

Klasifikasi Citra Daun Kelapa Sawit Menggunakan Metode KNN dan Naive Bayes

Syahrul Gunawan^{1*}, Nurahman², Lukman Bachtiar³, Depi Rusda⁴

^{1*,2,3,4}Fakultas Ilmu Komputer, Program Studi Sistem Informasi, Universitas Darwan Ali, Sampit, Indonesia

Email: ^{1*}stasyahrul2025@gmail.com, ²nurahman@unda.ac.id, ³lukman.bachtiar@gmail.com,

⁴depi.rusda@unda.ac.id

^{*)} Email Penulis Utama

Abstrak—Kelapa sawit (*Elaeis guineensis*) merupakan komoditas strategis yang berperan penting dalam perekonomian Indonesia, khususnya sebagai penghasil minyak sawit mentah (*Crude Palm Oil*) yang menjadi salah satu komoditas ekspor utama. Produktivitas kelapa sawit sering kali terancam oleh serangan hama daun seperti ulat api (*Setora nitens*), kutu daun (*Aphis gossypii*), tungau merah (*Oligonychus sp.*), dan *Valanga nigricornis*, serta beberapa penyakit seperti *Blight*, *Chlorosis*, *Crinkled Leaf*, dan *Orange Spotting*. Serangan tersebut dapat mengakibatkan penurunan hasil panen yang signifikan, sehingga deteksi dan identifikasi dini menjadi sangat penting. Metode identifikasi manual di lapangan memiliki keterbatasan dalam hal kecepatan, akurasi, dan konsistensi, sehingga dibutuhkan teknologi yang mampu melakukan klasifikasi secara otomatis. Penelitian ini bertujuan membandingkan kinerja algoritma *K-Nearest Neighbor* (KNN) dan *Naive Bayes* dalam mengklasifikasikan hama dan penyakit pada daun kelapa sawit menggunakan pengolahan citra digital. Dataset yang digunakan terdiri dari 3.600 citra beresolusi 800×800 piksel, terbagi dalam sembilan kelas yang mencakup empat jenis penyakit, empat jenis hama, dan satu kelas daun sehat. Tahapan penelitian meliputi pra-proses citra berupa konversi format, *resize*, *crop*, dan penamaan ulang file. Ekstraksi fitur dilakukan melalui analisis warna (nilai rata-rata dan standar deviasi kanal RGB) dan analisis tekstur menggunakan *metode Gray Level Co-occurrence Matrix* (GLCM) dengan parameter *contrast*, *energy*, *homogeneity*, dan *entropy*. Data dibagi menjadi 70% untuk pelatihan dan 30% untuk pengujian, kemudian dilakukan klasifikasi menggunakan KNN dan *Naive Bayes*. Evaluasi kinerja model dilakukan menggunakan metrik akurasi, presisi, *recall*, dan *F1-score*. Hasil penelitian menunjukkan bahwa KNN memiliki kinerja lebih unggul dibandingkan *Naive Bayes*. KNN mencapai akurasi 71% dengan presisi dan *recall* yang relatif seimbang pada seluruh kelas, sedangkan *Naive Bayes* hanya mencapai akurasi 42% dan cenderung tidak seimbang pada beberapa kelas. Temuan ini menunjukkan bahwa KNN lebih sesuai digunakan pada klasifikasi hama daun kelapa sawit berbasis pengolahan citra untuk dataset berukuran sedang dengan variasi tekstur dan warna yang tinggi. Penelitian ini merekomendasikan penerapan KNN dalam sistem deteksi hama otomatis berbasis perangkat bergerak atau *Internet of Things* (IoT) guna membantu petani dan pengelola perkebunan dalam identifikasi cepat dan akurat, sehingga dapat mengurangi kerugian dan mendukung penerapan pertanian presisi di Indonesia.

Kata Kunci: Klasifikasi, KNN, *Naive Bayes*, Kelapa Sawit, Pengolahan Citra.

