



## Klasifikasi Jenis Anggur Berdasarkan Bentuk Daun Menggunakan *Convolutional Neural Network* Dan *K-Nearest Neighbor*

Anissa Ollivia Cahya Pratiwi

Universitas PGRI Madiun

Alamat: Jl. Setia Budi No.85, Kanigoro, Kec. Kartoharjo, Kota Madiun,  
Jawa Timur. No. Telp (0351) 462986 Kode Pos 63118.

[anisaolivia193@gmail.com](mailto:anisaolivia193@gmail.com)

**Abstract.** *Grapes belong to the Vitaceae family group whose vines grow and produce dense fruit on their branches, grapes have health benefits for the body's metabolism. Wine has different types of variants, in this study there were 11 types of grape variants used consisting of Auxerrois grapes, Cabernet Franc, Cabernet Sauvignon, Chardonnay, Merlot, Muller Thurgau, Pinot Noir, Resling, Sauvignon Blanc, Syrah and Tempranillo. There are several ways to distinguish the types of grapes, one of which is by looking at the shape of the leaves of the tree. Grape leaves can be observed with the naked eye if people know and understand grape leaves, but if people who don't know or are still beginners don't understand grape leaves, the accuracy is not perfect because there are shapes of grape leaves that have a resemblance. To overcome this problem, an application is needed that makes it easier for the public to classify types of grapes automatically through a series of processing processes for the taste of grape leaves by recognizing the characteristics of the leaves such as the shape of the leaves. This study aims to classify types of grapes based on the shape of the leaves using the convolutional neural network (CNN) and K-nearest neighbor (KNN) methods to determine the types of grapes planted based on the shape of the leaves. The test results for the CNN and KNN methods were measured using a confusion matrix and obtained a result of 99% for CNN and 53% for KNN.*

**Keywords:** *Classification, Convolutional Neural Network, K-Nearest Neighbor Grape Leaves.*

**Abstrak.** Tanaman anggur termasuk golongan keluarga *Vitaceae* yang tanamannya merambat dan mengeluarkan buah lebat pada rantingnya, anggur memiliki manfaat untuk kesehatan metabolisme tubuh. Anggur memiliki jenis varian yang berbeda-beda, dalam penelitian ini terdapat 11 jenis varian anggur yang digunakan terdiri dari anggur *Auxerrois, Cabernet Franc, Cabernet Sauvignon, Chardonnay, Merlot, Muller Thurgau, Pinot Noir, Resling, Sauvignon Blanc, Syrah dan Tempranillo*. Terdapat beberapa cara supaya dapat membedakan jenis anggur salah satunya dengan melihat bentuk daun dari pohon. Daun anggur dapat diamati dengan mata apabila masyarakat tahu dan paham terkait daun anggur tetapi apabila masyarakat yang belum tahu atau masih pemula belum paham tentang daun anggur untuk keakuratannya tidak sempurna karena ada bentuk daun anggur yang memiliki kemiripan. Untuk mengatasi permasalahan tersebut dibutuhkan aplikasi yang memudahkan masyarakat dengan menggolongkan jenis anggur secara otomatis melalui serangkaian proses pengolahan cita daun anggur dengan mengenali karakteristik daun seperti dari bentuk daun. Penelitian ini bertujuan untuk mengklasifikasikan jenis anggur berdasarkan bentuk daun menggunakan metode *convolutional neural network* (CNN) dan *K-nearest neighbor* (KNN) untuk menentukan jenis buah anggur yang ditanam berdasarkan bentuk daun. Hasil pengujian metode CNN dan KNN diukur menggunakan *confusion matrix* dan memperoleh hasil sebesar 99% pada CNN dan untuk KNN 53%.

**Kata kunci:** *Klasifikasi, Convolutional Neural Network, K-Nearest Neighbor, Anggur.*

### LATAR BELAKANG

Tanaman anggur merupakan salah satu jenis tanaman tahunan (*perennial*) yang tumbuh secara merambat dan rantingnya memiliki keistimewaan yaitu dapat mengeluarkan buah yang lebat. Tanaman anggur termasuk dalam golongan *family/keluarga Vitaceae* dan cukup banyak

ditanam di seluruh Negara. Buah anggur dapat di konsumsi secara langsung atau dapat difermentasi menjadi makanan dan minuman. Tanaman anggur memiliki beberapa variasi yang dapat menghasilkan buah anggur dengan jenis yang berbeda-beda. Tanaman anggur memerlukan 4-7 bulan musim kemarau untuk dapatkan intensitas cahaya yang berguna dalam pertumbuhan buah anggur. Buah anggur memiliki kandungan zat *polifenol* dan *resveratol* yang berguna untuk kesehatan metabolisme tubuh, serta dapat menangkal terbentuknya sel kanker, mengurangi gejala *insufisiensi vena kronosis*, meningkatkan daya ingat, melindungi retina mata, menurunkan tekanan darah tinggi, memperlambat penuaan dan penyakit lainnya. (Saputro & Sumantri, 2022:248)

Dengan banyaknya manfaat kandungan dalam buah anggur menjadikan masyarakat berminat untuk menanam atau membudidayakan tanaman anggur untuk dapat di konsumsi secara pribadi. Dengan banyaknya jenis dan varian anggur, mengakibatkan masyarakat kesulitan dalam membedakan tanaman anggur yang dibudidayakan, terkadang masyarakat sering kecewa karena bibit tanaman anggur yang ditanam tidak sesuai dengan hasil buah anggur yang diharapkan. Saat ini, masyarakat mayoritas membedakan jenis anggur berdasarkan karakteristik buah anggur dan membutuhkan waktu yang lama untuk dapat mengetahui jenis anggur.

Metode yang cocok digunakan dalam mempermudah masyarakat dalam membedakan jenis daun anggur yaitu *image classificasion*. Dengan adanya *image classificasion* diharapkan mampu mengelompokkan berbagai jenis gambar daun anggur berdasarkan kelas tertentu. Dengan demikian, *image classificasion* menjadi solusi untuk mempermudah masyarakat dalam membedakan jenis daun anggur berdasarkan karakteristik bentuk daunnya. Jika dilihat berdasarkan data, daun anggur memiliki banyak kesamaan yang sulit untuk dibedakan dengan kasat mata.

Dalam bidang *image classification*, ada beberapa metode yang cocok digunakan dalam mengklasifikasi gambar atau citra. Salah satunya yang sering digunakan adalah metode *Convolutional Neural Network* (CNN) adalah algoritma *Deep Learning* yang efektif dalam memproses dan mengidentifikasi objek dalam gambar yang memungkinkan dapat membedakan satu gambar dengan gambar lain. CNN dirancang dengan menerima gambar yang memiliki kemampuan kuat dalam pengenalan gambar. data gambar. (Iswantoro & Handayani, 2022:901). Keunggulan metode *Convolutional Neural Network* (CNN) adalah metode ini tidak memerlukan ekstraksi khusus untuk mendapatkan fitur yang diperlukan dalam proses klasifikasi. Namun, sangat penting bahwa metode CNN perlu memiliki jumlah data yang besar untuk pelatihan yang efektif, sehingga membutuhkan unit pemrosesan grafis yang memiliki implikasi biaya tambahan. (Magdalena et al., 2021:336) Selain CNN, metode lain yang digunakan adalah *K-Nearest Neighbor* (K-NN). Menurut Arifin et al., (2019:28) *K-Nearest Neighbor* (K-NN) merupakan metode yang memiliki sifat sederhana namun efisien dan efektif dalam pengenalan pola, kategori teks, pengolahan objek dan lain-lain. Dengan menggunakan metode ini sangat cocok untuk menangani jumlah data besar karena kemampuannya melakukan *training* data dengan jumlah yang signifikan.

Dengan adanya penelitian ini diharapkan dapat mengetahui hasil tingkat akurasi dengan menggunakan dua metode yaitu *Convolutional Neural Network* (CNN) dan *K-Nearest Neighbor* (K-NN) dalam mengklasifikasi jenis anggur berdasarkan bentuk daun. Penelitian akan mengaplikasikan kedua metode pada *datasets* citra daun yang sudah tersedia. Dengan

mengaplikasikan *datasets* citra daun, akan diperoleh hasil dari klasifikasi citra yang dilakukan oleh kedua metode. Hasil yang diperoleh akan dibandingkan untuk mengetahui hasil akurasi mana yang lebih akurat dalam mengklasifikasi daun anggur. Kemudian hasil akurasi yang memiliki nilai tinggi akan digunakan untuk mengklasifikasi citra daun anggur. Hasil Penelitian diharapkan dapat memberikan informasi berguna bagi masyarakat untuk menentukan jenis anggur yang ditanam, sehingga memudahkan masyarakat dalam menanam buah anggur yang sesuai dengan keinginannya.

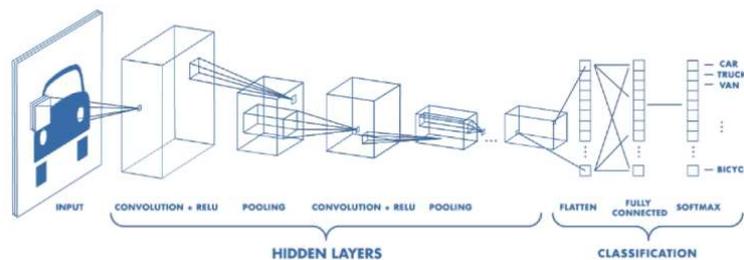
## KAJIAN TEORITIS

Berikut kajian teoritis yang berkaitan dengan penelitian yang dilakukan oleh penulis berdasarkan topik yang relevan.

### A. *Convolutional Neural Network* (CNN)

Pada dasarnya algoritma CNN adalah arsitektur jaringan syaraf tiruan yang lebih efektif untuk klasifikasi citra. Penggunaan operasi konvolusi menjadikan konsep utama pada CNN, di mana fitur pada citra dilakukan ekstraksi yang nanti membentuk pola agar memudahkan proses klasifikasi. Teknik ini menjadi lebih efisien dalam membuat fungsi pembelajaran untuk diimplementasikan. (Satwikayana et al., 2021:789).

