

## BAB 2

### DASAR TEORI

#### 2.1 KAJIAN PUSTAKA

Pada penelitian [7] membahas mengenai pengembangan sistem dalam indentifikasi varietas Kopi Arabika menggunakan metode pengolahan citra. Penelitian ini dimulai dengan tahap *pre-processing* data yaitu *cropping* citra dan dilanjutkan dengan tahap klasifikasi menggunakan metode *Deep Learning*. Tahap *pre-processing* dilakukan untuk mempersiapkan citra sebelum dilakukan klasifikasi menggunakan arsitektur *Convolutional Neural Network* (CNN) untuk menguji kemampuan model dalam identifikasi varietas kopi. Dataset yang digunakan yaitu biji kopi *Ciwangi Catimor*, *Ciwangi Redbourbon*, dan *Rasuna Sigararutang*. Hasil perhitungan *confusion matrix* menunjukkan bahwa model mampu mendeteksi varietas *ciwangi red bourbon* dengan tingkat akurasi 71.4%, *ciwangi catimor* dengan tingkat akurasi 85.7%, dan *rasuna sigararutang* dengan tingkat akurasi 80%. Pada penelitian mendapat nilai *threshold* rata-rata sebesar 0.5, *precision* rata-rata sebesar 0.8 dan *recall* sebesar 0.7. Model dalam penelitian ini memiliki kekurangan karena keterbatasan *varietas* data yang digunakan.

Pada penelitian [8] membahas mengenai penerapan metode *Convolution Neural Network* (CNN) untuk mengidentifikasi kecacatan pada biji Kopi Arabika. Input yang digunakan berupa gambar biji Kopi Arabika yang telah dikeringkan. Proses pada penelitian ini terdiri dari tahap pengumpulan data, *preprocessing* data, klasifikasi dan yang terakhir pengujian. Tahap *preprocessing* data dilakukan dengan memotong bagian objek agar tersisa gambar biji kopi saja. Selanjutnya pada proses klasifikasi dilakukan dengan metode CNN. Pengujian dilakukan dengan dua jenis model, yaitu model dua kelas dan model empat kelas. Paramater – parameter yang digunakan yaitu tingkat pembelajaran sebesar 0,0001, lapisan konvolusi tunggal dengan 15 filter, dan 100 neuron pada lapisan tersembunyi. Model ini menggunakan dua lapisan konvolusional. Pada lapisan pertama terdapat 6 filter dengan ukuran 3x5x5, sedangkan pada lapisan kedua terdapat 18 filter dengan

ukuran 6x3x3. Hasil percobaan model menunjukkan bahwa akurasi terbaik yang diperoleh untuk model dua kelas adalah 82,46 %. Sedangkan hasil percobaan untuk model empat kelas memperoleh akurasi sebesar 70,73%.

Pada penelitian [2] membahas mengenai identifikasi mutu Kopi Beras Robusta menggunakan teknik pengolahan citra dengan mengimplementasikan metode *Support Vector Machine* (SVM) untuk membuat sistem klasifikasi otomatis mutu biji kopi. Fitur – fitur yang akan diekstraksi meliputi fitur warna, tekstur dan bentuk. Klasifikasi menggunakan metode *Linear Discriminant Analysis* (LDA) menunjukkan fitur warna yang terdiri dari komponen G (*green*), B (*blue*), L\* (*lightness*), a\* (*red-green axis*), dan b\* (*blue-yellow axis*) dan fitur bentuk yang terdiri dari area, perimeter, serta fitur tekstur yang terdiri dari energi, kontras, korelasi dan *homogeneity* juga digunakan. Dalam penelitian ini, digunakan 2400 sampel data, di mana 1600 data digunakan sebagai data latih dan 800 data sebagai data uji. Hasil penelitian menunjukkan bahwa metode SVM mampu mengklasifikasi biji Kopi Beras Robusta dengan tingkat akurasi *training* sebesar 93.56% dan tingkat akurasi *testing* sebesar 80.75%.

Pada penelitian [9] mempunyai tujuan untuk identifikasi biji Kopi Arabika jenis Sigarar Utang berdasarkan parameter tekstur. Fitur tekstur digunakan sebagai fitur untuk mengklasifikasikan biji kopi cacat dan biji kopi tidak cacat menggunakan metode *machine learning*. Pengenalan objek atau gambar biji kopi dilakukan menggunakan parameter tekstur pada tahap *feature extraction* menggunakan metode *Grey Level Co-occurrence Matrix* (GLCM). Fitur yang umum digunakan dalam GLCM meliputi *contrast*, *homogeneity*, *correlation* dan *energy*. Sebelum melakukan ekstraksi fitur, dilakukan juga proses *image preprocessing* terhadap dataset seperti *resize*, *grayscale*, dan *augmentation*. Dataset yang digunakan dalam penelitian ini berjumlah 1400 gambar yang terdiri dari gambar asli biji kopi dan gambar hasil *image preprocessing*. Selanjutnya dilakukan proses *learning* menggunakan algoritma *Support Vector Machine* (SVM) dengan tiga jenis kernel yang berbeda yaitu kernel RBF, *Polynomial*, dan *Sigmoid*. Hasil penelitian ini menunjukkan bahwa model terbaik menggunakan kernel *Polynomial* karena memiliki nilai akurasi dan *f-score* yang tertinggi dibandingkan model lain.

Pemilihan pemodelan terbaik didasarkan pada nilai akurasi sebagai filter pertama dan *f-score* sebagai filter kedua dalam *confusion matrix*. Berdasarkan pengujian yang dilakukan, pemodelan terbaik untuk identifikasi biji kopi berdasarkan parameter tekstur adalah pemodelan dengan kernel *Polynomial*, dengan tingkat akurasi mencapai 96%.

Pada penelitian [10] membahas mengenai teknologi pengolahan citra digital untuk mendeteksi penyakit pada daun kentang. Klasifikasi dilakukan dengan tiga jenis kelas yaitu daun sehat, *early blight*, dan *late blight* menggunakan metode *Deep Learning* dengan arsitektur *Convolutional Neural Network* (CNN). Pada penelitian ini terdapat empat tahapan dimulai dari tahap pengumpulan data, *preprocessing data*, dan tahap *classification* yang merupakan proses identifikasi penyakit daun menggunakan metode *Deep Learning*. Tahap terakhir yaitu evaluasi yang dilakukan untuk mengevaluasi metode klasifikasi yang telah dilakukan. Berdasarkan implementasi model dan hasil pengujian yang dilakukan dari penelitian menghasilkan model yang baik dengan pembagian dataset 80% dan 20% dengan ukuran gambar yang digunakan yaitu 150x150 piksel. Parameter penelitian menggunakan nilai *epoch* 10 dengan ukuran *batch size* 20, dengan total data *training* sebanyak 922 citra dan data *testing* sebanyak 230 citra sehingga menghasilkan nilai akurasi sebesar 95% sedangkan untuk nilai akurasi validasi mencapai 94%.

Pada penelitian [11] membahas mengenai klasifikasi kualitas biji kopi pada Lereng Gunung Kelir Semarang. Penelitian ini menggunakan metode *Analytical Heirarchy Process* (AHP). Tujuan dari penelitian ini untuk membuat aplikasi yang dapat melakukan klasifikasi kualitas biji kopi dengan input kadar air, cacat biji, dan ketinggian lahan dengan menggunakan metode AHP. Hasil pada penelitian dari data kopi yang telah diinputkan menunjukkan presentasi *error* sebesar 15% dimana *error* tersebut merupakan ketidak akuratan antara data perhitungan manual dengan perhitungan dengan metode AHP yang ditunjukkan oleh karung biji kopi 5, karung biji kopi 8 dan karung biji kopi 14 dari total 20 karung data yang di bandingkan. Pada penelitian ini menghasilkan kesimpulan bahwa metode AHP dapat digunakan sebagai metode identifikasi kualitas biji Kopi Arabika pada Perkebunan Kopi

Lereng Gunung Kelir Jambu Semarang dengan akurasi sebesar 85% dari total 20 data yang telah diuji.