Abstract—Palm oil (*Elaeis guineensis*) is a strategic commodity that plays an important role in the Indonesian economy, especially as a producer of crude palm oil, which is one of the main export commodities. Oil palm productivity is often threatened by attacks by leaf pests such as fire caterpillars (*Setora nitens*), aphids (*Aphis gossypii*), red mites (*Oligonychus sp.*), and *Valanga nigricornis*, as well as several diseases such as *Blight*, *Chlorosis*, *Crinkled Leaf*, and *Orange Spotting*. These attacks can result in significant reductions in crop yields, so early detection and identification is very important. Manual identification methods in the field have limitations in terms of speed, accuracy and consistency, so technology is needed that is capable of carrying out classification automatically. This research aims to compare the performance of the *K-Nearest Neighbor* (KNN) and *Naive Bayes* algorithms in classifying pests and diseases on oil palm leaves using digital image processing. The dataset used consists of 3,600 images with a resolution of 800×800 pixels, divided into nine classes which include four types of disease, four types of pests, and one class of healthy leaves. The research stages include image *preprocessing* in the form of format conversion, resizing, cropping, and file renaming. Feature extraction is carried out through color analysis (average value and standard deviation of RGB channels) and texture analysis using the *Gray Level Co-occurrence Matrix* (GLCM) method with contrast, energy, homogeneity and entropy parameters. The data is divided into 70% for training and 30% for testing, then classification is carried out using KNN and *Naive Bayes*. Model performance evaluation is carried out using accuracy, precision, recall and *F1-score* metrics. The research results show that KNN has superior performance compared to *Naive Bayes*. KNN achieves 71% accuracy with relatively balanced precision and recall in all classes, while *Naive Bayes* only achieves 42% accuracy and tends to be unbalanced in some classes. These findings indicate that KNN is more suitable for use in image processing-based oil palm leaf pest classification for medium-sized datasets with high variations in texture and color. This research recommends the application of KNN in an automatic pest detection system based on mobile devices or the *Internet of Things* (IoT) to help farmers and plantation managers in fast and accurate identification, so as to reduce losses and support the implementation of precision agriculture in Indonesia.

Keywords: Classification, KNN, *Naive Bayes*, Palm Oil, Image Processing

1. PENDAHULUAN

Kelapa sawit merupakan salah satu komoditas perkebunan utama dunia yang menjadi sumber minyak sawit mentah (*Crude Palm Oil* atau CPO) [1]. Berdasarkan data Statista, luas areal perkebunan kelapa sawit dunia pada tahun 2023 mencapai lebih dari 28 juta hektar [2], dengan total produksi global lebih dari 77 juta ton CPO [3]. Indonesia dan Malaysia menjadi produsen utama, di mana Indonesia menyumbang sekitar 59% dari produksi

dunia [4]. Peran strategis kelapa sawit menjadikannya bukan hanya komoditas lokal, tetapi juga penggerak penting perekonomian global.

Di Indonesia, kelapa sawit memiliki kontribusi signifikan terhadap pembangunan ekonomi nasional. Data Direktorat Jenderal Perkebunan Kementerian Pertanian menunjukkan bahwa pada tahun 2023 luas lahan kelapa sawit nasional mencapai sekitar 16 juta hektar dengan produksi CPO sebesar 46 juta ton [2]. Sebaran perkebunan ini terpusat di Sumatera dan Kalimantan, dengan Kalimantan Tengah menjadi salah satu provinsi penyumbang utama. Badan Pusat Statistik Provinsi Kalimantan Tengah mencatat luas areal sawit provinsi ini mencapai 1,5 juta hektar dengan produksi CPO sekitar 8 juta ton pada tahun 2023 [5]. Kabupaten Kotawaringin Timur merupakan salah satu sentra penghasil kelapa sawit di Kalimantan Tengah, dengan luas lahan 33.915,34 hektar dan produksi sekitar 53.500 ton TBS pada tahun 2024 [6]. Rendahnya produksi ini diduga disebabkan oleh sebagian besar lahan masih dalam fase Tanaman Belum Menghasilkan (TBM) serta gangguan hama dan penyakit tanaman [7]. Hama utama yang sering menyerang antara lain ulat api (*Setothosea asigna*), belalang, kutu daun, dan tungau merah (*Oligonychus spp.*), yang dapat merusak jaringan daun, menghambat fotosintesis, dan menurunkan produktivitas tanaman [8]. Selain itu, gangguan fisiologis seperti *chlorosis*, *defisiensi boron*, *orange spotting*, dan *blight* juga berdampak negatif pada kualitas pertumbuhan [9].