Menurut Peryanto et al., (2019:139) secara garis besar konsep utama CNN dibagi menjadi 4 bagian, yaitu *convolution layer*, *pooling layer*, *fully connected layer* and *dropout*. Lapisan ini yang membentuk arsitektur dari CNN yang cocok digunakan dalam pemrosesan *input* berupa gambar. Arsitektur CNN dapat dilihat pada Gambar 1, berikut gambar arsitektur pada CNN:

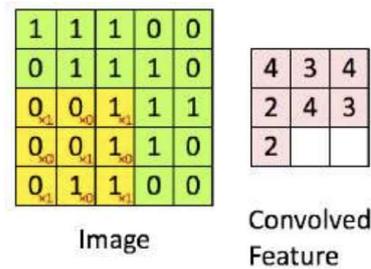


**Gambar 1 Arsitektur Convolutional Neural Network**

Sumber: (Peryanto et al., 2019:139)

#### 1. *Convolutiona Layer*

*Convolutiona layer* adalah lapisan utama dan paling penting pada metode CNN dan menghasilkan citra baru yang menunjukkan fitur dari citra masukkan. *Convolutional layer* terdiri neuron yang tersusun sehingga membentuk filter dengan panjang dan tinggi (*pixel*) (Peryanto et al., 2019:140). Berikut gambar *convolutional layer* dapat dilihat pada Gambar 2

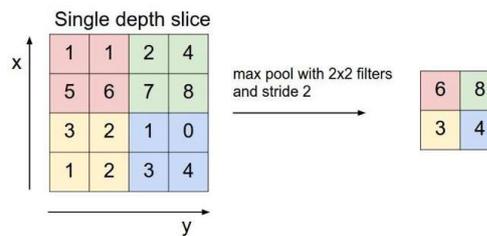


**Gambar 2 Lapisan Konvolusional CNN**

Sumber: (Peryanto et al., 2019:140)

2. *Pooling Layer*

*Pooling layer* adalah fungsi lapisan digunakan untuk *Feature Maps* yang sebagai masukan dan mengolah dengan operasi statistik nilai *piksel* terdekat. Lapisan *pooling* diatur secara berurutan dalam susunan arsitektur model CNN dan secara progresif dapat mengurangi volume *output* pada *Feature Maps*, sehingga dapat mengurangi jumlah parameter dan perhitungan jaringan untuk mengendalikan *overfitting*. Tujuan menggunakan *pooling layer* adalah dapat mengurangi dimensi dari *Feature Maps* (*downsampling*), yang dapat mempercepat komputasi karena parameter harus di *update* untuk mengatasi *overfitting*. (Peryanto et al., 2019:140) Contoh proses dari *pooling layer* dapat dilihat pada Gambar 2.4.

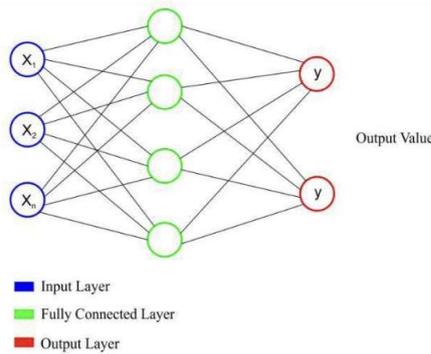


**Gambar 3 Pooling Layer**

Sumber: (Peryanto et al., 2019:140)

3. *Fully Connected Layer*

*Fully connected layer* adalah lapisan aktivitas *neuron* sebelumnya yang terhubung dengan lapisan *neuron* selanjutnya seperti jaringan syaraf tiruan. Setiap aktivitas *neuron* perlu diubah menjadi satu data dimensi untuk dapat dihubungkan ke semua *neuron* pada lapisan *Fully connected*. (Peryanto et al., 2019:141). Berikut gambar *fully connected*, yang dapat dilihat pada Gambar 2.5.

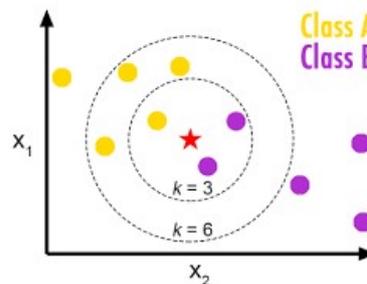


**Gambar 4 Fully Connected Layer**

Sumber: (Peryanto et al., 2019:141)

### B. *K-Nearest Neighbor (KNN)*

KNN adalah algoritma *parametrik* untuk mengklasifikasikan objek. Prinsip dasar dari algoritma ini adalah bahwa objek yang serupa (dengan nilai parameter) harus berada pada jarak yang cukup satu sama lain. Jarak *Euclidean* biasanya digunakan untuk menghitung jarak, tetapi karena metrik yang dipilih dengan benar, dimungkinkan untuk mencapai hasil klasifikasi dan akurasi yang optimal. (Stadnyk et al., 2022:75). Skema K-NN dilihat pada Gambar 5.

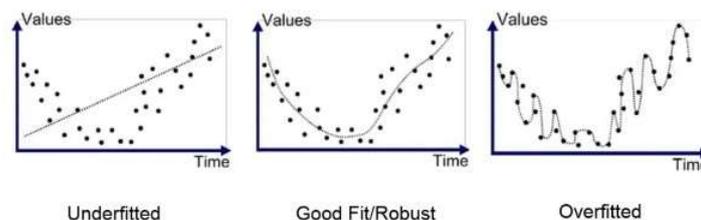


**Gambar 5 K-Nearest Neighbor (KNN)**

Sumber:(Nasri & AW, 2020:3)

### C. *Overfitting*

*Overfitting* adalah di mana model yang di uji tidak dapat memprediksi dengan tepat karena terlalu fokus pada *datasets* pelatihan. Hal ini karena model hanya mempelajari pola yang spesifik pada data pelatihan, sehingga tidak dapat digeneralisasi ke data baru. (Kurnia & Wibowo, 2021:7) Berikut gambar *overfitting* yang dapat dilihat pada Gambar 6.



**Gambar 6 Overfitting**

Sumber: (Kurnia & Wibowo, 2021:7)

#### **D. Tensorflow**

Menurut Goyal et al., (2018:64) dalam bukunya yang berjudul *Deep Learning for Natural Language Processing* menjelaskan tentang *tensorflow*. Jadi menurut Goyal et.al menyatakan bahwa *TensorFlow* adalah *library open source* yang dapat diterapkan oleh *machine learning* dengan skala besar dan dikembangkan oleh Google. *TensorFlow* merupakan lanjutan dari *DistBelief* yang telah dirilis oleh Google sebelumnya dan memiliki kemampuan melatih model besar dengan memanfaatkan kluster komputasi dengan ribuan mesin.

*TensorFlow* adalah dasar untuk implementasi aplikasi seperti *DeepDream*, yang merupakan perangkat lunak teks gambar otomatis, dan *RankBrain*, yang membantu Google memproses hasil pencarian dan memberikan hasil pencarian yang lebih relevan kepada pengguna.

#### **E. Keras**

*Keras* adalah API *deep learning* yang ditulis dengan bahasa pemrograman *python* dan berjalan di atas platform *machine learning TensorFlow*. Untuk dapat mempercepat proses konvolusi dan *recurrent neural networks Keras* berfokus pada perkembangannya. Dalam model *Keras* tidak perlu menulis kode perhitungan matematis satu persatu untuk mengekspresikannya *Keras* hanya perlu menyediakan dan mengoptimalkan model CNN untuk mempermudah penelitian tentang *deep learning*. (Satwikayana et al., 2021:787).

#### **F. Flask**

*Flask* adalah *framework* mikro yang dibangun untuk aplikasi *website* yang menggunakan bahasa pemrograman *python*. *Flask* memiliki beberapa fitur yang mampu memenuhi kebutuhan pengembangan aplikasi *website* selain itu *flask* juga tidak terlalu banyak menggunakan *library* sehingga memiliki sifat yang ringan. Dengan demikian, *flask* dalam membangun aplikasi *website* menggunakan bahasa pemrograman *python* mampu memberikan fleksibilitas dan kesederhanaan.

#### **G. Epoch**

*Epoch* adalah proses pelatihan model dalam satu putaran dengan *datasets* yang ada. Setiap model *epoch* akan memproses semua data pelatihan dan memperbaharui bobot untuk meningkatkan performa. Semakin tinggi nilai *epoch* pola yang dipelajari oleh model semakin kompleks dan tinggi performanya. Namun, *epoch* yang terlalu tinggi dapat mengakibatkan *overfitting* pada data penelitian dan performa data uji menurun. Jadi, pemilihan *epoch* harus dengan tepat dan dihentikan jika nilai dan akurasi tidak mengalami perubahan signifikan. (Kurnia & Wibowo, 2021:7).

#### **H. Confusion Matrix**

*Confusion matrix* adalah *matrix* untuk mengevaluasi klasifikasi dengan memberikan objek yang benar atau salah. *Matrix* membuat tentang informasi nilai yang akurat dan prediksi pada klasifikasi. *Confusion matrix* memiliki empat sel yang mewakili jumlah prediksi benar dan prediksi salah. Dengan *confusion matrix* dapat menghitung *matrix* evaluasi model klasifikasi seperti akurasi, presisi, *recall*, F1-score dan lainnya. (Nawangsih et al., 2021:27)

## METODE PENELITIAN

Metode penelitian yang digunakan dalam penelitian ini melibatkan beberapa tahapan langkah dan urutan yang dilakukan seperti, pengumpulan data dan pemberian label, *preprocessing* data, perancangan CNN dan KNN, pengujian *datasets*, perbandingan hasil uji, perancangan sistem, pembuatan sistem, implementasi sistem dan pengujian sistem. Pada gambar menguraikan tahapan dan urutan kegiatan yang dilakukan oleh penelitian, berikut penjelasan dari tahapan yang dilakukan.