Pada penelitian [12] mempunyai tujuan untuk klasifikasi buah pir menggunakan metode *Deep Learning* dengan arsitektur *Convolutional Neural Network* (CNN). Pada penelitian untuk implementasi model menggunakan bahasa *Python*, *Google Colab*, *Library TensorFlow* dan *Keras*. Model CNN dalam penelitian ini memiliki *input shape* sebesar 100x100 piksel, nilai *learning rate* sebesar 0,001, ukuran filter sebesar 3x3, jumlah *epoch* sebanyak 15, dan data *training* sebanyak 640 gambar dan data *validation* sebanyak 160 gambar. Hasil dari proses pelatihan menunjukkan akurasi sebesar 100% untuk data *training* dan *validasi*. Selanjutnya, dilakukan pengujian terhadap 100 gambar baru sebagai data *testing* menggunakan model yang telah dibuat. Pengujian ini menghasilkan tingkat akurasi sebesar 98% dalam melakukan klasifikasi citra buah pir antara jenis buah pir *Williams* dan *Forelle*. Dalam penelitian ini, ditemukan bahwa semakin tinggi nilai *learning rate*, akurasi dalam proses pelatihan akan semakin menurun. Selain itu, semakin besar nilai *epoch*, proses pelatihan akan memakan waktu yang lebih lama, namun hal ini tidak terlalu mempengaruhi akurasi secara signifikan.

Pada penelitian [13] membahas mengenai pengembangan sistem untuk klasifikasi tingkat kematangan buah kopi. Penelitian ini menggunakan fitur warna RGB dan HSV serta menerapkan metode K-Nearest Neighbor (KNN). Klasifikasi dilakukan dengan memproses citra menggunakan *software Matlab* untuk membuat sistem klasifikasi dengan tiga kelas, yaitu mentah, cukup matang, dan matang. Data yang digunakan dalam penelitian ini diperoleh dari sebuah dataset kopi dari *Google Image*, yang kemudian digunakan sebagai variabel penelitian. Jumlah total data yang digunakan dalam penelitian sebanyak 135 citra, yang dibagi menjadi 90 citra untuk data latih dan 45 data untuk data uji. Pengklasifikasian data dilakukan menggunakan metode KNN dengan menghitung jarak terdekat ke tetangga dengan nilai  $K=3$ . Dari hasil penelitian didapatkan tingkat akurasi sebesar 97,77% dengan hasil klasifikasi data pengujian sebanyak 44 data dengan hasil klasifikasi akurat dan 2,23 % dari 1 data mendapat hasil klasifikasi tidak akurat.

Pada penelitian [14] membahas mengenai klasifikasi varietas biji Kopi

Arabika menggunakan ekstraksi bentuk dan tekstur dengan menggunakan metode *Eccentricity* dan *Gray Level Co-Occurrence Matrix* sebagai alat untuk mengekstrak fitur serta *Naive Bayes Classifier* sebagai metode klasifikasi. Sistem ini menggunakan beberapa parameter untuk menentukan klasifikasi yaitu nilai rasio kebulatan, nilai ekstraksi tekstur *Gray Level Co-Occurrence Matrix* yang meliputi *Entropy*, *Energy*, *Homogeneity*, *Contrast* dan *Correlation*. Proses klasifikasi dilakukan dengan menggunakan metode *Naive Bayes*, yaitu dengan membandingkan nilai ekstraksi data uji dengan nilai data *training*. Keuntungan menggunakan metode ini karena membutuhkan jumlah data latih yang kecil untuk menentukan parameter yang diperlukan dalam klasifikasi. Penelitian ini berhasil mengembangkan sistem klasifikasi dengan hasil pengujian dan perhitungan data real sebanyak 24 data dengan menghasilkan sebanyak 20 data terklasifikasi dengan benar dan 4 data terklasifikasi salah. Selanjutnya untuk mengukur tingkat akurasi, data yang terklasifikasi dengan benar dibagi dengan total jumlah data uji, kemudian dikalikan dengan 100% sehingga mendapatkan hasil akurasi sebesar 83,3%.

Pada penelitian [15] membahas mengenai proses klasifikasi tingkat sangrai biji kopi dengan tujuan mempermudah para pengusaha kopi dan meningkatkan ketertarikan masyarakat dalam mengenali kualitas tingkat sangrai biji kopi, pada biji Kopi Arabika. Proses klasifikasi dilakukan dengan mengambil citra biji kopi menggunakan perangkat dan selanjutnya dilakukan tahap *preprocessing*. Jumlah dataset yang digunakan dalam penelitian ini adalah 150 data, dengan 90 data digunakan untuk data latih dan 60 data digunakan untuk data pengujian. Terdapat tiga kualitas tingkat sangrai biji kopi, yaitu *light*, *medium*, dan *dark*. Proses ekstraksi fitur dilakukan menggunakan metode *Singular Value Decomposition* (SVD), dan proses klasifikasi dilakukan menggunakan metode *Learning Vector Quantization* (LVQ). Data dan metode yang telah dirancang kemudian disimulasikan menggunakan *software Matlab*. Hasil akhir dari penelitian menghasilkan model yang dapat mengklasifikasikan tingkat kualitas sangrai citra biji kopi. Dari hasil pengujian dengan menggunakan metode yang telah diimplementasikan diperoleh akurasi sebesar 90%.

Pada penelitian [16] membahas mengenai penentuan lama sangrai biji kopi

berdasarkan variasi derajat pada proses pemanggangan menggunakan model warna RGB dengan teknik pengolahan citra digital. Pada penelitian ini teknik pengolahan citra digital dapat digunakan untuk melakukan perhitungan pada nilai RGB secara kuantitatif pada Kopi Arabika maupun Robusta yang telah disangrai. Hubungan antara variasi standar derajat sangrai dengan citra sampel Kopi Arabika dan Robusta menunjukkan korelasi yang sangat kuat pada setiap tahapan proses penyangraian. Hal ini dibuktikan dengan nilai koefisien korelasi yang dihasilkan berkisar pada interval 0,8 – 1,0. Hasil dari prediksi lama sangrai untuk variasi standar derajat sangrai pada Kopi Robusta dengan suhu 200°C, 225°C, dan 250°C adalah 101,7, 56,9 dan 30,2 menit untuk tingkat sangrai paling rendah serta 158,2, 85,2 dan 41,3 menit untuk tingkat sangrai paling tinggi. Sedangkan hasil prediksi lama sangrai untuk variasi standar derajat sangrai pada Kopi Arabika dengan suhu 205°C, 225°C, dan 250°C adalah 31,6 menit, 20,7 menit, dan 21 menit untuk tingkat sangrai paling rendah, serta 44,7 menit, 28,9 menit, dan 29,6 menit untuk tingkat sangrai paling tinggi.

Pada penelitian [17] mempunyai tujuan untuk identifikasi citra biji jagung kering dengan menerapkan metode *Convolutional Neural Network* (CNN) dan *deep learning*. Pada penelitian tahap pertama yang dilakukan tahap *preprocessing* atau menormalkan data input citra biji jagung dengan melakukan *wrapping* dan *cropping*. Kedua, dilakukan pembentukan model dan pelatihan sistem dan yang terakhir adalah pengujian sistem untuk mengukur performanya. Penelitian ini menggunakan metode CNN untuk identifikasi citra biji jagung kering dan menentukan nilai akurasinya. Pada penelitian digunakan 20 citra biji jagung yang digunakan sebagai data *testing* dari total 80 citra biji jagung digunakan sebagai *training* dataset. Seluruh citra diambil dari kamera *smartphone* dan proses pelatihan dilakukan dengan jumlah *epoch* sebanyak 100. Nilai akurasi identifikasi biji jagung kering dipengaruhi oleh ukuran citra dan posisi pengambilan citra dari kamera *smartphone*. Dalam penelitian ini penggunaan 7 lapisan konvolusi (*convolutional layer*) yang menghasilkan nilai akurasi yang berkisar antara 80% hingga 100%, Sehingga nilai rata-rata akurasi pada data *testing* sebesar 0,90296.

Pada penelitian [18] membahas mengenai klasifikasi kualitas sayur kol

berdasarkan citra fisik menggunakan *Deep Learning* dan *Convolutional Neural Network* (CNN) sebagai metode klasifikasi. Tujuan dari penelitian ini adalah untuk menentukan model yang paling sesuai untuk proses klasifikasi sayur kol dan mengukur hasil akurasi penggunaan metode CNN. Dalam penelitian ini, peneliti membangun sebuah model yang terdiri dari 4 lapisan konvolusi, 2 *pooling layer* yang berukuran  $2 \times 2$ , 3 *dropout layer*, 2 *dense layer* serta 1 *flatten layer*. Sedangkan untuk aktivasinya, menggunakan ReLu, dengan filter sebanyak 32 dan 64 dengan ukuran kernel  $3 \times 3$ . Model ini diuji menggunakan 270 data, yang dimana 210 data digunakan sebagai data latih dan 60 data digunakan sebagai data pengujian. Dengan *learning rate* sebesar 0.004, nilai *epoch* 30 dan tiga algoritma performansi berbeda yaitu *Stochastic Gradient Descent* (SGD), *Adaptive Moment* (Adam), dan *Root Mean Square Propagation* (RMSProp), dengan hasil pengujian tertinggi berada pada algoritma Adam dengan tingkat akurasi sebesar 80% untuk data uji dan 73% untuk data latih.