Identifikasi hama pada perkebunan kelapa sawit selama ini masih banyak dilakukan secara manual oleh petugas lapangan. Metode ini memerlukan waktu, tenaga, dan keahlian, serta rentan kesalahan terutama di area perkebunan yang luas. Untuk mengatasi keterbatasan tersebut, pemanfaatan teknologi pengolahan citra digital (*digital image processing*) menjadi solusi yang menjanjikan. Teknologi ini memungkinkan pengambilan citra daun menggunakan kamera digital, diikuti ekstraksi fitur visual seperti warna, bentuk, dan tekstur, yang kemudian dianalisis menggunakan algoritma kecerdasan buatan untuk mengidentifikasi jenis hama [10]. Dalam klasifikasi citra daun kelapa sawit, metode *K-Nearest Neighbor* (KNN) menjadi salah satu pilihan populer karena prinsip kerjanya yang sederhana, yaitu menentukan kelas suatu citra berdasarkan kedekatan jarak pada ruang fitur [11]. Sementara itu, metode *Naive Bayes* mengandalkan pendekatan probabilistik untuk menentukan kelas berdasarkan distribusi fitur yang ada [12]. Penelitian sebelumnya menunjukkan bahwa metode KNN dengan ekstraksi fitur tekstur GLCM mampu mencapai akurasi hingga 93,3% dalam membedakan daun sehat dan daun terinfeksi hama seperti ulat api [11], sedangkan metode *Naive Bayes* dengan fitur warna dan tekstur mampu mencapai akurasi 82% [13].

Implementasi sistem klasifikasi hama berbasis pengolahan citra dan *machine learning* selaras dengan upaya *transformasi* digital industri kelapa sawit yang tengah didorong Kementerian Pertanian melalui Ditjen Perkebunan [14], [15]. Hal ini diharapkan mampu mempercepat deteksi hama, meningkatkan efisiensi pengendalian, serta mendukung penerapan *precision agriculture* yang mengedepankan efisiensi sumber daya dan keberlanjutan [16].

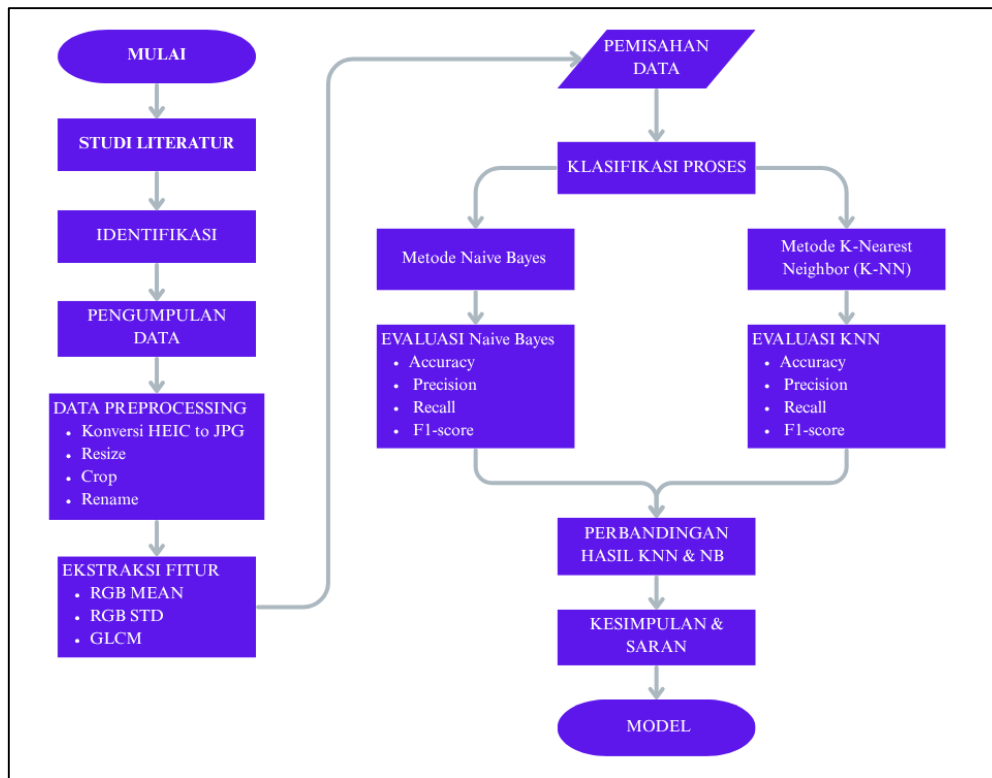
Penelitian ini difokuskan pada penerapan dan perbandingan metode KNN dan *Naive Bayes* dalam klasifikasi hama daun kelapa sawit berbasis citra digital. Evaluasi kinerja dilakukan menggunakan metrik akurasi, presisi, *recall*, dan *F1-score*, untuk menentukan metode yang paling optimal. Kedua algoritma dipilih karena memiliki kompleksitas rendah dan tidak memerlukan sumber daya komputasi besar sehingga berpotensi diimplementasikan pada perangkat bergerak di daerah dengan keterbatasan infrastruktur [17]. Selain sebagai inovasi teknologi, penerapan metode klasifikasi otomatis ini juga memiliki nilai strategis bagi petani dan perusahaan perkebunan. Dengan sistem yang cepat dan akurat, tindakan pengendalian dapat dilakukan lebih dini, sehingga kerugian akibat serangan hama dapat ditekan. Hal ini akan berdampak langsung pada peningkatan produktivitas, penghematan biaya operasional, dan pengurangan penggunaan pestisida berlebihan yang dapat merusak lingkungan. Lebih jauh lagi penerapan teknologi ini mendukung terciptanya sistem pertanian berkelanjutan, yang tidak hanya mengutamakan hasil panen tetapi juga kelestarian ekosistem perkebunan.