### 1. Pengumpulan data & pemberian label

Pada tahapan pengumpulan data dimulai dengan mencari *dataset* jenis daun anggur yang dapat diperoleh dari *website Kaggle*, pastikan data yang didapatkan memiliki jumlah yang mencakup variasi jenis daun anggur. Selanjutnya, memberikan label pada setiap gambar daun dalam *datasets*, pemberian label dapat disesuaikan dengan informasi yang tersedia di *datasets*.

### 2. *Preprocessing* data

Beberapa langkah tahapan *preprocessing* data yang meliputi, penyesuaian gambar untuk mengubah ukuran gambar menjadi dimensi yang konsisten. Kemudian normalisasi *pixel* yang berguna untuk menjaga konsistensi gambar dalam data dengan melakukan *scaling pixel* rentang yang diharapkan. Terakhir pemisahan *datasets* yang dibagi menjadi set latih, set validasi dan set pengujian yang digunakan untuk melatih model, memonitor performa serta menguji akhir model.

### 3. Perancangan CNN & KNN

Pada perancangan *convolutional neural network* (CNN) tahapan terdiri dari menentukan arsitektur yang melibatkan penentuan jumlah lapisan seperti, konvolusi merupakan operasi inti dalam CNN dengan penggunaan filter (kernel) untuk mengekstrak fitur penting seperti tepi, sudut, dan pola lainnya. *Pooling* digunakan untuk mereduksi dimensi fitur dengan mengambil nilai *max pooling* atau *average pooling* untuk mengurangi *overfitting*. *Fully connected* terdiri dari sejumlah besar neuron, fitur yang telah diubah ke vektor neuron akan menghubungkan fitur kelas yang sesuai. *Output layer* menunjukkan prediksi kelas dari CNN dengan menggunakan fungsi aktivitas *softmax* yang menghasilkan probabilitas kelas. Selanjutnya, inisialisasi bobot untuk membantu mempercepat konvergensi. Kemudian, optimasi dengan mengambil *fine tuning* apabila model tidak memberi kinerja yang memuaskan. Terakhir evaluasi dan validasi untuk mengetahui sejauh mana model dapat memprediksi dengan benar. Sedangkan pada perancangan *K-Nearest Neighbors* tahapan awal yaitu memastikan *datasets* telah melalui tahap *preprocessing*, kemudian menentukan parameter utama KNN yaitu nilai *k* (jumlah tetangga terdekat) yang optimal dengan mencoba beberapa nilai *k*. Selanjutnya, menentukan metrik jarak untuk mengukur jarak antara titik data. Kemudian, pelatihan model dengan menyimpan data latih dengan lengkap tanpa perhitungan yang signifikan. Tahapan selanjutnya pengujian model dengan menggunakan data pengujian yang telah dipisah dengan nilai *K* yang telah ditentukan. Terakhir evaluasi performa dengan menggunakan metrik evaluasi tergantung pada jenis masalah, jika evaluasi performa tidak memuaskan dapat mencoba dengan *fine tuning*.

### 4. Pengujian *datasets*

Pada tahapan pengujian *datasets* dilakukan tahap prediksi untuk menguji performa dan memperoleh hasil yang sesuai. Kemudian hasil prediksi dihitung untuk mengukur performa model dengan menggunakan metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-score*. Hasil pengujian yang kurang baik akan diperbaiki modelnya untuk meningkatkan performa model.

5. Perbandingan hasil uji

Pada tahap perbandingan hasil uji, dilakukan perbandingan dengan metode *convolutional neural network* dan *k-nearest neighbor*, hasil dari kedua metode akan dipilih dengan tingkat akurasi tinggi dengan mengevaluasi dan menggunakan matriks seperti akurasi, presisi, *recall*, dan *F1-score*. Kemudian hasil perbandingan dengan tingkat akurasi tinggi akan diimplementasikan ke dalam *website* klasifikasi jenis anggur berdasarkan bentuk daun anggur.

6. Perancangan sistem

Pada tahapan perancangan sistem terdapat langkah untuk menjelaskan alur kerja aplikasi pada *website* dengan menggunakan *flask* dengan memanfaatkan UML (Unified Modeling Language) serta perancangan *user interface* (antarmuka) sistem.

7. Pembuatan sistem

Tahapan pembuatan sistem dimulai mempersiapkan tempat pembuatan kode program dengan meng-*install python* dan *library* yang dibutuhkan. Kemudian, membuat direktori untuk *template HTML*, file statis, file *Python* dan direktori yang dibutuhkan. Selanjutnya, mengimplementasikan model yang dilatih dan memilih akurasi tinggi ke dalam aplikasi *Flask*. Setelah itu, pada aplikasi *Flask* dibuat *routing* untuk memenuhi kebutuhan pengguna dan supaya lebih menarik dibuat *desain* antarmuka dengan membuat *template HTML*. Kemudian, akan ditambahkan fitur untuk dapat meng-*upload* gambar untuk dapat melakukan prediksi. Terakhir, melakukan pengujian dan validasi pada semua fitur untuk memastikan sistem berjalan dengan baik dan memberikan hasil yang sesuai harapan.

8. Implementasi sistem

Pada tahapan ini sistem yang telah di rancang dan dilakukan pengujian kemudian diimplementasikan dengan menambah *hosting* supaya dapat diakses dengan *online* dan dapat memudahkan pengguna dalam mengklasifikasi jenis daun anggur.

9. Pengujian sistem

Sistem yang telah dibuat atau dibangun akan dilakukan tahap pengujian untuk memverifikasi fungsionalitas fitur pada sistem sesuai dengan alur kerja sistem dan memastikan hasil pelatihan dengan CNN dan KNN dengan proses pengujian menggunakan metode *black box*.

## HASIL DAN PEMBAHASAN

### 1. Perancangan Metode *Convolutional Neural Network* dan *K-Nearest Neighbors*

Pada penelitian ini menggunakan 1009 citra daun anggur yang terdiri dari 11 jenis anggur yang berbeda-beda. Data di *split* menjadi dua yaitu data *training* dan data *validasi*, pembagian *datasets* untuk data *training* sebanyak 80% sedangkan untuk data

validasi sebanyak 20%. Pengujian dilakukan dengan menggunakan metode *convolutional Neural Network* (CNN) dan *K-Nearest Neighbors* (KNN).

**a) Klasifikasi menggunakan *convolutional neural network* (CNN)**

Pada CNN, *convolution layer* dan *pooling layer* dilakukan sebanyak empat kali dengan jumlah filter yang berbeda-beda pada setiap layer, pada lapisan pertama dengan ukuran 32 filter, untuk lapisan kedua dengan ukuran 64 filter, sementara untuk lapisan ketiga 128 filter dan lapisan terakhir berukuran 256 filter. Dengan meningkatkan jumlah filter dapat lebih banyak mempelajari fitur visual yang semakin kompleks. Untuk kombinasi ekstraksi fitur, hasil ekstraksi yang diperoleh digabung kemudian diklasifikasikan dengan *fully connected layer*. Fungsi *Activation* yang digunakan pada model CNN adalah *Activation Relu* dan *Softmax* dengan *optimizer Adam*. Pada model CNN proses *training* dilakukan dengan *epochs* selama dua kali dengan *epochs* 50 dan *epochs* 150 dengan *batch\_size* = 16. *Epochs* berarti berapa kali jaringan akan melihat seluruh kumpulan data, sedangkan *batch\_size* adalah jumlah contoh pelatihan dalam satu *forward/ backward pass*, jadi semakin tinggi nilai *batch\_size* maka semakin banyak memori yang dibutuhkan.

**Tabel 1 Classification Report Epoch=50**

|                           | Precision (%) | Recall (%) | F1-score (%) | Support |
|---------------------------|---------------|------------|--------------|---------|
| <i>Auxerrois</i>          | 94%           | 100%       | 97%          | 44      |
| <i>Cabernet franc</i>     | 96%           | 98%        | 97%          | 44      |
| <i>Cabernet sauvignon</i> | 98%           | 100%       | 99%          | 56      |
| <i>Chardonnay</i>         | 100%          | 98%        | 99%          | 44      |
| <i>Merlot</i>             | 100%          | 93%        | 96%          | 44      |
| <i>Muller thurgau</i>     | 98%           | 98%        | 98%          | 61      |
| <i>Pinot noir</i>         | 100%          | 100%       | 100%         | 44      |
| <i>Resling</i>            | 100%          | 98%        | 99%          | 44      |
| <i>Sauvignon blanc</i>    | 100%          | 91%        | 95%          | 44      |
| <i>Syrah</i>              | 97%           | 100%       | 98%          | 60      |
| <i>Tempranillo</i>        | 96%           | 100%       | 98%          | 44      |
| <i>Accuracy</i>           |               |            | 98%          | 529     |
| <i>Macro avg</i>          | 98%           | 98%        | 98%          | 529     |
| <i>Weighted avg</i>       | 98%           | 98%        | 98%          | 529     |