Pada penelitian [19] membahas mengenai implementasi *Deep Learning* pada sistem klasifikasi hama tanaman padi menggunakan arsitektur *Convolutional Neural Network* (CNN). Arsitektur CNN yang digunakan terdiri dari tiga lapisan konvolusi dan dua lapisan *fully connected* dengan penambahan *dropout* dan augmentasi citra untuk mengurangi *overfitting*. Skenario pembagian data yang digunakan pada penelitian ini yaitu 70%:30%, 80%:20%, dan 90%:10%. Berdasarkan percobaan dengan menggunakan *optimizer Adam* dan *learning rate* sebesar 0,001, diperoleh nilai akurasi validasi untuk masing-masing pembagian data yaitu 77,12%, 76,06%, dan 83,02% dengan *epoch* yang berbeda, yaitu 500, 500, dan 100. Sementara itu, nilai akurasi validasi untuk tiga model pelatihan tertinggi ada pada pembagian data 90%:10% dengan nilai 83,02%, 78,30%, dan 81,13% pada *epoch* 100, 200, dan 500. Total terdapat lima model CNN yang dipilih untuk data pengujian. Hasil pengujian menunjukkan nilai akurasi masing-masing model, yaitu 69,33%, 72%, 69,33%, 77,33%, dan 76%. Model dengan nilai akurasi tertinggi adalah 77,33%, yang dicapai oleh model dengan pembagian data 90%:10% dan akurasi *training* sebesar 78,30%. Seluruh proses pelatihan model yang dilakukan mengalami *overfitting*, yang dipengaruhi oleh ketidakseimbangan

dan kualitas dataset yang digunakan.

Pada penelitian [20] mempunyai tujuan untuk identifikasi penyakit pada daun tanaman kopi menggunakan metode *deep learning*. Hal ini bertujuan untuk mencegah penyebaran penyakit dengan cepat. Dalam penelitian ini, digunakan metode *deep learning* dengan menggunakan arsitektur VGG16. VGG16 adalah salah satu jenis arsitektur dalam *deep learning* yang terdiri dari total 16 lapisan, yang terdiri dari 13 lapisan konvolusi, 2 lapisan *fully connected*, dan 1 lapisan *classifier*. Dataset yang digunakan dalam penelitian sebanyak 360 gambar daun kopi yang terbagi menjadi 3 jenis yaitu daun kopi sehat, daun kopi yang terkena penyakit *Red Spider Mite*, dan daun kopi yang terkena penyakit *Rust*. Setelah dilakukan proses pengujian terhadap data *validation* diperoleh nilai akurasi tertinggi sebesar 89% pada percobaan perbandingan data 60:40 antara data *train* dan data *validation*. Hal ini menunjukkan bahwa metode *deep learning* VGG16 berjalan dengan baik dalam mengidentifikasi penyakit pada tanaman kopi.

**Tabel 2. 1 Analisis penelitian**

No	Judul	Nama Peneliti	Data	Metode dan Arsitektur	Hasil
1	Klasifikasi Varietas Kopi Berdasarkan Green Bean Coffe Menggunakan Metode <i>Machine Learning</i>	M. Agung Nugroho, Maria Mediatix Sebatubun (2020)	Menggunakan Dataset model tiga Varietas kopi yaitu <i>Ciwangi Catimor</i> , <i>Ciwangi Redbourbon</i> , dan <i>Rasuna Sigararutang</i> Dengan total data sebanyak 188 citra.	Metode <i>Deep Learning</i> dan Arsitektur CNN ( <i>Convolutional Neural Network</i> ) dengan proses identifikasi menggunakan google autoML.	Pada hasil <i>Confusion Matrix</i> didapatkan hasil akurasi pada saat mendeteksi varietas <i>Ciwangi Redbourbon</i> sebesar 71.4%, <i>Ciwangi Catimor</i> 85.7%, dan <i>Rasuna Sigararutang</i> 80%.

No	Judul	Nama Peneliti	Data	Metode dan Arsitektur	Hasil
2	Identifikasi Mutu Biji Kopi Arabika Berdasarkan Cacat Dengan Teknik Convolutional Neural Network	Mahmuda Saputra, Kusriani, Mei P Kurniawan (2020)	Menggunakan Dataset dengan total 850 citra yang terdiri dari 430 citra Biji kopi yang memenuhi syarat untuk ekspor dan 445 Biji kopi tidak memenuhi syarat untuk ekspor.	Metode <i>Deep Learning</i> dan Arsitektur CNN ( <i>Convolutional Neural Network</i> ) Dengan Skenario pengujian untuk dua jenis model, model 2 kelas dan model 4 kelas.	Lapisan konvolusional tunggal yang digunakan dalam CNN mampu memberikan 82,46% untuk klasifikasi model dua kelas dan 67,05% untuk klasifikasi model empat kelas. Penambahan lapisan konvolusi mampu meningkatkan akurasi model empat kelas menjadi 70,73%.
3	Klasifikasi Mutu Fisik Biji Kopi Beras Robusta Menggunakan Pengolahan Citra Digital	Dwi Anindea Putri, Agus Arip Munawar, Indera Sakti Nasution (2022)	Dataset dengan total 2400 citra dengan 1600 data <i>training</i> dan 800 data <i>testing</i> , Biji Kopi Beras Robusta yang digunakan berasal dari Aceh Tengah.	Metode <i>Machine Learning</i> dan Arsitektur <i>Support Vector Machine</i> (SVM) dengan menggunakan nilai 0.05 yang merupakan <i>Numclass</i> untuk pemisahan kelas.	Arsitektur SVM mampu mengklasifikasi biji Kopi Beras Robusta dengan tingkat akurasi <i>training</i> sebesar 93.56% dan tingkat akurasi <i>testing</i> sebesar 80.75%.
4	Pengenalan Biji Kopi Arabika varietas Sigarar Utang Lintong Nihuta Berdasarkan Parameter Tekstur Menggunakan <i>Machine Learning</i>	Indriani Tiosari Sitorus, Debora Rodearna Simarmata, Inte Christinawati Bu'ulolo (2020)	Menggunakan Dataset citra biji kopi Arabika varietas Sigarar Utang yang terdiri 100 citra biji kopi cacat dan 100 citra biji kopi tidak cacat, dengan total data sebanyak 200 citra biji kopi.	Metode <i>Machine Learning</i> dan Arsitektur <i>Support Vector Machine</i> (SVM) dengan skenario tiga jenis kernel berbeda yaitu kernel RBF, <i>Polynomial</i> , dan <i>Sigmoid</i> .	Pemodelan terbaik dalam melakukan pengenalan biji Kopi Arabika varietas Sigarar Utang berdasarkan parameter tekstur adalah pemodelan dengan kernel <i>Polynomial</i> dengan akurasi sebesar 96%.

No	Judul	Nama Peneliti	Data	Metode dan Arsitektur	Hasil
5	Deteksi Penyakit pada Daun Kentang Menggunakan Pengolahan Citra dengan Metode <i>Convolutional Neural Network</i>	Abdul Jalil Rozaqi, Andi Sunyoto <sup>2</sup> , Rudyanto Arief (2020)	Menggunakan Dataset dengan total 1152 data dengan rincian jumlah data yang digunakan adalah 500 data <i>late blight</i> , 500 data <i>early blight</i> dan 152 data daun sehat atau normal. Dengan pembagian dataset 80% dan 20%	Metode <i>Deep Learning</i> dan Arsitektur CNN ( <i>Convolutional Neural Network</i> ) menggunakan 20 <i>batch size</i> dan 46 iterasi per <i>epoch</i> untuk data training dan 11 iterasi per <i>epoch</i> untuk data testing dengan jumlah <i>epoch</i> 20.	Pada <i>epoch</i> ke 10 dengan <i>batch_size</i> 20 dengan total data <i>training</i> 922 gambar dan data <i>testing</i> 230 gambar menghasilkan nilai akurasi 95% dan untuk akurasi validasi menghasilkan 94%
6	Penentuan Kualitas Biji Kopi Arabika Dengan Menggunakan Analytical Hierarchy Process	Wahyu Muhammad Kurniawan, Khafiizh Hastuti (2018)	Menggunakan dataset Kopi Gunung Kelir Jambu Semarang sebanyak 20 Karung, Dengan jenis biji kopi arabika kualitas <i>grade 1</i> , <i>grade 2</i> , atau <i>grade 3</i>	Metode <i>Machine Learning</i> dan Arsitektur AHP ( <i>Analytical Heirarchy Process</i> ) dengan menentukan bobot kriteria, menentukan priority vector dan eigen vector lalu perangkaian hasil	Metode AHP dapat digunakan sebagai metode penentuan kualitas biji kopi arabika pada Perkebunan Kopi Lereng Gunung Kelir Jambu Semarang dengan akurasi sebesar 85% dari total 20 data yang diuji.
7	Klasifikasi Citra Buah Pir Menggunakan Convolutional Neural Network	Syauqani Juliansyah, Arif Dwi Laksito (2021)	Menggunakan Dataset buah pir yaitu <i>Williams</i> dan <i>Forelle</i> , Dengan total data <i>training</i> sebanyak 800 citra dan data <i>testing</i> sebanyak 100 citra.	Metode <i>Deep Learning</i> dan Arsitektur (CNN) <i>Convolutional Neural Network</i> dengan skenario memvariasikan parameter pada nilai <i>learning rate</i> dan <i>epoch</i>	Pada hasil <i>confusion matrix</i> didapatkan hasil akurasi sebesar 98% dengan data uji sebanyak 100 citra dan 2 citra tidak terdeteksi dengan akurat