Dari sisi akademik, penelitian ini dapat memperkaya literatur mengenai penerapan algoritma klasifikasi pada pengolahan citra pertanian, khususnya pada komoditas kelapa sawit. Kajian ini juga memberikan dasar empiris untuk penelitian lanjutan yang mungkin menggabungkan metode KNN dan *Naive Bayes* dengan algoritma lain yang lebih kompleks, seperti *Support Vector Machine* (SVM) atau *Convolutional Neural Network* (CNN), guna mencapai akurasi yang lebih tinggi. Pengembangan model hibrida juga menjadi peluang untuk menciptakan sistem deteksi yang adaptif terhadap variasi kondisi lapangan dan jenis hama yang lebih beragam. Dengan mempertimbangkan peran strategis kelapa sawit bagi perekonomian nasional serta ancaman serius dari serangan hama, penelitian ini memiliki urgensi tinggi dalam mendukung keberlanjutan sektor perkebunan. Hasil yang diperoleh diharapkan dapat menjadi acuan pengembangan sistem deteksi hama otomatis yang dapat diterapkan secara luas, khususnya di daerah penghasil kelapa sawit utama seperti Kalimantan Tengah dan Kabupaten Kotawaringin Timur.

2. METODE PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menerapkan pendekatan kuantitatif dengan metode eksperimental yang difokuskan pada proses klasifikasi hama pada daun kelapa sawit berbasis pengolahan citra digital. Setiap tahap dilaksanakan secara sistematis sesuai dengan prosedur penelitian komputasional. Seluruh proses dilakukan secara sistematis melalui beberapa tahapan yang ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alur Penelitian

Gambar 1. menunjukkan diagram alur penelitian yang meliputi beberapa tahapan utama, yaitu:

- Studi literatur dilakukan untuk memperoleh pemahaman mendalam tentang pengolahan citra, klasifikasi hama, dan penerapan metode KNN serta *Naive Bayes*. Sumber informasi diperoleh dari jurnal ilmiah, buku, dan artikel terkait [18].
- Identifikasi dilakukan terhadap permasalahan utama dalam pengamatan manual hama pada daun kelapa sawit yang dinilai tidak efisien dan kurang objektif. Oleh karena itu, dibutuhkan sistem otomatis berbasis citra digital [19].
- Pengumpulan data citra dikumpulkan dari daun kelapa sawit yang diperoleh melalui pemotretan langsung di empat lokasi di Kabupaten Kotawaringin Timur. Kamera iPhone 11 digunakan untuk menjamin kualitas dan konsistensi pencahayaan [20]. Gambar disimpan dalam format HEIC dan dikelompokkan dalam sembilan subfolder berdasarkan jenis hama atau kondisi daun.
- Data *preprocessing* tahap ini meliputi:
 - Konversi format HEIC ke JPG menggunakan *library Python* seperti *pyheif* [21]. Format HEIC umumnya digunakan oleh perangkat iOS dan tidak kompatibel langsung dengan banyak sistem pengolahan citra, sehingga perlu dikonversi.
 - Resize* ke ukuran seragam (misalnya 800x800 piksel) menggunakan *OpenCV* [22]. Gambar akan diubah ukurannya ke resolusi tertentu dan disimpan dalam folder tujuan. Proses *resize* ini bertujuan untuk memastikan semua gambar memiliki dimensi yang konsisten agar dapat diproses secara optimal oleh algoritma pengolahan citra. Ukuran yang seragam juga membantu dalam mempercepat proses ekstraksi fitur dan meningkatkan Akurasi model klasifikasi. Selain itu, normalisasi ukuran ini penting untuk mencegah kesalahan komputasi akibat perbedaan resolusi antar gambar.
 - Crop* area daun untuk fokus pada objek utama dan mengurangi *noise* latar belakang [22]. Pemotongan ini penting untuk menyesuaikan area gambar yang akan diekstraksi fiturnya.
 - Citra diberi nama ulang (*rename*) berdasarkan label kelas hama dan nomor urut untuk memudahkan proses klasifikasi. Penamaan dilakukan secara sistematis, misalnya *kutu_daun_1.jpg*, *ulat_api_45.jpg*,