**Tabel 2 Classification Report Epoch=150**

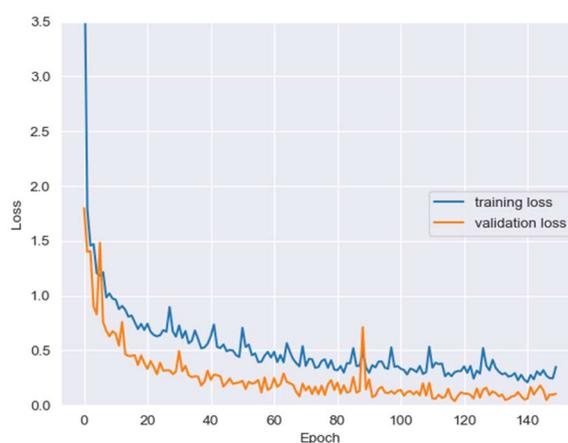
|                           | Precision (%) | Recall (%) | F1-score (%) | Support |
|---------------------------|---------------|------------|--------------|---------|
| <i>Auxerrois</i>          | 100%          | 100%       | 100%         | 44      |
| <i>Cabernet franc</i>     | 98%           | 100%       | 99%          | 44      |
| <i>Cabernet sauvignon</i> | 98%           | 98%        | 98%          | 56      |
| <i>Chardonnay</i>         | 100%          | 100%       | 100%         | 44      |
| <i>Merlot</i>             | 98%           | 98%        | 98%          | 44      |
| <i>Muller thurgau</i>     | 100%          | 97%        | 98%          | 61      |
| <i>Pinot noir</i>         | 100%          | 100%       | 100%         | 44      |

|                        |      |      |      |     |
|------------------------|------|------|------|-----|
| <i>Resling</i>         | 100% | 100% | 100% | 44  |
| <i>Sauvignon_blanc</i> | 98%  | 100% | 99%  | 44  |
| <i>Syrah</i>           | 98%  | 100% | 99%  | 60  |
| <i>Tempranillo</i>     | 100% | 98%  | 99%  | 44  |
| <i>Accuracy</i>        |      |      | 99%  | 529 |
| <i>Macro avg</i>       | 99%  | 99%  | 99%  | 529 |
| <i>Weighted avg</i>    | 99%  | 99%  | 99%  | 529 |

Berdasarkan Tabel di atas hasil pelatihan yang mendapatkan *score* performa tinggi diperoleh pada pengujian model CNN yang menggunakan *epochs* 150. Hasil yang didapatkan dengan *epochs* 150 menunjukkan *accuracy*, *recall*, dan *f1-score* mencapai 99%. Dari hasil pelatihan data *training* dan data *validasi* dapat divisualisasikan ke dalam plot/grafik sebagai berikut.



**Gambar 7 Visualisasi metrik akurasi pelatihan model CNN**



**Gambar 8 Visualisasi metrik loss pelatihan model CNN**

Berdasarkan Gambar dan Gambar disimpulkan bahwa proses pembelajaran dan validasi dengan menggunakan model CNN memiliki *accuracy* tinggi dan nilai *loss*

yang rendah, berarti model CNN bisa mengklasifikasikan citra daun anggur dengan baik.

**b) Klasifikasi menggunakan *k-nearest neighbors* (KNN)**

Pada model KNN tahapan *preprocessing* dilakukan *grayscale* untuk mengurangi dimensi warna dari citra dan dapat mengurangi kompleksitas perhitungan dalam proses pelatihan model. Dengan menggunakan perhitungan nilai K 1, 3, 5, kenapa memilih nilai K 1, 3, 5 karena dapat menghindari situasi keimbangan dalam kelas ketika melakukan voting mayoritas jadi dengan menggunakan nilai K bilangan ganjil selalu ada keputusan mayoritas yang jelas. Perhitungan jarak pada KNN dilakukan menggunakan teknik silang di mana data akan di *split* menjadi 2 yaitu data *training* dan data *validasi*. Hasil klasifikasi yang diperoleh dari model KNN dapat dilihat pada Tabel 1, Tabel 4 dan Tabel 5.

**Tabel 3 Classification Report K=1**

|                           | Precision (%) | Recall (%) | F1-score (%) | Support |
|---------------------------|---------------|------------|--------------|---------|
| <i>Auxerrois</i>          | 71%           | 67%        | 69%          | 18      |
| <i>Cabernet_franc</i>     | 50%           | 33%        | 40%          | 9       |
| <i>Cabernet_sauvignon</i> | 57%           | 42%        | 48%          | 19      |
| <i>Chardonnay</i>         | 46%           | 61%        | 52%          | 28      |
| <i>Merlot</i>             | 43%           | 55%        | 48%          | 11      |
| <i>Muller_thurgau</i>     | 57%           | 59%        | 58%          | 29      |
| <i>Pinot_noir</i>         | 33%           | 23%        | 27%          | 13      |
| <i>Resling</i>            | 53%           | 47%        | 50%          | 17      |
| <i>Sauvignon_blanc</i>    | 57%           | 72%        | 63%          | 18      |
| <i>Syrah</i>              | 67%           | 58%        | 62%          | 24      |
| <i>Tempranillo</i>        | 44%           | 44%        | 44%          | 16      |
| <i>Accuracy</i>           |               |            | 53%          | 202     |
| <i>Macro avg</i>          | 52%           | 51%        | 51%          | 202     |
| <i>Weighted avg</i>       | 54%           | 53%        | 53%          | 202     |

**Tabel 4 Classification Report K=3**

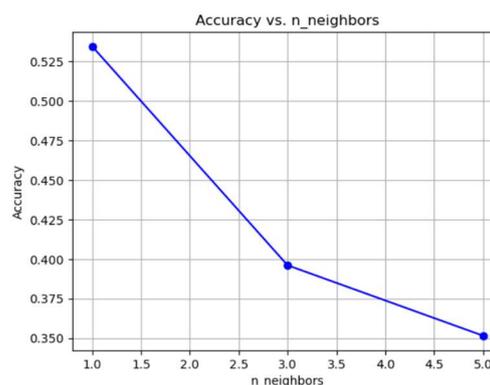
|                           | Precision (%) | Recall (%) | F1-score (%) | Support |
|---------------------------|---------------|------------|--------------|---------|
| <i>Auxerrois</i>          | 41%           | 61%        | 49%          | 18      |
| <i>Cabernet_franc</i>     | 33%           | 33%        | 33%          | 9       |
| <i>Cabernet_sauvignon</i> | 26%           | 32%        | 29%          | 19      |
| <i>Chardonnay</i>         | 33%           | 46%        | 38%          | 28      |
| <i>Merlot</i>             | 41%           | 64%        | 50%          | 11      |
| <i>Muller_thurgau</i>     | 41%           | 41%        | 41%          | 29      |
| <i>Pinot_noir</i>         | 20%           | 8%         | 11%          | 13      |
| <i>Resling</i>            | 36%           | 29%        | 32%          | 17      |

|                        |     |     |     |     |
|------------------------|-----|-----|-----|-----|
| <i>Sauvignon_blanc</i> | 53% | 44% | 48% | 18  |
| <i>Syrah</i>           | 71% | 50% | 59% | 24  |
| <i>Tempranillo</i>     | 33% | 12% | 18% | 16  |
| <i>Accuracy</i>        |     |     | 40% | 202 |
| <i>Macro avg</i>       | 39% | 38% | 37% | 202 |
| <i>Weighted avg</i>    | 40% | 40% | 39% | 202 |

**Tabel 5 Classification Report K=5**

|                           | <i>Precision (%)</i> | <i>Recall (%)</i> | <i>F1-score (%)</i> | <i>Support</i> |
|---------------------------|----------------------|-------------------|---------------------|----------------|
| <i>Auxerrois</i>          | 42%                  | 44%               | 43%                 | 18             |
| <i>Cabernet_franc</i>     | 25%                  | 11%               | 15%                 | 9              |
| <i>Cabernet_sauvignon</i> | 27%                  | 21%               | 24%                 | 19             |
| <i>Chardonnay</i>         | 42%                  | 50%               | 46%                 | 28             |
| <i>Merlot</i>             | 39%                  | 64%               | 48%                 | 11             |
| <i>Muller_thurgau</i>     | 39%                  | 48%               | 43%                 | 29             |
| <i>Pinot_noir</i>         | 10%                  | 8%                | 9%                  | 13             |
| <i>Resling</i>            | 19%                  | 35%               | 25%                 | 17             |
| <i>Sauvignon_blanc</i>    | 44%                  | 44%               | 44%                 | 18             |
| <i>Syrah</i>              | 57%                  | 33%               | 42%                 | 24             |
| <i>Tempranillo</i>        | 0%                   | 0%                | 0%                  | 16             |
| <i>Accuracy</i>           |                      |                   | 35%                 | 202            |
| <i>Macro avg</i>          | 31%                  | 33%               | 31%                 | 202            |
| <i>Weighted avg</i>       | 34%                  | 35%               | 34%                 | 202            |

Berdasarkan Tabel di atas menunjukkan bahwa *score* tertinggi diperoleh pada pengujian dengan nilai  $K = 1$ . Hasil yang didapatkan yaitu *accuracy* sebesar 53%, *precision* 52%, *recall* dan *f1-score* 51% sedangkan *score* terendah diperoleh pada pengujian dengan nilai  $K = 5$  dengan *accuracy* sebesar 35%, *precision* sebesar 31%, *recall* sebesar 33%, dan *f1-score* sebesar 31%.



**Gambar 9 Visualisasi Akurasi Model K-Nearest Neighbors (K-NN)**

Berdasarkan Gambar disimpulkan bahwa semakin besar nilai  $K$  maka semakin rendah *score* performa yang dihasilkan, tetapi besarnya nilai  $K$  tidak mempengaruhi tingginya *score* performa yang dihasilkan.

## 2. Perbandingan Skor Hasil Klasifikasi

Dari hasil model CNN dan KNN dapat dilihat bahwa hasil penilaian yang menunjukkan kinerja dengan baik dalam melakukan klasifikasi citra yaitu menggunakan model CNN karena model CNN memiliki nilai *accuracy* tertinggi.

**Tabel 6 Perbandingan Skor Klasifikasi**

|                                     | <i>Accuracy</i> | <i>Precision</i> | <i>Recall</i> | <i>F1-Score</i> |
|-------------------------------------|-----------------|------------------|---------------|-----------------|
| <i>Convolutional Neural Network</i> | 99%             | 99%              | 99%           | 99%             |
| <i>K-Nearest Neighbors (K-NN)</i>   | 53%             | 52%              | 51%           | 51%             |

Hasil evaluasi kinerja model yang dilakukan, terbukti bahwa dalam megklasifikasi citra *Convolutional Neural Network (CNN)* memberikan hasil dengan tingkat akurasi sebesar 99%. Tingkat akurasi tinggi model pada CNN dapat dengan mudah mengenali serta memprediksi citra daun anggur dengan sangat akurat. Sedangkan pada model *K-Nearest Neighbors (K-NN)* mendapatkan akurasi sebesar 53%, di mana *K-Nearest Neighbors* dalam memprediksi citra daun anggur masih memberikan hasil prediksi yang kurang bagus. Namun, dengan menggunakan model *K-Nearest Neighbors* dapat membandingkan dalam pemrosesan data.