No	Judul	Nama Peneliti	Data	Metode dan Arsitektur	Hasil
8	Klasifikasi Tingkat Kematangan Buah Kopi Berdasarkan Deteksi Warna Menggunakan Metode KNN Dan PCA	Siti Raysyah, Veri Arinal, Dadang Iskandar Mulyana (2021)	Dataset berupa biji kopi dengan tingkat kematangan mentah, cukup matang, dan matang. Dengan total data sebanyak 135 yang terbagi menjadi 90 data <i>training</i> dan 45 data <i>testing</i> .	Metode <i>Machine Learning</i> dan arsitektur <i>K-Nearest Neighbor</i> (KNN) untuk klasifikasi dataset dengan metode <i>Principal Component Analysis</i> (PCA) sebagai parameter untuk mengetahui sebaran data	Hasil pengujian didapatkan akurasi sebesar 97,77% dengan total data <i>testing</i> sebanyak 45 citra dan 1 citra tidak terdeteksi dengan akurat.
9	Klasifikasi Varietas Biji Kopi Arabika Menggunakan Ekstraksi Bentuk dan Tekstur	Rawansyah, Rosa Andrie Asmara, Taufiq Alif Heryanto, (2019)	Dataset variates biji Kopi Arabika yaitu <i>Typica, Yellow Cattura, Pacamara, dan Ethiopia</i>	Metode <i>Machine Learning</i> dan Teknik <i>Eccentricity</i> dan <i>Gray Level Co-Occurence Matrix</i> untuk ekstraksi fitur dan <i>Naive Bayes Classifier</i> sebagai metode klasifikasi.	Pada hasil <i>confusion matrix</i> didapatkan hasil akurasi saat mendeteksi variates biji kopi arabika sebesar 83,3% dengan data <i>testing</i> sebanyak 24 citra.
10	Klasifikasi Biji Kopi Berbasis Pengolahan Citra Digital Dengan Menggunakan <i>Singular Value Decomposition</i> Dan <i>Learning Vector Quantization</i>	Muh. Ipnu Udjie Hasiru, Dr. Ir. Jangkung Raharjo, M.T., Nur Ibrahim, S.T. M.T., (2019)	Dataset berupa biji kopi <i>light roast, medium roast, dan dark roast</i> . Dengan total data sebanyak 150 citra dengan rincian 90 citra data <i>training</i> dan 60 citra data <i>testing</i> .	Metode <i>Machine Learning</i> dan Teknik <i>Singular Value Decomposition</i> untuk ekstraksi cirinya dan menggunakan <i>Learning Vector Quantization</i> untuk klasifikasinya	Hasil pengujian mendapatkan akurasi terbaik sebesar 90% dengan <i>hyperparameter hidden layer</i> 10 dan <i>epoch</i> 100.
11	Penentuan Lama Sangrai Kopi Berdasarkan Variasi Derajat Sangrai Menggunakan Model Warna RGB Pada Pengolahan	Bambang Marhaenanto, Deddy Wirawan Soedibyo, Miftahul Farid (2015)	Dataset berupa biji kopi sangrai yaitu Robusta dan arabika. Dengan jumlah data sebanyak 30 kg biji kopi arabika dan 60 kg biji kopi Robusta.	Metode <i>Image Processing</i> atau pengolahan citra digital menggunakan model warna RGB dengan variasi berbagai jenis derajat sangrai	Hasil lama sangrai kopi adalah Robusta 200°C (101,7 & 158,2 menit), Robusta 225°C (56,9 menit, 85,2 menit), Robusta 250°C (30,2 menit, 41,3

No	Judul	Nama Peneliti	Data	Metode dan Arsitektur	Hasil
	Citra Digital ( <i>Digital Image Processing</i> )				menit), Arabika 205°C (31,6 menit, 44,7 menit), dan Arabika 225°C (20,7 menit, 28,9 menit).
12	Penerapan <i>Convolutional Neural Network Deep Learning</i> dalam Pendeteksian Citra Biji Jagung Kering	Arum TiaraSari, Emy Haryatmi (2021)	Dataset berupa biji jagung kering. Dengan total data sebanyak 100 dengan rincian 20 citra biji sebagai <i>testing</i> dan 80 citra biji jagung sebagai data <i>training</i> .	Metode <i>Deep Learning</i> dan Arsitektur <i>Convolutional Neural Network</i> dengan memvariasikan inputan gambar.	Hasil <i>testing</i> dengan ukuran yang bervariasi didapatkan nilai akurasi berkisar antara 80% - 100% sehingga nilai rata-rata akurasi <i>testing</i> data sebesar 0,90296
13	Penggunaan <i>Deep Learning</i> Dengan Metode <i>Convolutional Neural Network</i> Untuk Klasifikasi Kualitas Sayur Kol Berdasarkan Citra Fisik	Ratna Dhamayanti, Mimin Fatchiyatur Rohmah, Sofa Zahara (2021)	Dataset berupa sayur kol dengan kualitas berupa layak, cukup dan buruk. Dengan total data sebanyak 270 yang terbagi menjadi data <i>training</i> sebanyak 210 citra, serta data <i>testing</i> sebanyak 60 citra.	Metode <i>Deep Learning</i> dan Arsitektur (CNN) <i>Convolutional Neural Network</i> dengan scenario algoritma performasi berbeda yaitu SGD, Adam, dan RMSProp	Hasil <i>testing</i> tertinggi yaitu menggunakan algoritma Adam dengan tingkat akurasi sebesar 80% untuk data <i>testing</i> dan 73% untuk data <i>training</i> .

No	Judul	Nama Peneliti	Data	Metode dan Arsitektur	Hasil
14	Implementasi <i>Deep Learning</i> pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode <i>Convolutional Neural Network</i> (CNN)	Susi Yuliany, Aradea, Andi Nur Rachman, (2022)	Dataset berupa hama tanaman padi yaitu yaitu: Belalang, Hispa Padi, Penggerek Batang Padi, Ulat Grayak dan Wereng Hijau.	Metode <i>Deep Learning</i> dan Arsitektur (CNN) <i>Convolutional Neural Network</i> dengan skenario perbandingan data, nilai <i>epoch</i> dan <i>learning rate</i> .	Hasil pengujian didapatkan akurasi tertinggi sebesar 77,33% dengan pembagian data 90:10, nilai <i>epoch</i> 200 serta <i>learning rate</i> sebesar 0,001.
15	Identifikasi Penyakit pada Daun Kopi Menggunakan Metode <i>Deep Learning</i> VGG16	Rizki Windiawan, Aries Suharso (2019)	Dataset berupa penyakit daun kopi yaitu daun kopi sehat, daun kopi penyakit <i>Red Spider Mite</i> , dan penyakit <i>Rust</i> .	Metode <i>Deep Learning</i> dan Arsitektur VGG16 dengan Skenario perbandingan data <i>train</i> dan data <i>validation</i> .	Pada hasil pengujian didapatkan akurasi tertinggi sebesar 89% dengan menggunakan perbandingan data <i>train</i> dan <i>validation</i> 60:40.
16	Sistem Klasifikasi Kualitas Biji Kopi Menggunakan Pengolahan Citra Digital Dengan Metode <i>Deep Learning</i> (DL)	Nur Badriatun Muntamah, Kholidiyah Masykuroh, S.T.,M.T, Agung Wicaksono, S.T.,M.T. (2023)	Dataset berupa kualitas biji kopi Arabika hasil sangrai yang terbagi menjadi empat kelas yaitu <i>green</i> , <i>light</i> , <i>medium</i> , dan <i>dark</i> . Dengan total data sebanyak 1600 citra yang terbagi menjadi 1200 citra sebagai data <i>training</i> dan 400 citra sebagai data <i>testing</i> .	Metode <i>Deep Learning</i> dan Arsitektur (CNN) <i>Convolutional Neural Network</i> dengan skenario perbandingan nilai <i>epoch</i> 25, 50, dan 75. Menggunakan <i>hyperparameter</i> dengan total 5 layer konvolusi dan jumlah filter pada layer pertama sebanyak 32 filter, layer kedua 64 filter, layer ketiga 128 filter, layer keempat 64 filter dan layer ke lima 32 filter dengan kernel size 3 x 3, <i>MaxPooling2D</i> (2x2) dengan ukuran <i>batch size</i> 32.	Hasil kinerja arsitektur CNN dikatakan efektif dalam klasifikasi kualitas biji kopi dibuktikan dengan hasil pengujian model menunjukkan akurasi 89% pada <i>epoch</i> 25, 97% pada <i>epoch</i> 50, dan 100% pada <i>epoch</i> 75. Hasil model dengan <i>epoch</i> 75 digunakan sebagai pengembangan <i>website</i> karena memiliki akurasi terbaik.