dan seterusnya. Proses ini membantu dalam mengelompokkan gambar sesuai kelas dan memudahkan pelabelan saat pelatihan model klasifikasi.

- e. Ekstraksi fitur proses ekstraksi fitur dilakukan untuk mengambil ciri penting dari citra:
 1. *RGB Mean & RGB Standard Deviation* (STD) untuk fitur warna, menggambarkan distribusi intensitas warna dalam saluran RGB [23],[24].
 2. *GLCM (Gray Level Co-occurrence Matrix)* untuk fitur tekstur, dengan parameter: *contrast, correlation, energy*, dan *homogeneity* [11].
- f. Total citra yang digunakan dalam penelitian ini sebanyak 3600 gambar, dengan masing-masing kelas hama daun kelapa sawit berjumlah 400 gambar. Kelas tersebut terdiri dari: *Blight, Chlorosis, Crinkled Leaf, Daun Sehat, Kutu Daun, Orange Spotting, Tungau Merah, Ulat Api, dan Valanga*. Dataset ini kemudian dibagi menjadi dua bagian, yaitu data latih sebesar 70% (2520 gambar) dan data uji sebesar 30% (1080 gambar). Pembagian dilakukan menggunakan teknik *stratified split* untuk menjaga keseimbangan jumlah data di setiap kelas. Hal ini penting agar model tidak condong pada satu kelas tertentu, serta menghasilkan evaluasi kinerja yang lebih adil dan akurat.
- g. Klasifikasi dua algoritma klasifikasi digunakan:
 1. *K-Nearest Neighbor* (KNN): data dibagi menjadi fitur (X) dan target (y), lalu diproses dengan *train_test_split*, dan dievaluasi menggunakan *scikit-learn* [25].
 2. *Naïve Bayes*: dilakukan dengan cara serupa menggunakan *GaussianNB* dari library *scikit-learn* [26].
- h. Evaluasi model evaluasi dilakukan berdasarkan empat metrik utama:
 1. *Accuracy*: Persentase prediksi yang benar.
 2. *Precision*: Tingkat ketepatan prediksi positif.
 3. *Recall*: Kemampuan model dalam menemukan semua kasus positif.
 4. *F1-score: Harmonic Mean* dari *precision* dan *recall*.
- i. Perbandingan hasil, hasil klasifikasi dari metode KNN dan *Naïve Bayes* dibandingkan berdasarkan empat metrik evaluasi tersebut untuk mengetahui metode yang paling optimal.
- j. Kesimpulan dan saran tahap akhir dari penelitian adalah menyimpulkan hasil klasifikasi dan memberikan rekomendasi untuk penelitian lebih lanjut.

2.2 Metode Pengumpulan Data

Metode pengumpulan data dalam penelitian ini dilakukan melalui pendekatan wawancara, observasi, dan dokumentasi langsung di lapangan. Peneliti mendatangi lokasi penelitian secara langsung untuk melakukan beberapa aktivitas berikut:

- a. Wawancara
Wawancara adalah metode pengumpulan data yang dilakukan secara lisan. Dalam penelitian ini, wawancara dilakukan kepada petani atau pengelola kebun kelapa sawit untuk mendapatkan informasi tentang jenis-jenis hama pada daun kelapa sawit, ciri-cirinya, dan cara penanggulangannya.
- b. Observasi
Observasi adalah kegiatan pengamatan yang dilakukan secara sistematis terhadap objek penelitian. Dalam penelitian ini, peneliti melakukan pengamatan langsung ke kebun kelapa sawit untuk mengetahui, mengumpulkan data, dan memperoleh informasi yang lengkap serta mendalam tentang kondisi daun kelapa sawit yang terserang hama. Observasi ini bertujuan untuk mengetahui jenis hama yang ada, ciri-cirinya, serta kondisi lingkungan kebun saat pengamatan dilakukan.
- c. Dokumentasi
Dokumentasi dilakukan di kebun kelapa sawit menggunakan kamera iPhone 11 dengan resolusi 12 MP untuk merekam dan menyimpan gambar daun kelapa sawit sehat maupun yang terserang hama. Dokumentasi ini bertujuan untuk memperoleh bahan visual yang akurat dan jelas sebagai data utama dalam tahap pengolahan citra dan klasifikasi hama.