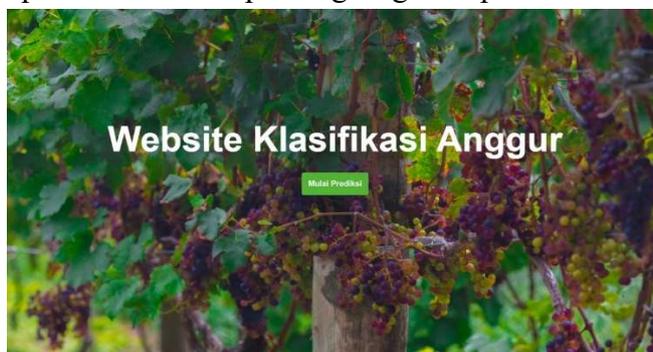
Tingkat akurasi yang tinggi pada model CNN yaitu sebesar 99% akan dijadikan model utama dalam mengaplikasi pada *website* klasifikasi daun anggur, karena model CNN memiliki ketepatan dan memberikan hasil yang akurat dalam mengenali citra daun anggur.

### 3. Implementasi Sistem

Implementasi sistem merujuk pada proses mengubah sistem yang telah ada menjadi bentuk yang dapat berfungsi secara nyata. Tujuan implementasi sistem untuk mengubah *desain* sistem menjadi solusi yang berfungsi memenuhi kebutuhan, dan memberikan ketersediaan serta kinerja yang baik. Berikut tampilan dari *website* klasifikasi jenis anggur berdasarkan bentuk daun:

#### a) Tampilan halaman mulai prediksi

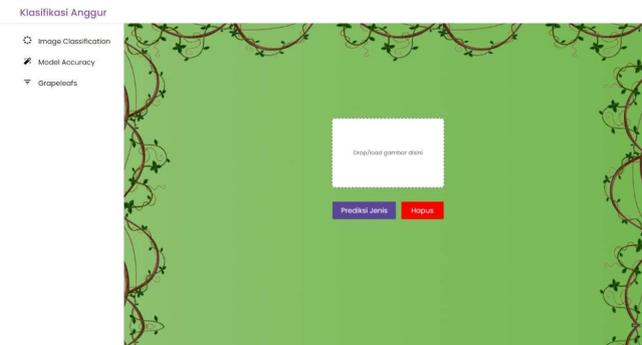
Pada tampilan mulai prediksi terdapat *button* mulai prediksi, yang nanti akan langsung menuju pada halaman prediksi untuk dapat langsung memprediksi citra daun anggur.



**Gambar 10 Tampilan Halaman Mulai Prediksi**

#### b) Tampilan halaman prediksi

Pada tampilan halaman prediksi terdapat tempat untuk menginput atau load gambar citra daun. Di halaman ini juga terdapat *button* prediksi jenis dan hapus, dapat digunakan untuk memproses atau memprediksi citra daun yang sudah di *input*, sementara untuk *button* hapus digunakan untuk menghapus citra daun anggur jika ingin berganti dalam memprediksi citra daun anggur. Pada halaman ini juga akan menampilkan hasil prediksi citra daun yang di *input*.



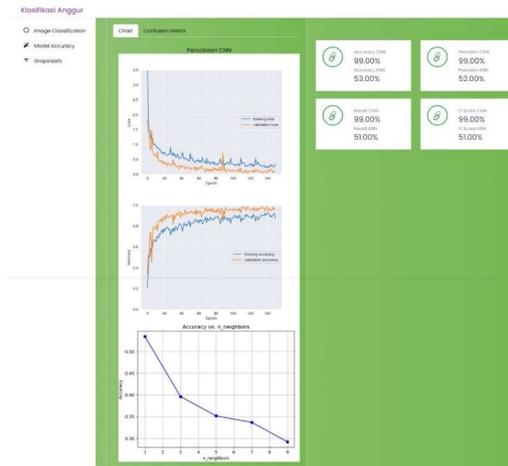
**Gambar 11 Tampilan Halaman *Input* Gambar**



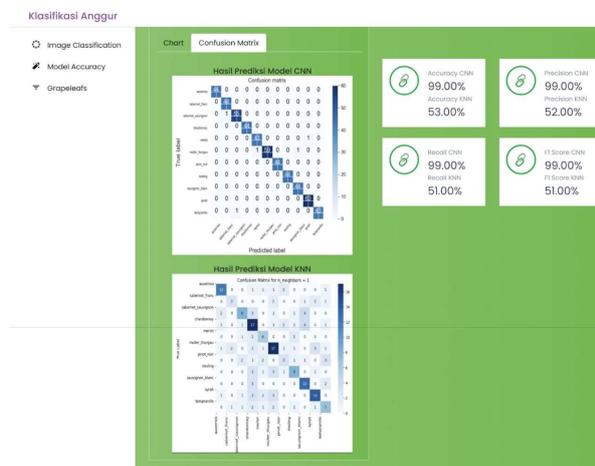
**Gambar 12 Tampilan Halaman Hasil Prediksi**

**c) Tampilan halaman akurasi**

Pada tampilan halaman akurasi terdapat pilihan *chart* dan *confusion matrix*, untuk *chart* memberikan informasi terkait grafik model CNN dan KNN, sementara *confusion matrix* memberikan informasi tentang *confusion matrix* model CNN dan KNN.



**Gambar 13 Tampilan Halaman Akurasi Chart**



**Gambar 14 Tampilan Halaman Akurasi Confusion Matrix**

**d) Tampilan halaman jenis anggur**

Tampilan pada jenis daun anggur menampilkan gambar daun anggur yang sering ditanam atau dibudidayakan oleh masyarakat. Informasi jenis anggur berguna untuk lebih mengenal jenis daun anggur dan macam-macam anggur.



**Gambar 15 Tampilan Halaman Jenis Daun Anggur**

**4. Pengujian**

Pengujian dilakukan untuk menjamin kualitas dan juga mengetahui kelemahan dari perangkat lunak. Pengujian pada *website* klasifikasi jenis daun anggur ini menggunakan metode *black box* dan metode SUS (*system usability scale*). Berikut beberapa dilakukan kasus pengujian dan hasil pengujiannya:

**a) Pengujian menggunakan metode SUS (*system usability scale*)**

Hasil pengujian menggunakan metode SUS (*system usability scale*) yang dilakukan oleh peneliti dengan membagikan kuesioner SUS menggunakan *google form*. Dengan jumlah responden kuesioner SUS berjumlah 20 orang yang merupakan *user* yang pernah menggunakan atau mengakses aplikasi klasifikasi jenis anggur berdasarkan bentuk daun. Kuesioner berisikan 8 pertanyaan dengan lima opsi jawaban yaitu, (1) sangat tidak setuju, (2) tidak setuju, (3) tidak berpendapat, (4) setuju, (5) sangat setuju. Berikut pada tabel pertanyaan kuesioner SUS yang digunakan.

**Tabel 7 Pertanyaan Kuesioner SUS**

| No | Pertanyaan  |
|----|---|
| 1. | Informasi yang ditampilkan oleh sistem cukup jelas dan mudah dipahami                 |
| 2. | Tata letak dan desain antarmuka menyulitkan dalam berinteraksi dengan aplikasi        |
| 3. | Informasi terkait tingkat keakuratan yang diberikan oleh aplikasi sangat jelas        |
| 4. | Merasa tidak puas dengan kecepatan respons aplikasi saat melakukan proses klasifikasi |
| 5. | Pengunggahan gambar daun anggur untuk klasifikasi cukup mudah dan intuitif            |
| 6. | Fitur dan fungsionalitas aplikasi tidak sesuai dengan yang diterapkan                 |

|     |  |
|-----|--|
| 7.  | Hasil klasifikasi yang diberikan sangat memuaskan dan memberikan informasi yang berguna tentang jenis anggur |
| 8.  | Dalam proses klasifikasi aplikasi sulit untuk berinteraksi   |
| 9.  | Proses interaksi dengan aplikasi responsif terhadap tindakan yang dilakukan                                  |
| 10. | Aplikasi terlalu banyak langkah yang harus diikuti dalam klasifikasi citra daun anggur                       |

Setelah mendapatkan hasil kuesioner dari responden, penulis melakukan perhitungan menggunakan *Microsoft Excel*. Untuk melanjutkan konversi tanggapan responden dengan cara:

1. Pertanyaan ganti, yaitu: 1, 3, 5, 7, dan 9 skor yang diberikan oleh responden dikurangi dengan 1.

$$\text{Skor SUS ganjil} = \sum Px - 1$$

2. Pernyataan genap, yaitu 2, 4, 6, 8, dan 10 skor yang diberikan oleh responden digunakan untuk mengurangi 5.

$$\text{Skor SUS genap} = \sum 5 - Pn$$

3. Hasil dari konversi tersebut selanjutnya dijumlahkan untuk setiap responden kemudian dikalikan dengan 2,5 agar mendapatkan rentang nilai antara 0 – 100.

$$(\sum \text{skor ganjil} - \sum \text{skor genap}) \times 2,5$$

4. Setelah skor masing-masing responden telah diketahui selanjutnya adalah mencari skor rata-rata dengan cara menjumlah semua hasil skor dan dibagi dengan jumlah responden yang ada. Perhitungan dapat dilihat dengan rumus:

$$\bar{X} = \frac{\sum x}{n}$$

Berikut adalah hasil yang didapatkan dari perhitungan akhir. Dapat dilihat pada gambar tabel berikut ini.

