunakan 345 citra uji menunjukkan angka 97,97%.
13.	Klasifikasi Citra Digital Bumbu Dan Rempah Dengan Algoritma Convolutional Neural Network (Cnn). Oleh (Wulandari et	Jurnal Gaussian, Volume 9, Nomor 3, Tahun 2020, Halaman 273 - 282. Issn: 2339-2541	Pada penelitian ini metode CNN digunakan untuk mengklasifikasikan objek citra. Objek citra tersebut akan dibagi menjadi 3 kategori yaitu ginseng, jahe dan lengkuas. Didapatkan nilai akurasi data training sebesar 0,9875 dan nilai loss 0,0769. Nilai akurasi data testing sebesar 0,85 dan nilai loss 0,4773. Sementara itu, pengujian dengan data baru yaitu masing-masing 3 citra untuk setiap

	al. 2020)		kategori menghasilkan akurasi sebesar 88,89%.
--	-----------	--	---



UNIVERSITAS ISLAM NEGERI  
SUMATERA UTARA MEDAN