2.3 Klasifikasi

Klasifikasi adalah proses sistematis untuk mengelompokkan data, objek, atau informasi ke dalam kategori-kategori tertentu berdasarkan karakteristik atau atribut yang dimiliki. Dalam konteks ilmu komputer dan pengolahan citra, klasifikasi bertujuan untuk memetakan data ke dalam label tertentu dengan menggunakan metode statistik, *machine learning*, atau teknik pengenalan pola.

2.4 KNN (K-Nearest Neighbors)

KNN (*K-Nearest Neighbor*) merupakan algoritma klasifikasi non-parametrik yang menentukan kelas suatu data berdasarkan kedekatannya dengan data lain dalam ruang fitur. Dalam konteks pengolahan citra, KNN

di gunakan untuk mengklasifikasi objek berdasarkan fitur yang diekstraksi dari citra [11]. Berikut langkah-langkah penerapan algoritma KNN meliputi :

- a. Tentukan besaran k (jumlah tetangga) sesuai eksperimen.
- b. Hitung jarak Euclidean antara data uji dan semua data latih.
- c. Urutkan berdasarkan jarak, pilih k data terdekat.
- d. Klasifikasi data uji berdasarkan kelas mayoritas dari k tetangga tersebut.

Untuk menghitung jarak antar data di gunakan rumus *Euclidean distance* berikut :

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \tag{1}$$

Keterangan:

$d(x, y)$: jarak Euclidean antara dua titik atau vektor x dan y

n : jumlah dimensi fitur

x_i : nilai fitur ke- i dari data x

y_i : nilai fitur ke- i dari data y

2.5 Naïve Bayes

Naïve Bayes adalah algoritma klasifikasi probabilistik yang didasarkan pada *Teorema Bayes* dengan asumsi independensi antar fitur. Dalam pengolahan citra, metode ini digunakan untuk mengklasifikasikan objek berdasarkan probabilitas fitur yang diamati [12]. Berikut langkah-langkah penerapan algoritma *Naïve Bayes* meliputi [27]:

- a. *Teorema Bayes*

$$P(C_k | \mathbf{x}) = \frac{P(\mathbf{x} | C_k) P(C_k)}{P(\mathbf{x})} \tag{1}$$

Keterangan:

C_k : kelas ke- k

X : (k_1, k_2, \dots, k_n) vektor fitur

$P(C_k)$: probabilitas prior kelas (prevalensi kelas dalam data latih)

$P(X | C_k)$: *likelihood*-probabilitas data X diberikan kelas C_k

$P(X)$: total probabilitas data X – biasanya diabaikan saat hanya mencari *argmax* kelas

- b. Asumsi *Naïf* (fitur independen)

$$P(\mathbf{x} | C_k) = \prod_{i=1}^n P(x_i | C_k) \tag{2}$$

Keterangan :

$P(X | C_k)$: probabilitas dari vektor fitur X terhadap kelas C_k

$P(x_i | C_k)$: probabilitas fitur ke- i terhadap kelas C_k

n

$\prod_{i=1}^n$: operator perkalian dari $i = 1$ hingga n

- c. Distribusi *Gaussian*

$$P(x_j | C_k) = \frac{1}{\sqrt{2\pi\sigma_{ki}^2}} \exp\left(-\frac{(x_i - \mu_{ki})^2}{2\sigma_{ki}^2}\right) \tag{3}$$

Keterangan :

$\mu_{k,i}$: rata-rata fitur ke- i pada kelas C_k

$\sigma_{k,i}^2$: variansi fitur ke- i pada kelas C_k

- d. Keputusan Klasifikasi (MAP)

$$C = \arg \max_{C_k} P(C_k) \prod_{i=1}^n P(x_j | C_k) \tag{4}$$

Keterangan :

C : kelas yang diprediksi

C_k : kelas ke- k dari himpunan semua kelas
 $P(C_k)$: probabilitas apriori dari kelas C_k
 x_i : fitur ke- i dari data input
 $P(x_i | C_k)$: probabilitas fitur x_i diberikan kelas C_k
 n : jumlah total fitur