**Tabel 8 Nilai Perhitungan Akhir SUS**

| Skor Hasil Hitung |    |    |    |    |    |    |    |    |     | Jumlah<br>SUS Raw<br>Score | SUS<br>Final<br>Score |
|-------------------|----|----|----|----|----|----|----|----|-----|----------------------------|-----------------------|
| Q1                | Q2 | Q3 | Q4 | Q5 | Q6 | Q7 | Q8 | Q9 | Q10 |                            |                       |
| 4                 | 2  | 5  | 3  | 4  | 1  | 5  | 2  | 4  | 1   | 31                         | 78                    |
| 5                 | 2  | 4  | 2  | 5  | 1  | 5  | 2  | 5  | 1   | 32                         | 80                    |
| 4                 | 2  | 4  | 1  | 5  | 3  | 5  | 1  | 3  | 1   | 29                         | 73                    |
| 5                 | 1  | 4  | 1  | 5  | 2  | 5  | 2  | 5  | 1   | 31                         | 78                    |
| 5                 | 3  | 4  | 2  | 5  | 1  | 5  | 3  | 4  | 1   | 33                         | 83                    |
| 5                 | 1  | 5  | 1  | 4  | 2  | 4  | 1  | 5  | 1   | 29                         | 73                    |
| 2                 | 3  | 5  | 1  | 5  | 3  | 5  | 1  | 4  | 1   | 30                         | 75                    |
| 5                 | 1  | 3  | 1  | 5  | 2  | 4  | 1  | 5  | 1   | 28                         | 70                    |
| 5                 | 2  | 4  | 3  | 4  | 1  | 5  | 2  | 3  | 2   | 31                         | 78                    |
| 5                 | 1  | 3  | 1  | 4  | 2  | 5  | 2  | 5  | 1   | 29                         | 73                    |
| 5                 | 3  | 4  | 2  | 5  | 1  | 5  | 3  | 4  | 2   | 34                         | 85                    |
| 5                 | 3  | 4  | 2  | 5  | 1  | 5  | 3  | 4  | 2   | 34                         | 85                    |
| 1                 | 1  | 4  | 2  | 5  | 3  | 5  | 3  | 4  | 3   | 31                         | 78                    |
| 1                 | 4  | 4  | 1  | 3  | 2  | 5  | 1  | 5  | 1   | 27                         | 68                    |
| 5                 | 3  | 4  | 2  | 5  | 1  | 5  | 3  | 4  | 2   | 34                         | 85                    |

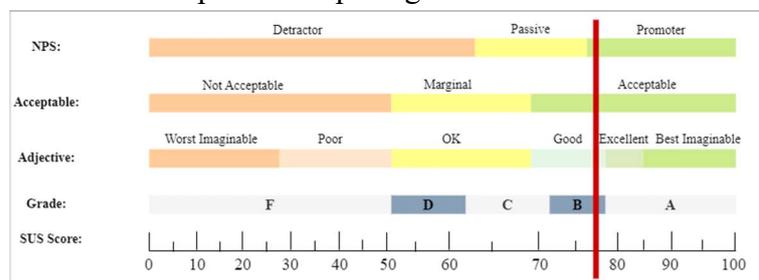
|                              |   |   |   |   |   |   |   |   |   |    |    |
|------------------------------|---|---|---|---|---|---|---|---|---|----|----|
| 1                            | 4 | 4 | 1 | 5 | 1 | 5 | 2 | 5 | 1 | 29 | 73 |
| 5                            | 1 | 5 | 1 | 5 | 1 | 5 | 1 | 5 | 1 | 30 | 75 |
| 5                            | 1 | 4 | 1 | 4 | 1 | 4 | 2 | 5 | 1 | 28 | 70 |
| 5                            | 2 | 4 | 2 | 5 | 1 | 5 | 1 | 5 | 1 | 31 | 78 |
| 5                            | 1 | 5 | 1 | 5 | 1 | 4 | 2 | 5 | 1 | 30 | 75 |
| Skor Rata-tata (Hasil Akhir) |   |   |   |   |   |   |   |   |   |    | 77 |

Penentuan hasil penilaian berdasarkan SUS *score percentile rank* dilakukan secara umum berdasarkan hasil perhitungan penilaian pengguna. Kedua penentuan dapat dilihat di lihat pada tabel

**Tabel 9 SUS Score Percentile Rank**

| Grade | Keterangan                  |
|-------|-----------------------------|
| A     | Skor $\geq$ 80,3            |
| B     | Skor $\geq$ 74 dan $<$ 80,3 |
| C     | Skor $\geq$ 68 dan $<$ 74   |
| D     | Skor $\geq$ 51 dan $<$ 68   |
| E     | Skor lebih $<$ 68           |

Dengan keluaran hasil nilai dari perhitungan nilai akhir SUS, penulis melakukan perhitungan rata-rata dari nilai akhir SUS, nilai rata-rata dari didapatkan dengan cara menjumlahkan nilai akhir SUS kemudian dibagi dengan jumlah responden maka hasil yang didapatkan adalah 77. Dengan begitu nilai ini masuk ke kategori B atau bisa dikatakan baik. Dapat dilihat pada gambar di bawah ini.



**Gambar 16 Hasil Penilaian**

**b) Pengujian menggunakan metode *black box***

Hasil pengujian menggunakan metode *black box testing* ditunjukkan pada tabel.

**Tabel 10 Pengujian Dengan Metode *Black Box***

| No | Menu                     | Hasil  |       | Kesimpulan |
|----|--------------------------|--------|-------|------------|
|    |                          | Normal | Error |            |
| 1. | Menu Beranda             | ✓      |       | Normal     |
|    | Tombol Mulai<br>Prediksi | ✓      |       | Normal     |
| 2. | Menu Prediksi            | ✓      |       | Normal     |
|    | Input Daun Anggur        | ✓      |       | Normal     |
|    | Tombol Prediksi<br>Jenis | ✓      |       | Normal     |
|    | Tombol Hapus             | ✓      |       | Normal     |

|    |                                    |   |        |
|----|------------------------------------|---|--------|
|    | Tampilan Hasil<br>Prediksi         | ✓ | Normal |
| 3. | Menu Akurasi                       | ✓ | Normal |
|    | Tombol <i>Chart</i>                | ✓ | Normal |
|    | Tombol <i>Confusion<br/>Matrix</i> | ✓ | Normal |
| 4. | Menu Jenis Daun<br>Anggur          | ✓ | Normal |

## KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian yang dilakukan, dapat disimpulkan bahwa dalam penelitian ini, peneliti berhasil mengklasifikasikan jenis daun anggur menggunakan dua metode, yaitu *Convolutional Neural Network* (CNN) dan *K-Nearest Neighbor* (K-NN). Prosesnya melibatkan pembuatan model dengan bahasa pemrograman *Python* yang kemudian diimplementasikan dalam bentuk aplikasi klasifikasi jenis daun anggur berbasis *website* menggunakan *framework Flask*. Evaluasi dilakukan terhadap tingkat akurasi dan efisiensi kedua metode menggunakan *confusion matrix* dan *classification report*. Hasil evaluasi menunjukkan bahwa model CNN memiliki tingkat akurasi yang sangat tinggi, mencapai 99%, dengan *precision*, *recall*, dan *f1-score* juga sebesar 99%. Sementara itu, model KNN memiliki tingkat akurasi yang lebih rendah, yaitu 53%, dengan *precision*, *recall*, dan *f1-score* sekitar 52% dan 51%. Dengan demikian, model CNN dianggap sebagai pilihan optimal untuk diimplementasikan dalam sistem klasifikasi jenis daun anggur karena tingkat akurasinya yang lebih tinggi dibandingkan dengan model KNN.

Adapun beberapa saran untuk penelitian selanjutnya adalah meningkatkan jumlah *datasets* dengan melibatkan lebih banyak jenis daun anggur yang beragam, sehingga model yang dikembangkan dapat memiliki kemampuan yang lebih baik dalam mengenali variasi daun anggur dan mencapai tingkat akurasi yang lebih tinggi. Selain itu, pengembangan sistem dapat dilanjutkan dengan menambah fitur *hosting* agar informasi dan analisis terkait daun anggur dapat diakses melalui internet oleh masyarakat secara mudah dan cepat. Selanjutnya, penelitian dapat memperbaiki sistem dengan menyertakan opsi *input* citra melalui fitur kamera, memudahkan pengguna untuk mengidentifikasi daun anggur dengan mengambil gambar langsung dari kamera untuk analisis lebih lanjut. Dengan demikian, penelitian selanjutnya dapat memperbaiki dan meningkatkan sistem klasifikasi jenis daun anggur untuk keperluan yang lebih luas.