## 2.2 DASAR TEORI

### 2.2.1 Kopi

Kopi merupakan minuman yang dihasilkan dari proses seduhan biji kopi yang telah disangrai dan dihaluskan. Tanaman kopi memiliki peranan penting sebagai sumber pendapatan bagi masyarakat serta berkontribusi dalam meningkatkan pendapatan atau devisa negara melalui ekspor biji kopi mentah maupun kopi hasil olahan. Melalui penanaman dan penjualan biji kopi, orang dapat menghasilkan pendapatan yang berkelanjutan. Hasil panen kopi yang baik dan harga yang menguntungkan dapat memberikan pendapatan yang lebih tinggi. Selain itu, dalam industri kopi, ada juga kesempatan untuk menghasilkan pendapatan melalui proses pemanggangan, penggilingan, pengemasan, dan penjualan kopi olahan. Dengan menjalankan usaha kopi yang efisien dan berkualitas, orang dapat menciptakan sumber pendapatan yang stabil dan berkelanjutan dari industri kopi. Kualitas kopi dapat bervariasi tergantung pada proses pengolahannya, semakin baik prosesnya, maka kualitas dan harga kopi akan semakin tinggi. Kata kopi sendiri berasal dari bahasa Arab, yaitu *qahwah* yang memiliki arti kekuatan. Kemudian, kata *coffee* dalam bahasa Belanda kemudian diserap ke dalam bahasa Indonesia menjadi kopi. Biji kopi mengalami proses yang panjang sebelum dapat dinikmati sebagai minuman kopi. Proses ini dimulai dengan panen biji kopi, kemudian dilakukan pengupasan kulit dan pengeringan biji. Selanjutnya, biji kopi mengalami proses penyangraian, dan yang terakhir adalah proses penggilingan atau penghalusan menjadi bubuk kopi agar dapat diseduh dan dinikmati sebagai secangkir kopi [5].

Secara umum terdapat dua jenis biji kopi yang banyak tersedia dipasaran, yaitu jenis Arabika dan Robusta. Kedua jenis biji kopi ini memiliki perbedaan dari segi bentuk dan ukuran biji dan dari segi rasa. Kopi jenis Robusta dikenal memiliki rasa dan aroma yang kuat namun kurang bervariasi, hal ini dikarenakan kandungan kafein yang lebih tinggi sehingga kopi jenis Robusta cenderung lebih pahit. Sedangkan kopi jenis Arabika memiliki variasi rasa yang lebih beragam dan cenderung asam. Karena memiliki variasi rasa yang lebih beragam kopi jenis Arabika lebih banyak diminati pasar dibandingkan kopi jenis Robusta. Kedua jenis

biji kopi ini juga memiliki perbedaan dari segi bentuk dan ukuran. Biji kopi Arabika memiliki ukuran biji yang lebih besar dengan bentuk oval. Sedangkan biji Kopi Robusta memiliki ukuran biji yang lebih kecil dan bentuk yang lebih bulat [14]. Biji Kopi Arabika memiliki ciri khas berupa bentuk biji yang oval dan datar. Rasa yang dihasilkan dari biji kopi ini didominasi oleh rasa asam dan manis namun lembut ketika diminum. Biji Kopi Arabika juga memiliki aroma yang sangat enak, bahkan proses ekstraksi biji kopi ini juga menghasilkan aroma yang menarik dan menyegarkan. Selain itu, tingkat kafein yang dihasilkan oleh biji Kopi Arabika lebih sedikit dibandingkan dengan biji kopi lain.

### 2.2.2 Kualitas Biji Kopi Hasil Sangrai

Proses sangrai kopi memiliki tujuan untuk menciptakan aroma dan cita rasa kopi dengan karakteristik tertentu. Proses sangrai merupakan proses memanggang kopi untuk menghilangkan kadar air dalam biji kopi dengan mengeringkan dan mengembangkan biji kopi. Proses penyangraian atau pemanggangan kopi dapat diatur untuk menentukan tiga aspek utama yang mempengaruhi cita rasa kopi yaitu tingkat keasamannya, kemanisannya, dan pahitnya. Pada umumnya semakin lama proses penyangraian kopi, maka tingkat rasa keasamannya akan semakin berkurang sementara tingkat rasa pahit akan meningkat secara perlahan. Secara umum terdapat tiga tingkat kualitas kematangan biji kopi yang dihasilkan dari proses sangrai :

1. Kualitas Biji Kopi *Light Roast*



**Gambar 2.1** Kualitas biji kopi *light roast* [21].

Pada Gambar 2.1 menunjukkan kualitas biji kopi *light roast* dengan warna yang dihasilkan yaitu coklat tua. Biji kopi pada kualitas ini dipanggang hingga terjadi letupan pertama dengan proses *roasting* pada suhu mencapai 196 sampai 205 derajat celcius. Pada saat tingkatan *light roast* cita rasa yang dihasilkan yaitu asam dan aroma sangrai yang dihasilkan kurang begitu tercium, dikarenakan pada tingkat ini memiliki kematangan yang paling rendah. Kopi dengan kualitas *roasting* pada tingkatan pertama ini memiliki tingkat keasaman dan kadar kafeinnya cukup tinggi. Bagi para penikmat kopi *strong* maka jenis kopi dengan kualitas *light roast* sangat direkomendasikan. Cita rasa yang dihasilkan biasanya khas dengan rasa *citrus*, *earthy* dan *butter* [22].

## 2. Kualitas Biji Kopi *Medium Roast*



**Gambar 2. 2 Kualitas biji kopi *medium roast* [21].**

Pada Gambar 2.2 menunjukkan kualitas biji kopi *medium roast* dengan warna biji kopi yang dihasilkan yaitu coklat tua cenderung gelap. Biji kopi ini dipanggang melewati letupan pertama namun tidak sampai pada letupan kedua, dengan proses *roasting* pada suhu mencapai 210 sampai 219 derajat celcius. Pada tingkatan *roasting* kopi ini cita rasa yang dihasilkan manis dan aroma asap sangat tercium dengan jelas. Pada tingkat sangrai *medium roast* ini merupakan kualitas biji kopi yang paling umum digunakan sebagai minuman kopi. Biji kopi yang dihasilkan pada kualitas ini memiliki warna lebih gelap daripada kualitas biji kopi dengan tingkat sangrai *light roast*. Tingkat *medium roast* ini menghasilkan biji kopi dengan kadar kafein yang rendah dan cita rasa kopi yang cenderung *balance* dengan keasaman yang menghasilkan beragam rasa [22].

### 3. Kualitas Biji Kopi *Dark Roast*



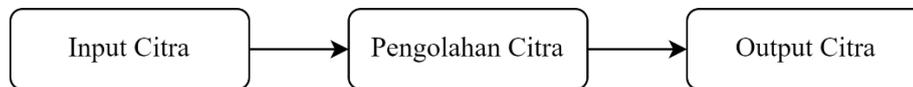
**Gambar 2. 3 Kualitas biji kopi *dark roast* [21].**

Pada Gambar 2.3 menunjukkan kualitas biji kopi *dark roast* dengan warna biji kopi yang dihasilkan yaitu warna gelap. Biji kopi ini dipanggang hingga letupan kedua, dengan proses *roasting* pada suhu sekitar 225 derajat celcius. Pada tahap *roasting* ini memiliki rasa keasaman dan manis yang mulai berkurang, sehingga muncul rasa pahit seiring dengan kenaikan level kematangan biji kopi. Tahap *roasting* ini merupakan tingkatan yang paling tinggi. Jika proses *roasting* melebihi tingkatan ini, biasanya rasa kopi menjadi kurang enak. Cita rasa pada kualitas biji kopi ini cenderung pahit dan menutupi cita rasa serta karakteristik kopi yang sebenarnya. Bagi para penggemar kopi yang menyukai kopi dengan tingkat kekentalan yang tebal, kualitas biji kopi pada tingkat *dark roast* ini sangat cocok untuk dinikmati [22].