2.6 Tools Penelitian

Penelitian ini menggunakan Google Colaboratory (Google Colab) sebagai tools utama dalam implementasi algoritma klasifikasi. Google Colab adalah layanan *cloud computing* berbasis *Jupyter notebook* yang disediakan gratis oleh Google memungkinkan pengguna menjalankan kode *Python* secara daring tanpa membutuhkan perangkat keras khusus [28]. Beberapa keunggulan dari Google Colab antara lain yaitu menyediakan akses GPU/TPU gratis yang sangat berguna untuk mempercepat komputasi, terutama pada pemrosesan citra dan model pembelajaran mesin [28]. Selain itu Google Colab memiliki integrasi mudah dengan Google Drive sehingga memudahkan penyimpanan dan akses dataset penelitian. Platform ini juga mendukung penggunaan berbagai *library Python* populer seperti *OpenCV*, *scikit-learn*, *NumPy*, dan *Matplotlib* yang bermanfaat untuk pemrosesan citra, klasifikasi, komputasi numerik, maupun visualisasi [29]. Lebih lanjut, karena berbasis notebook kolaboratif, Google Colab mempermudah dokumentasi, pembagian, serta revisi kode penelitian secara daring [29]. Dengan adanya Google Colab, proses *preprocessing* citra, ekstraksi fitur, pelatihan model, dan pengujian algoritma KNN dan *Naive Bayes* dapat dilakukan dengan lebih efisien.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Penelitian

Bagian ini menyajikan hasil dari seluruh tahapan penelitian yang telah dilakukan, mulai dari proses pengumpulan data citra daun kelapa sawit, *preprocessing*, ekstraksi fitur, pemisahan data, hingga pengujian metode klasifikasi menggunakan algoritma *K-Nearest Neighbor* (K-NN) dan *Naive Bayes*. Seluruh data diproses melalui platform Google Colab dan hasil ekstraksi fitur disimpan dalam bentuk tabel Excel untuk analisis lebih lanjut.

3.1.1 Deskripsi Data

Dataset yang digunakan dalam penelitian ini berjumlah 3600 gambar yang terdiri dari 9 kelas berbeda, masing-masing berjumlah 400 gambar. Data dikumpulkan dari berbagai kondisi daun kelapa sawit, baik yang terserang hama maupun yang dalam keadaan sehat. Setiap gambar telah melalui proses labeling berdasarkan kondisi visual daun yang diamati.

Kelas-kelas yang diklasifikasikan antara lain: Tungau Merah, Ulat Api, Kutu Daun, Belalang, *Blight*, *Chlorosis*, *Orange Spotting*, *Defisiensi Boron*, dan Daun Sehat. Jumlah data yang seimbang pada setiap kelas bertujuan untuk menghindari dominasi satu kelas terhadap lainnya selama proses pelatihan model, sehingga dapat meningkatkan Akurasi dan generalisasi dalam proses klasifikasi.

Kondisi visual dari masing-masing kelas menunjukkan karakteristik unik yang menjadi dasar dalam proses ekstraksi fitur. Sebagai contoh, Tungau Merah ditandai dengan bintik putih pada daun, sementara *Chlorosis* menunjukkan warna daun yang memucat. Citra daun sehat digunakan sebagai pembanding dalam proses klasifikasi untuk mengukur keakuratan deteksi kondisi tidak normal.

3.1.2 Preprocessing Data dan Ekstraksi Fitur

Sebelum data digunakan dalam proses pelatihan model klasifikasi, gambar daun kelapa sawit harus melalui tahapan *preprocessing* untuk memastikan bahwa input yang diberikan ke model bersih, seragam, dan relevan. Proses *preprocessing* mencakup konversi format gambar dari HEIC ke JPG, kemudian dilanjutkan dengan *resize* ukuran citra agar seragam, *crop* pada area daun yang relevan, dan rename file sesuai kelasnya. Setelah itu dilakukan ekstraksi fitur berupa nilai Rata-rata (*Mean*) dan *Standar Deviasi* (STD) pada kanal warna RGB serta tekstur citra menggunakan metode *GLCM* (*Gray Level Co-Occurrence Matrix*). Hasil ekstraksi digunakan sebagai input ke dalam model klasifikasi. Adapun tahapan *preprocessing* yang dilakukan dalam penelitian ini meliputi:

- a. Konversi Format Gambar (HEIC ke JPG)