## DAFTAR PUSTAKA

- Abdulloh, R. (2022). 7 Materi Pemrograman Web Untuk Pemula.
- Aningtiyas, P. R., Sumin, A., & Wiraman, S. (2020). Pembuatan Aplikasi Deteksi Objek Menggunakan Memanfaatkan SSD MobileNet V2 Sebagai Model TensorFlow Object Detection API dengan Pra-Terlatih. *Jurnal Ilmiah KOMPUTASI*, 19(3), 421–430.
- Apriyanto, R., & Ahsan, M. (2019). Sistem Analisis Diagnosa Penyakit Tanaman Anggur Dengan Pendekatan Certainty Factor Berbasis Android. *Kurawal - Jurnal Teknologi, Informasi Dan Industri*, 2(1), 64–78. <https://doi.org/10.33479/kurawal.v2i1.214>
- Arifianto, J., & Muhimmah, I. (2021). Aplikasi Web Pendeteksi Jerawat Pada Wajah

- Menggunakan Algoritma Deep Learning dengan TensorFlow. *Jurnal Ilmiah Informatika Dan Komputer*, 2(2).
- Arifin, Z., Shudiq, W. J., & Maghfiroh, S. (2019). Penerapan Metode KNN (K-Nearest Neighbor) Dalam Sistem Pendukung Keputusan Penerimaan KIP (Kartu Indonesia Pintar) Di Desa Pandean Berbasis Web Dan MySQL. *Jurnal NJCA*, 4(1).
- Astuti, F. A. (2021). Pemanfaatan Teknologi Artificial Intelligence untuk Penguatan Kesehatan dan Pemulihan Ekonomi Nasional. *Jurnal Sistem Cerdas*, 4(1), 25–34.
- Aurin, K., Fajar, M., & Munir, A. (2021). Pemodelan Jaringan Sensor Nirkabel Menggunakan System Modeling Language. *Jurnal Jtriste*, 8(1), 9–20.
- Chazar, C., & Erawan, B. (2020). Machine Learning Diagnosis Kanker Payudara Menggunakan Algoritma Support Vector Machine. *INFORMASI (Jurnal Informatika Dan Sistem Informasi)*, 12(1), 67–80. <https://doi.org/10.37424/informasi.v12i1.48>
- Derajat, R. M., Sopariah, Y., Aprilianti, S., Candra Taruna, A., Rahmawan Tisna, H. A., Ridwana, R., & Sugandi, D. (2020). Klasifikasi Tutupan Lahan Menggunakan Citra Landsat 8 Operational Land Imager (OLI) di Kecamatan Pangandaran. *Jurnal Samudra Geografi*, 3(1), 1–10. <https://doi.org/10.33059/jsg.v3i1.1985>
- Fatih, M. Al, Riadi, A. A., & Evanita, E. (2022). Identifikasi Tingkat Kematangan Buah Pisang Kepok Berdasarkan Warna Dan Tekstur Dengan Metode K-means. *Jurnal SmartAI*, 1(4), 201–206.
- Felix, F., Faisal, S., Butarbutar, T. F. M., & Sirait, P. (2019). Implementasi CNN dan SVM untuk Identifikasi Penyakit Tomat via Daun. *Jurnal SIFO Mikroskil*, 20(2), 117–134. <https://doi.org/10.55601/jsm.v20i2.670>
- Goyal, P., Pandey, S., & Jain, K. (2018). Deep Learning for Natural Language Processing. In *Lecture Notes in Networks and Systems* (Vol. 190). [https://doi.org/10.1007/978-981-16-0882-7\\_45](https://doi.org/10.1007/978-981-16-0882-7_45)
- Habiba, A. miftahul I., Prasetiadi, A., & Ramdani, C. (2020). Analisis Kesehatan Terumbu Karang Berdasarkan Karakteristik Sungai, Laut, Dan Populasi Area Pemukiman Menggunakan Machine Learning. *IJIS - Indonesian Journal On Information System*, 5(2), 187. <https://doi.org/10.36549/ijis.v5i2.119>
- Herdiansah, A., Borman, R. I., Nurnaningsih, D., Sinlae, A. A. J., & Al Hakim, R. R. (2022). Klasifikasi Citra Daun Herbal Dengan Menggunakan Backpropagation Neural Networks Berdasarkan Ekstraksi Ciri Bentuk. *JURIKOM (Jurnal Riset Komputer)*, 9(2), 388. <https://doi.org/10.30865/jurikom.v9i2.4066>
- Hermawati, F. A., & Zai, R. A. (2021). Sistem Deteksi Pemakaian Masker Menggunakan Metode Viola-Jones dan Convolutional Neural Networks (CNN). *Jurnal KONIK*, 182–187. <https://www.kaggle.com/prithwirajmitra/covid-face-mask>
- Hidayat, D. (2022). Klasifikasi Jenis Mangga Berdasarkan Bentuk Dan Tekstur Daun Menggunakan Metode Convolutional Neural Network (CNN). *Journal of Information Technology and Computer Science (INTECOMS)*, 5(1), 98–103.
- Hidayatullah, V. A. D., Nilogiri, A., & Al Faruq, H. A. (2022). Klasifikasi Siswa Berprestasi Menggunakan Metode K-Nearest Neighbor (KNN) Pada SMA Negeri 2 Situbondo Classification Of Achieving Students Using K-Nearest Neighbor (KNN) Method At SMA Negeri 2 Situbondo. *Jurnal Smart Teknologi*, 3(6), 2774–1702. <http://jurnal.unmuhjember.ac.id/index.php/JST>
- Hutabri, E., & Putri, A. D. (2019). Perancangan Media Pembelajaran Interaktif Berbasis Android pada Mata Pelajaran Ilmu Pengetahuan Sosial untuk Anak Sekolah Dasar. *Jurnal Hasil Penelitian Dan Industri Terapan*, 08(02), 57–64.
- I, R. I. F., Wijaya, D. R., Hernawati, E., & Kom, M. (2020). Pengembangan Aplikasi Machine Learning Menggunakan Algoritma Support Vector Regression Dan Statistical-Based Feature Selection Untuk Memprediksi Kemiskinan Development On Machine Learning

- Application Using Support Vector Regression and Statistical-Based F. *Jurnal Smart Teknologi*, 6(2), 1910–1917.
- Irawan, J., Chusna, N. L., & Hartawan, M. S. (2022). Rancang Bangun Aplikasi Lokasi Stasiun Pengisian Bulk Elpiji ( SPBE ) Berbasis Android Menggunakan GPS ( Studi Kasus PT . Patra Trading ). *Jurnal Ilmiah Informatika Dan Komputer*, 5(1), 1–10.
- Julian, D. (2016). Designing Machine Learning Systems with Python. In *PACKT Publishing open source community experience distilled* (Vol. 53, Issue 9).
- Kurnia, D., & Wibowo, A. T. (2021). Klasifikasi Spesies Tanaman Kaktus Grafting Berdasarkan Citra Scion Menggunakan Metode Convolutional Neural Network (Cnn). *Jurnal Smart Teknologi*, 8(4), 4171.
- Kurniawan, A. A., & Mustikasari, M. (2021). Implementasi Deep Learning Menggunakan Metode CNN dan LSTM untuk Menentukan Berita Palsu dalam Bahasa Indonesia. *Jurnal Informatika Universitas Pamulang*, 5(4), 544–552.
- Lorentius, C. A., Adipranata, R., & Tjondrowiguno, A. (2019). Pengenalan Aksara Jawa dengan Menggunakan Metode Convolutional Neural Network. *Jurnal Ilmiah Sistem Informasi Dan Teknik Informatika (JISTI)*.
- Magdalena, R., Saidah, S., Pratiwi, N. K. C., & Putra, A. T. (2021). Klasifikasi Tutupan Lahan Melalui Citra Satelit SPOT-6 dengan Metode Convolutional Neural Network (CNN). *Jurnal Edukasi Dan Penelitian Informatika (JEPIN)*, 7(3), 335. <https://doi.org/10.26418/jp.v7i3.48195>
- Mait, C. D., Watuseke, J. A., Saerang, P. D. G., & Joshua, S. R. (2022). Sistem Pendukung Keputusan Menggunakan Fuzzy Logic Tahani Untuk Penentuan Golongan Obat Sesuai Dengan Penyakit Diabetes. *Jurnal Media Infotama*, 18(2), 344.
- Maslan, A., Annurrallah, A., & Musnansyah, A. (2022). Predicting the Spread of Covid-19 in Indonesia Using Machine Learning Models. *Jurnal SNISTEK* 4, 441–446.
- mutho, S., Ayu Jufri, W., & Usman, N. (2022). Karakteristik Morfologi Tumbuhan Daun Majemuk. *Jurnal JBES: Journal Of Biology Education And Science*, 2(2), 107–114. <https://jurnal.stkipkieraha.ac.id/index.php/jbes>
- Muthohir, M. (2021). *Mudah Membuat Web Bagi Pemula*.
- Nana, N., Iskandar Mulyana, D., Akbar, A., & Zikri, M. (2022). Optimasi Klasifikasi Buah Anggur Menggunakan Data Augmentasi dan Convolutional Neural Network. *Smart Comp: Jurnalnya Orang Pintar Komputer*, 11(2), 148–161. <https://doi.org/10.30591/smartcomp.v11i2.3527>
- Nasri, E., & AW, A. S. (2020). Aplikasi Seleksi Penentuan Nasabah Untuk Penjualan Barang Secara Kredit Dengan Algoritma K-Nearest Neighbor. *Jurnal Ilmiah Sains Dan Teknologi Universitas Baten Jaya*, 4(1), 1–11.
- Nawangsih, I., Melani, I., & Fauziah, S. (2021). Prediksi Pengangkatan Karyawan Dengan Metode Algoritma C5.0 (Studi Kasus Pt. Mataram Cakra Buana Agung). *Jurnal Pelita Bangsa*, 16(2), 24–33.
- Ngantung, R. K., & Pakereng, M. A. I. (2021). Model Pengembangan Sistem Informasi Akademik Berbasis User Centered Design Menerapkan Framework Flask Python. *Jurnal Media Informatika Budidarma*, 5(3), 1052. <https://doi.org/10.30865/mib.v5i3.3054>
- Novindri, G. F., & Saian, P. O. N. (2022). Implementasi Flask Pada Sistem Penentuan Minimal Order Untuk Tiap Item Barang Di Distribution Center Pada Pt Xyz Berbasis Website. *Jurnal Mnemonic*, 5(2), 81–85. <https://doi.org/10.36040/mnemonic.v5i2.4670>
- Pamungkas, C. A., & Widiyanto, W. W. (2022). Klasifikasi Indeks Pembangunan Manusia Di Indonesia Thaun 2022 Dengan Support Vector Machine. *Jurnal Ilmiah Sistem Informasi Dan Ilmu Komputer*, 2(3), 0–6.
- Paraijun, F., Aziza, R. N., & Kuswardani, D. (2022). Implementasi Algoritma Convolutional Neural Network Dalam Mengklasifikasi Kesegaran Buah Berdasarkan Citra Buah. *Jurnal*

*KiLAT*, 11(1), 1–9.