#### **2.2.3 Pengolahan Citra Digital**

Citra merupakan salah satu bagian dari informasi berupa teks, suara, video, maupun gambar. Citra dapat dibedakan menjadi dua jenis, yaitu citra analog dan citra digital. Citra analog dihasilkan melalui alat akuisisi citra analog, seperti mata manusia dan kamera analog. Contoh dari citra analog adalah gambar yang dapat dilihat oleh mata manusia atau foto dan video yang diambil menggunakan kamera analog. Sedangkan citra digital merupakan kumpulan matriks yang terdiri dari baris dan kolom yang mewakili titik – titik pada citra, serta dan elemen matriknya. Citra digital tersusun dari sekumpulan piksel (*picture element*) dengan koordinat (x, y)

yang menunjukkan posisi piksel pada citra dan amplitudo  $f(x, y)$  yang menunjukkan nilai intensitas pada warna citra [23]. Pada Gambar 2.4 menunjukkan proses pengolahan citra.



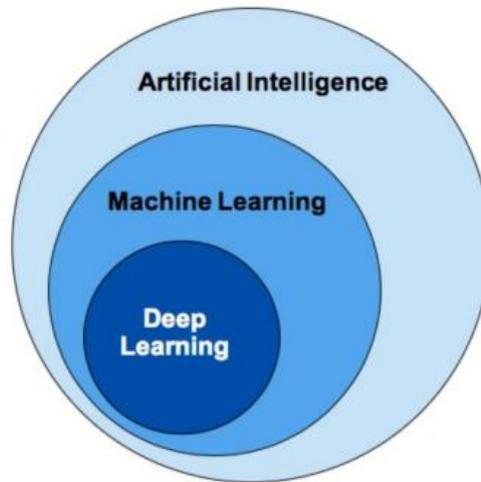
**Gambar 2. 4 Proses pengolahan citra [5].**

Pada Gambar 2.4 merupakan proses pengolahan citra dimulai dari tahap *input* citra kemudian pengolahan citra dan terakhir pada tahap *output* citra. Pengolahan citra merupakan ilmu yang mempelajari teknik dalam mengolah citra, citra yang dimaksud adalah gambar diam (foto) atau gambar yang bergerak (seperti video yang direkam). Sedangkan arti digital adalah pengolahan citra atau gambar yang dilakukan menggunakan komputer secara digital. RGB merupakan singkatan dari *Red-Green-Blue*, merupakan tiga warna dasar (*primary colors*) yang secara umum dijadikan sebagai acuan dari warna lainnya. Dengan menggunakan basis warna RGB, kita dapat mengkonversi warna menjadi kode-kode angka yang membuat representasi warna tersebut menjadi universal. Komputer mengemas informasi warna menjadi model warna yang seragam sehingga membuat pengolahan warna RGB dapat dilakukan dengan mudah [24].

#### **2.2.4 Artificial Intelligence**

Kecerdasan buatan atau *Artificial Intelligence* (AI) adalah teknik yang digunakan untuk meniru kecerdasan yang dimiliki oleh makhluk hidup maupun benda mati untuk menyelesaikan sebuah permasalahan. Tujuan utama dari AI adalah untuk mengetahui atau memodelkan proses berpikir manusia dengan mendesain mesin sehingga dapat menirukan perilaku manusia. AI dibuat berdasarkan sistem yang memiliki keahlian seperti manusia pada domain tertentu yaitu disebut dengan *soft computing*. AI ini mencakup banyak bidang keilmuan, salah satunya sub bidang *machine learning* yang merupakan bidang turunan dari AI yang mampu belajar secara mandiri berdasarkan pada algoritma dan data yang telah diimplementasikan. Sedangkan sub bidang *deep learning* merupakan sistem

turunan dari *machine learning* yang bekerja berdasarkan dataset berskala besar tanpa intervensi manusia [25].

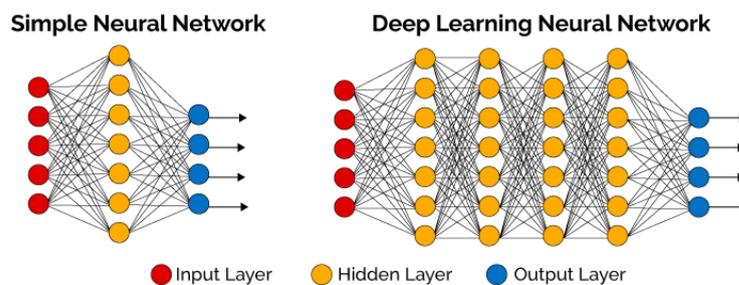


**Gambar 2. 5** Sub bidang *artificial intelligence* [26].

Pada gambar 2.5 menunjukkan sub bidang dari *artificial intelligence* yaitu *machine learning* dan *deep learning*.

### 2.2.5 Deep Learning

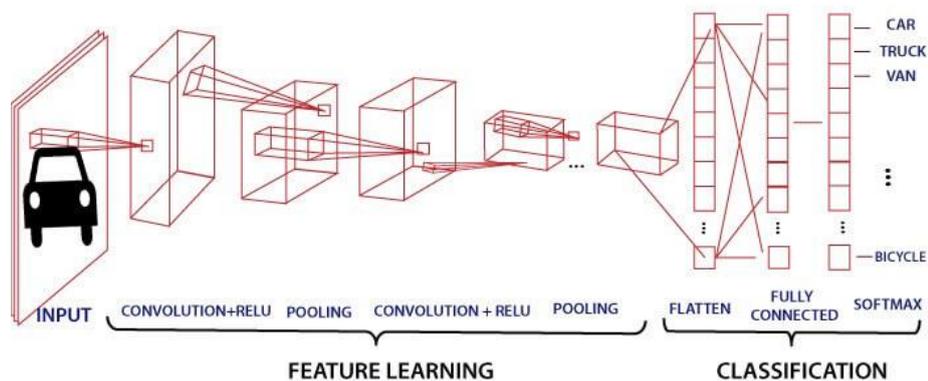
*Deep Learning* merupakan sistem turunan dari bidang *machine learning* yang berbasis jaringan saraf tiruan (*neural network*) untuk mengajari komputer melakukan suatu tindakan untuk menyelesaikan sebuah permasalahan. Dalam *deep learning*, sebuah komputer belajar mengklasifikasi secara langsung dari gambar, teks atau suara. *Deep learning* adalah teknik dalam *neural network* yang menggunakan arsitektur tertentu untuk mempercepat proses pembelajaran dalam *neural network* dengan menggunakan lapisan yang banyak.



**Gambar 2. 6** Lapisan *deep learning* [27].

Pada gambar 2.6 menunjukkan lapisan *deep learning* yang terdiri dari tiga bagian yaitu *input layer*, *hidden layer* dan *output layer*. *Input layer* berisi node-node yang masing-masing menyimpan sebuah nilai masukan yang tidak berubah pada fase latih dan hanya bisa berubah jika diberikan nilai masukan baru. Pada *hidden layer* dapat dibuat beberapa lapisan untuk menemukan komposisi algoritma yang tepat agar meminimalisir error pada *output*. Kemudian *output layer* berfungsi untuk menampilkan hasil perhitungan sistem oleh fungsi aktivasi pada lapisan *hidden layer* berdasarkan input yang diterima. Dengan menambahkan lebih banyak lapisan, model pembelajaran dapat secara lebih efektif mewakili gambaran yang lebih baik tentang data berlabel. *Deep learning* sering digunakan pada komunitas industri dan riset dalam menyelesaikan masalah data besar seperti pada *computer vision*, *speech recognition*, dan *neural language processing* [25].

### 2.2.6 Convolutional Neural Network (CNN)



**Gambar 2. 7** Arsitektur *Convolutional Neural Network* [8].

Gambar 2.7 menunjukkan arsitektur *Convolutional Neural Network* (CNN) yang dirancang khusus untuk mengolah data dua dimensi, CNN merupakan salah satu jenis *Deep Neural Network* karena kedalaman jaringan yang tinggi serta banyak diterapkan pada data klasifikasi citra. Algoritma dari cabang bidang *deep learning* ini dalam satu proses akan mengekstraksi fitur kemudian mengklasifikasi citra. Dapat dikatakan juga dalam proses ekstraksi fitur pada algoritma CNN sebagai proses *learning*. Pada algoritma CNN, konvolusi merupakan operasi yang penting. Konvolusi melibatkan matriks filter yang digunakan untuk mengolah data.