- Permana, R., Saldu, H., & Maulana, D. I. (2022). Optimasi Image Classification Pada Jenis Sampah Dengan Data Augmentation Dan Convolutional Neural Network. *Jurnal Sistem Informasi Dan Informatika (Simika)*, 5(2), 111–120. <https://doi.org/10.47080/simika.v5i2.1913>
- Peryanto, A., Studi, P., Elektro, T., Dahlan, U. A., Studi, P., Teknik, M., & Dahlan, U. A. (2019). Rancang Bangun Klasifikasi Citra Dengan Teknologi Deep Learning Berbasis Metode Convolutional Neural Network. *Jurnal Format*, 8(2), 138–147.
- Pintanarum, R., Prasetiadi, A., & Ramdani, C. (2021). Klasifikasi Rasa Berdasarkan Citra Buah Menggunakan Algoritma Convolutional Neural Network Dengan Teknik Identitas Ganda. *IJIS - Indonesian Journal On Information System*, 6(1), 79. <https://doi.org/10.36549/ijis.v6i1.132>
- Prasetya, A. F., Sintia, S., & Putri, U. L. D. (2022). Perancangan Aplikasi Rental Mobil Menggunakan Diagram UML (Unified Modelling Language). *Jurnal Ilmiah Komputer Terapan Dan Informasi*, 1(1), 14–18.
- Prastika, I. W., & Zuliarso, E. (2021). Deteksi Penyakit Kulit Wajah Menggunakan Tensorflow Dengan Metode Convolutional Neural Network. *Jurnal Manajemen Informatika Dan Sistem Informasi*, 4(2), 84–91. <https://doi.org/10.36595/misi.v4i2.418>
- Purnamawati, A., Nugroho, W., Putri, D., & Hidayat, W. F. (2020). Deteksi Penyakit Daun pada Tanaman Padi Menggunakan Algoritma Decision Tree, Random Forest, Naïve Bayes, SVM dan KNN. *Jurnal Nasional Informatika Dan Teknologi Jaringan*, 5(1), 212–215. <https://doi.org/10.30743/infotekjar.v5i1.2934>
- Qiudandra, E., Akram, R., & Novianda. (2022). Sistem Pakar Diagnosa Penyakit Osteoarthritis Dengan Menggunakan Metode K-Nearest Neighbor. *Methodika : Jurnal Ilmiah Teknik Informatika*, 2(2), 37–48. <https://ojs.fikom-methodist.net/index.php/methodika/article/view/59>
- Rasyid, M. F., Djafar, I., & Mahersatillah, A. A. (2022). Prediksi Penyebaran Sub Varian Omicron di Indonesia Menggunakan Machine Learning. *Jurnal Seminar Ilmiah Sistem Informasi Dan Teknologi Informasi*, XI(1), 1–7.
- Ren, Y., Wei, W., Zhu, P., Zhang, X., Chen, K., & Liu, Y. (2023). Characteristics, classification and KNN-based evaluation of paleokarst carbonate reservoirs: A case study of Feixianguan Formation in northeastern Sichuan Basin, China. *Energy Geoscience*, 4(3), 100156. <https://doi.org/10.1016/j.engeos.2023.100156>
- Ristiawanto, S. P., Irawan, B., & Setianingsih, C. (2021). Pengenalan Ekspresi Wajah Berbasis Convolutional Neural Network Menggunakan Arsitektur Residual Network-50. *Jurnal EProceedings of Engineering*, 8(5), 6455–6469. <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/16402/16115%0Ahttps://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/16402>
- Romli, I., & Zy, A. T. (2020). Penentuan Jadwal Overtime Dengan Klasifikasi Data Karyawan Menggunakan Algoritma C4.5. *Jurnal Sains Komputer & Informatika (J-SAKTI)*, 4(2), 694–702.
- Rumandan, R. J., Nuraini, R., Sadikin, N., & Rahmanto, Y. (2022). Klasifikasi Citra Jenis Daun Berkhasiat Obat Menggunakan Algoritma Jaringan Syaraf Tiruan Extreme Learning Machine. *Journal of Computer System and Informatics (JoSYC)*, 4(1), 145–154. <https://doi.org/10.47065/josyc.v4i1.2586>
- Santosa, S., Sudin, S., & Kamala, N. S. (2022). Identifikasi Tingkat Kesegaran Ikan Tuna Melalui Citra Mata Menggunakan Metode K-Nearest Neighbor (KNN). *Jurnal PRODUKTIF*, 6(1), 517–524.
- Saputra, O., & Ismail, I. (2022). Klasifikasi Pada Literasi Membaca Buku Oleh Mahasiswa

- Menggunakan Algoritma Random Forest Di Perguruan Tinggi Lampung. *Jurnal Ilmudata.Org*, 2(11), 1–15.
- Saputro, W., & Sumantri, D. B. (2022). Implementasi Citra Digital Dalam Klasifikasi Jenis Buah Anggur Dengan Algoritma K-Nearest Neighbors (KNN) Dan Data Augmentasi. *Journal of Information Technology and Computer Science (INTECOMS)*, 5(2), 248–253.
- Satwikayana, S., Adi Wibowo, S., & Vendyansyah, N. (2021). Sistem Presensi Mahasiswa Otomatis Pada Zoom Meeting Menggunakan Face Recognition Dengan Metode Convulitional Neural Network Berbasis Web. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 5(2), 785–793. <https://doi.org/10.36040/jati.v5i2.3762>
- Septian, I., & Septanto, H. (2022). Pengembangan Model Pendeteksian Gambar Alat Musik dengan Metode Faster R-CNN dengan Library Keras. *Jurnal Mahasiswa Intituti Teknologi Dan Bisnis Kalnis*, 8(1). <http://ojs.kalbis.ac.id/index.php/kalbisiana/article/view/258>
- Seprinas, E., Indriati, I., & Soebroto, A. A. (2019). Klasifikasi Berita Olahraga Berbahasa Indonesia Menggunakan Metode. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 3(10), 9762–9769.
- Setiawan, R. (2016). Teknik Pemecahan Masalah Dengan Algoritma Dan Flowchart. *Angewandte Chemie International Edition*, 6(11), 951–952., 5–24. <https://fliphtml5.com/mynw/aibk>
- Sharma, R., Kumar, A., & Chuah, C. (2021). Turning the blackbox into a glassbox: An explainable machine learning approach for understanding hospitality customer. *International Journal of Information Management Data Insights*, 1(2), 100050. <https://doi.org/10.1016/j.jjime.2021.100050>
- Silva, L. F. de J., Cortes, O. A. C., & Diniz, J. O. B. (2023). A novel ensemble CNN model for COVID-19 classification in computerized tomography scans. *Results in Control and Optimization*, 11(September 2022), 100215. <https://doi.org/10.1016/j.rico.2023.100215>
- Stadnyk, M., Fryz, M., Zagorodna, N., Muzh, V., Kochan, R., Nikodem, J., & Hamera, L. (2022). Steady state visual evoked potential classification by modified KNN method. *Procedia Computer Science*, 207(Kes), 71–79. <https://doi.org/10.1016/j.procs.2022.09.039>
- Susanti, N. A., Walid, M., & Hoisiyah, H. (2022). Klasifikasi Data Tweet Ujaran Kebencian Di Media Sosial Menggunakan Naive Bayes Classifier. *Jurnal JATI (Jurnal Mahasiswa Teknik Informatika)*, 6(2), 538–543.
- Susanto, Y., Tarigan, M., & Yulhendri. (2022). Pengukuran Dan Pendataan Zat Cair Toluene Dengan Akses Rfid Berbasis Nodemcu Esp8266 Yang Termonitor Melalui Web. *SINTAMA: Jurnal Sistem Informasi*, 2(3), 383–395.
- Ula, M., Ulva, A. F., Sistem, P., Fakultas, I., Universitas, T., Unimal, K., Indah, B., Kedokteran, P. S., Kedokteran, F., Malikussaleh, U., & Cunda, K. (2021). Implementasi Machine Learning Dengan Model Case Based Reasoning Dalam Mendagnosa Gizi Buruk Pada Anak. *Jurnal Informatika Kaputama*, 5(2), 333–339.
- Umar, R., Riadi, I., & Farook, D. A. (2020). A Komparasi Image Matching Menggunakan Metode K-Nearest Neightbor (KNN) dan Support Vector Machine (SVM). *Journal of Applied Informatics and Computing*, 4(2), 124–131. <https://doi.org/10.30871/jaic.v4i2.2226>
- Utomo, D. T., Baihaqi, A., Asysyauqi, H., Azizissani, R., Ash'shobir, A. H. A., & Wijaya, H. S. (2022). Perancangan Sistem Penyiraman Otomatis Pada Greenhouse Guna Meningkatkan Kualitas Bibit Tanaman Anggur (*Vitis vinivera*) Di Daerah Sidoarjo. *JEECOM Journal of Electrical Engineering and Computer*, 4(1), 46–50. <https://doi.org/10.33650/jeecom.v4i1.3581>
- Vommi, A. M., & Battula, T. K. (2023). A hybrid filter-wrapper feature selection using Fuzzy

- KNN based on Bonferroni mean for medical datasets classification: A COVID-19 case study. *Expert Systems with Applications*, 218(May 2022), 119612. <https://doi.org/10.1016/j.eswa.2023.119612>
- Yusuf, A., Wihandika, R. C., & Dewi, C. (2019). Klasifikasi Emosi Berdasarkan Ciri Wajah Menggunakan Convolutional Neural Network. *Jurnal Pengembangan Teknologi Dan Ilmu Komputer*, 3(11).
- Zer, P. P. P. A. N. . F. I., Hayadi, B. H., & Damanik, A. R. (2022). Pendekatan Machine Learning Menggunakan Algoritma C4.5 Berbasis Pso Dalam Analisa Pemahaman Pemrograman Website. *Jurnal Informatika Dan Teknik Elektro Terapan*, 10(3). <https://doi.org/10.23960/jitet.v10i3.2700>
- Zuhairi, M., Putra, H. F. T. S., & Dewanta, F. (2022). Rancang Bangun Aplikasi Deteksi Dini Kanker Ovarium Berbasis Android Dengan Expert System. *Jurnal E-Proceeding of Engineering*, 8(6), 3828–3838.