Lapisan konvolusi (*convolutional layer*) dalam CNN bertanggung jawab untuk menerapkan filter pada setiap tahap prosesnya, yang biasa disebut proses pelatihan (*training*).

Dalam proses pelatihan, CNN secara otomatis mempelajari pola-pola penting pada citra melalui penggunaan filter konvolusi. Setiap lapisan konvolusi pada CNN akan mengambil fitur-fitur yang semakin abstrak dan kompleks. Dengan demikian, setiap lapisan konvolusi berfungsi sebagai pengenalan fitur-fitur yang semakin spesifik pada citra. Dengan menggunakan kombinasi lapisan konvolusi dan lapisan lainnya, seperti *pooling layer* dan *fully connected layer*, CNN dapat mengklasifikasikan citra dengan akurasi yang tinggi. Algoritma CNN telah berhasil diaplikasikan dalam berbagai bidang, seperti pengenalan objek, deteksi wajah, dan analisis citra digital [28].

Pada CNN memiliki dua tahapan, yaitu tahap *feature learning* dan *classification*. Pada model CNN, Input gambar umumnya memiliki ukuran 224x224x3. Angka tiga tersebut mengacu pada sebuah citra yang memiliki 3 channel yaitu *Red*, *Green*, dan *Blue* (RGB). Citra inputan akan mengalami proses pengolahan awal melalui konvolusi dan *pooling* pada tahap *feature learning*. Setiap konvolusi memiliki jumlah filter dan ukuran kernel yang berbeda. Selanjutnya, hasil dari layer *pooling* akan diubah menjadi bentuk vektor melalui proses *flatten*. Tahap ini sering disebut sebagai *fully connected layer* [8].

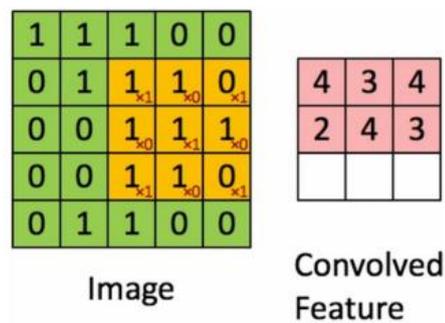
#### **2.2.6.1 Feature Learning**

Pada tahap *feature learning* terdapat dua lapisan utama yaitu lapisan konvolusi (*convolution layer*) dan lapisan penggabungan *pooling layer* dengan fungsi aktivasi yang umumnya digunakan yaitu aktivasi ReLu. Untuk mendapatkan model dengan nilai akurasi terbaik didapatkan dari percobaan pada tahapan ini. Lapisan yang terdapat pada tahap *feature learning* sebagai berikut :

##### **A. Convolution layer**

Layer konvolusi (*convolution layer*) merupakan layer yang pertama kali menerima input gambar langsung pada arsitektur CNN untuk melakukan operasi

konvolusi. *Convolution layer* merupakan lapisan utama yang paling penting untuk digunakan. *Layer* tersebut merupakan proses utama yang mendasari arsitektur CNN. Proses konvolusi menggunakan filter atau kernel sebagai matriks yang digunakan untuk mengubah citra masukan dengan mengalikan setiap elemen citra dengan elemen terkait dalam filter dan menjumlahkan hasilnya [29]. *Convolutional layer* memiliki tugas untuk mendeteksi fitur - fitur lokal tertentu pada seluruh area citra masukan. Lapisan ini berperan sebagai penghubung yang mengubah data masukan menjadi peta fitur (*feature map*) atau peta aktivasi (*activation map*) setelah melalui proses konvolusi [30].



**Gambar 2. 8 Operasi konvolusi [3].**

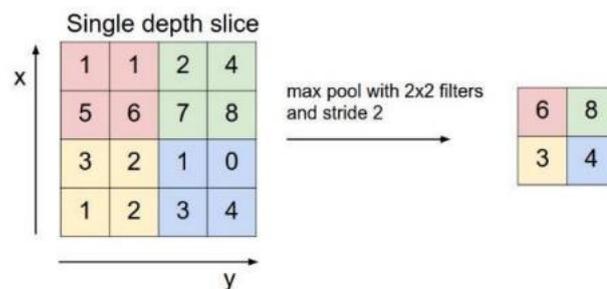
Gambar 2.8 menunjukkan operasi konvolusi untuk mengekstraksi fitur – fitur dari citra input. Melalui proses konvolusi akan menghasilkan transformasi linear dari data input sesuai dengan informasi spasial yang terdapat dalam data tersebut. Bobot pada lapisan konvolusi menentukan kernel konvolusi yang digunakan, sehingga kernel konvolusi dapat diatur dan diperbarui selama pelatihan CNN berdasarkan input data yang diberikan [25].

## **B. Pooling Layer**

*Pooling Layer* merupakan lapisan yang menggunakan fungsi pada *feature map* sebagai masukan dan mengolahnya dengan berbagai macam operasi statistik berdasarkan nilai piksel terdekat. *Pooling layer* pada model CNN biasanya disisipkan secara teratur setelah beberapa lapisan konvolusi dalam model. Penambahan layer *Pooling* di antara lapisan konvolusi secara berurutan dalam arsitektur model CNN secara bertahap mengurangi ukuran output pada peta fitur,

mengurangi jumlah parameter dan perhitungan dalam jaringan, serta membantu mengendalikan *overfitting*.

Penggunaan lapisan *pooling* pada CNN memiliki tujuan untuk mengurangi ukuran citra sehingga dapat digantikan dengan lapisan konvolusi dengan *stride* yang sama dengan lapisan *pooling* tersebut. *Stride* adalah parameter yang mengontrol sejauh mana filter bergeser. Jika nilai *stride* adalah satu, filter akan bergeser satu piksel secara horizontal dan vertikal. Semakin kecil nilai *stride* yang digunakan, semakin detail informasi yang diambil dari input, tetapi juga membutuhkan komputasi yang lebih tinggi dibandingkan dengan nilai *stride* yang lebih besar. *Pooling layer* yang digunakan untuk mengambil nilai maksimal disebut *max-pooling* dan yang mengambil nilai rata-rata disebut *average pooling*. Metode *pooling* yang sering digunakan dalam CNN adalah metode *max-pooling*.



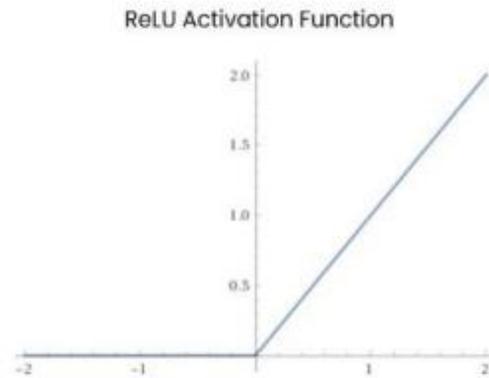
**Gambar 2. 9** Operasi *pooling layer (Max-Pooling)* [31].

Gambar 2.9 menunjukkan operasi *max-pooling* dengan membagi *output* dari lapisan konvolusi menjadi beberapa grid kecil, di mana nilai maksimal dari setiap grid diambil untuk membentuk matriks citra yang telah direduksi [25].

### C. *Activation Function*

Fungsi aktivasi adalah fungsi non-linear yang memungkinkan jaringan saraf tiruan untuk mentransformasikan data masukan ke dimensi yang lebih tinggi. Hal ini memungkinkan untuk melakukan pemisahan yang lebih kompleks melalui pemotongan *hyperplane* sederhana, sehingga memungkinkan untuk dilakukan klasifikasi [32]. Ada beberapa jenis fungsi aktivasi yang biasa digunakan dalam *neural network* yaitu aktivasi ReLU dan fungsi aktivasi *Softmax*. Fungsi aktivasi

ReLU (*Rectified Linear Unit*) adalah jenis fungsi aktivasi yang biasa digunakan dalam model CNN. Fungsi aktivasi ini melakukan *thresholding* dengan nilai 0 terhadap nilai piksel pada input citra. Dengan demikian, fungsi aktivasi ReLU mengganti nilai negatif pada citra dengan nilai 0 [31]. Pada Gambar 2.10 menunjukkan grafik fungsi aktivasi ReLU, apabila  $x \leq 0$  maka  $x = 0$  dan apabila  $x > 0$  maka  $x = x$ .



**Gambar 2. 10 ReLU** [33].

### 2.2.6.2 Classification

Pada tahap *classification* terdapat layer *flatten* dan *fully connected* layer dengan fungsi aktivasi yang digunakan yaitu *softmax*. Berikut penjelasan dari tahapan *classification*:

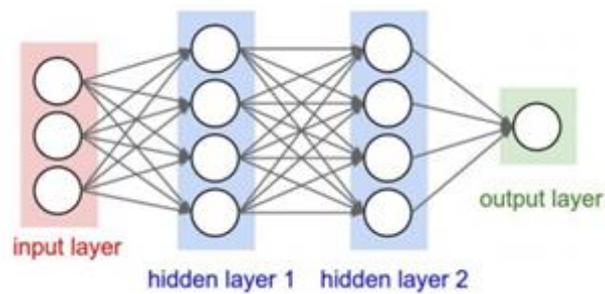
#### A. Flatten

*Flattening* merupakan operasi yang mengubah bentuk fitur (matriks) menjadi vektor satu dimensi. Pada proses ini *flattening* merubah *feature map* dari layer sebelumnya ke dalam vektor satu dimensi agar *feature map* tersebut dapat digunakan sebagai input untuk lapisan selanjutnya yaitu *fully connected layer* [34].

#### B. Fully Connected Layer

*Fully connected layer* merupakan lapisan di mana semua neuron aktivasi dari lapisan sebelumnya terhubung dengan neuron di lapisan berikutnya. *Fully connected layer* biasanya digunakan dalam penerapan *Multi Layer Perceptron*

(MLP) dan bertujuan untuk melakukan transformasi pada dimensi data agar dapat diklasifikasikan secara linear. Perbedaan utama antara *fully connected layer* dan *convolution layer* adalah neuron pada *convolution layer* hanya terhubung ke daerah tertentu pada input, sementara *fully connected layer* memiliki neuron yang secara keseluruhan terhubung. [25].

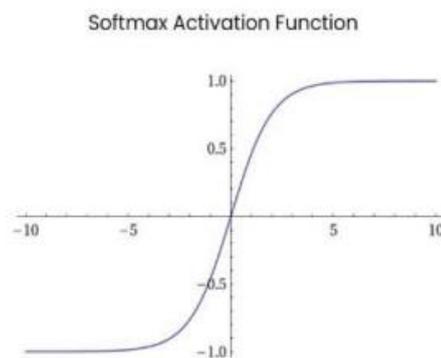


**Gambar 2. 11** Arsitektur *fully connected layer* [36].

Pada Gambar 2.11 menunjukkan arsitektur *fully connected layer* yang terdiri dari *input layer*, *hidden layer*, dan *output layer*. Pada *input layer*, masukan diterima dari tahap *convolution layer* yang kemudian diteruskan ke *hidden layer*. Pada layer ini terdapat bobot di setiap *neuron* dan *output layer* akan menampilkan hasil prediksi dari setiap data [35].

### C. *Softmax Activation*

*Softmax* adalah fungsi aktivasi yang digunakan untuk menghitung probabilitas pada setiap kelas, di mana kelas dengan probabilitas tertinggi akan dijadikan sebagai hasil prediksi. Selain itu, aktivasi *softmax* juga merupakan bentuk lain dari *logistic regression* yang dapat digunakan untuk mengklasifikasikan data lebih dari dua kelas [30]. Fungsi *softmax* digunakan dalam *neural network* untuk menentukan output yang sesuai dengan input yang diberikan [34]. Pada gambar 2.13 merupakan grafik fungsi aktivasi *softmax* dimana vektor bernilai negatif atau lebih besar dari satu akan berada dalam interval (0-1).



**Gambar 2. 12** *Activation function* [34].

### 2.2.7 *Epoch*

*Epoch* merupakan sebuah tahapan dalam *deep learning* dimana seluruh data pelatihan (*training*) diproses secara berulang untuk melakukan proses pembelajaran model. Setiap kali satu siklus penuh dari *feed forward* dan *backward learning* yang telah dilakukan pada seluruh *dataset*, diartikan atau dihitung sebagai satu nilai *epoch*. Dalam konteks jaringan saraf tiruan, proses pembelajaran berulang ini bertujuan untuk melatih komputer agar dapat belajar dan berlatih mengenali data yang telah diinputkan. Karena tidak ada cara pasti untuk menentukan nilai *epoch* yang optimal, maka model perlu melakukan percobaan dengan nilai *epoch* yang sesuai agar dapat menghasilkan nilai akurasi terbaik [37].

### 2.2.8 *Confusion Matrix*

*Confusion matrix* adalah suatu metode evaluasi kinerja model yang digunakan dalam proses klasifikasi. Metode ini merupakan tabel yang digunakan untuk menggambarkan performa model dengan membandingkan nilai prediksi dengan nilai sebenarnya dalam dataset. Dengan menggunakan *confusion matrix*, berbagai teknik evaluasi seperti akurasi, presisi, *recall*, dan F1-score dapat dihitung untuk mengukur kinerja model klasifikasi. [38]. Terdapat empat istilah sebagai representasi hasil proses klasifikasi. Keempat istilah tersebut adalah *True Positive* (TP), *True Negative* (TN), *False Positive* (FP) dan *False Negative* (FN). TP mewakili jumlah kasus positif yang benar-benar diprediksi dengan benar oleh

model, FP mewakili jumlah kasus negatif yang salah diprediksi sebagai positif, FN mewakili jumlah kasus positif yang salah diprediksi sebagai negatif, dan TN mewakili jumlah kasus negatif yang benar-benar diprediksi dengan benar. Pada Tabel 2.2 merupakan hasil kelas prediksi dan kelas sebenarnya dari hasil pengujian data yang dilakukan.

**Tabel 2. 2 Confusion matrix.**

		Prediksi	
		1	2
Kelas Sebenarnya	1	TP ( <i>True Positive</i> )	FN ( <i>False Negative</i> )
	2	FP ( <i>False Positive</i> )	TN ( <i>True Negative</i> )

Pada persamaan 2. 1 menunjukkan rumus untuk menghitung nilai *accuracy* menggunakan metode *confusion matrix*.

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (2.1)$$

TP : Jumlah data kelas positif yang terklasifikasi dengan benar.

FN : Jumlah data kelas negatif namun terklasifikasi salah.

TN : Jumlah data kelas negatif yang terklasifikasi dengan benar.

FP : Jumlah data kelas positif namun terklasifikasi salah

### 2.2.9 Akurasi

Akurasi merupakan ukuran parameter yang menunjukkan ketepatan sistem dalam mengenali inputan yang diberikan sehingga menghasilkan output yang benar [15]. Pada proses penghitungan nilai akurasi dilakukan untuk mengevaluasi

keberhasilan model berdasarkan hasil yang diperoleh saat proses pengujian dalam melakukan klasifikasi, sehingga nilai akurasi digunakan sebagai variabel untuk merepresentasikan kinerja model [12]. Tingkat akurasi menunjukkan tingkat keberhasilan dalam mengklasifikasikan data sesuai dengan jenis yang sebenarnya. Semakin rendah nilai akurasi yang diperoleh, maka semakin tinggi tingkat kesalahan dalam klasifikasi sehingga menghasilkan model yang kurang baik. Sebaliknya jika semakin tinggi nilai akurasi yang diperoleh maka akan menghasilkan model yang baik [25]. Secara matematis, nilai akurasi dapat dituliskan pada rumus persamaan 2.2.

$$\text{Akurasi} = \frac{\text{Jumlah Prediksi Benar}}{\text{Jumlah Total Prediksi}} \times 100\% \quad (2.2)$$

#### **2.2.10 Underfitting dan Overfitting**

*Underfitting* merupakan hasil kinerja sebuah model di mana kesalahan (*error*) dalam proses *training* dan *validation* tinggi dan tidak dapat dikurangi. *Underfitting* terjadi ketika model yang dibangun terlalu sederhana untuk mempelajari pola yang kompleks dalam data pelatihan. Sedangkan *overfitting* merupakan model memiliki kinerja yang baik saat dilatih dengan data *training*, tetapi tidak memberikan hasil yang baik saat diuji dengan data validasi. *Overfitting* terjadi ketika model terlalu rumit atau terlalu banyak beradaptasi dengan data pelatihan.

Untuk mengatasi *underfitting*, langkah-langkah yang dapat diambil antara lain meningkatkan kompleksitas model, menambahkan fitur yang lebih relevan, atau meningkatkan jumlah iterasi pelatihan. Untuk mengatasi *overfitting*, langkah-langkah yang dapat diambil meliputi pengurangan kompleksitas model (misalnya dengan mengurangi jumlah fitur atau menggunakan regularisasi), penggunaan teknik validasi silang, atau pengumpulan data yang lebih banyak untuk melatih model [39].