Data mentah yang di peroleh dari perangkat tertentu memiliki format HEIC (*High Efficiency Image Coding*) yang belum umum digunakan dalam pemrosesan citra di *Python*. Oleh karena itu, seluruh file gambar dikonversi terlebih dahulu ke format JPG menggunakan *library pyheif* dan *PIL*. Gambar 2. ini ialah proses konversi format gambar dari HEIC ke JPG.

```
/Dataset_Original/Blight/IMG_9009.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9009.jpg
/Dataset_Original/Blight/IMG_9008.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9008.jpg
/Dataset_Original/Blight/IMG_9006.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9006.jpg
/Dataset_Original/Blight/IMG_9007.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9007.jpg
/Dataset_Original/Blight/IMG_9005.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9005.jpg
/Dataset_Original/Blight/IMG_9004.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9004.jpg
/Dataset_Original/Blight/IMG_9002.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9002.jpg
/Dataset_Original/Blight/IMG_9001.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9001.jpg
/Dataset_Original/Blight/IMG_9003.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9003.jpg
/Dataset_Original/Blight/IMG_8999.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_8999.jpg
/Dataset_Original/Blight/IMG_8998.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_8998.jpg
/Dataset_Original/Blight/IMG_8997.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_8997.jpg
/Dataset_Original/Blight/IMG_8996.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_8996.jpg
/Dataset_Original/Blight/IMG_9325.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9325.jpg
/Dataset_Original/Blight/IMG_9326.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9326.jpg
/Dataset_Original/Blight/IMG_9329.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9329.jpg
/Dataset_Original/Blight/IMG_9327.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9327.jpg
/Dataset_Original/Blight/IMG_9330.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9330.jpg
/Dataset_Original/Blight/IMG_9328.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9328.jpg
/Dataset_Original/Blight/IMG_9331.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9331.jpg
/Dataset_Original/Blight/IMG_9332.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9332.jpg
/Dataset_Original/Blight/IMG_9334.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9334.jpg
/Dataset_Original/Blight/IMG_9333.HEIC -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Dataset_Original/Blight/IMG_9333.jpg
```

Gambar 2. Proses Konversi

b. *Resize* Ukuran Citra

Ukuran asli gambar bervariasi, sehingga dilakukan penyesuaian ukuran gambar ke ukuran tetap 800x800 piksel untuk menyeragamkan input ke dalam model. Gambar 3 menunjukkan proses penyesuaian ukuran gambar ke resolusi tetap 800x800 piksel untuk menyeragamkan seluruh gambar.

```
light/IMG_8766.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_8766.jpg
light/IMG_8765.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_8765.jpg
light/IMG_9021.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9021.jpg
light/IMG_9020.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9020.jpg
light/IMG_9018.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9018.jpg
light/IMG_9019.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9019.jpg
light/IMG_9017.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9017.jpg
light/IMG_9013.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9013.jpg
light/IMG_9014.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9014.jpg
light/IMG_9015.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9015.jpg
light/IMG_9016.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9016.jpg
light/IMG_9012.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9012.jpg
light/IMG_9011.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9011.jpg
light/IMG_9010.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9010.jpg
light/IMG_9009.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9009.jpg
light/IMG_9008.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9008.jpg
light/IMG_9006.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9006.jpg
light/IMG_9007.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9007.jpg
light/IMG_9005.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9005.jpg
light/IMG_9004.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9004.jpg
light/IMG_9002.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9002.jpg
light/IMG_9001.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9001.jpg
light/IMG_9003.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_9003.jpg
light/IMG_8999.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Resized/Blight/IMG_8999.jpg
```

Gambar 3. Proses Resize

c. *Crop* Area Daun

Proses cropping dilakukan untuk menghilangkan latar belakang yang tidak relevan, memfokuskan area pengamatan hanya pada bagian daun. Ini membantu model menangkap fitur penting secara lebih akurat. Proses cropping untuk memfokuskan area pengamatan hanya pada bagian daun ditunjukkan pada Gambar 4.

```

/Data_Resized/Blight/IMG_8775.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_8775.jpg
/Data_Resized/Blight/IMG_8773.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_8773.jpg
/Data_Resized/Blight/IMG_8774.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_8774.jpg
/Data_Resized/Blight/IMG_8772.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_8772.jpg
/Data_Resized/Blight/IMG_8771.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_8771.jpg
/Data_Resized/Blight/IMG_8776.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_8776.jpg
/Data_Resized/Blight/IMG_8768.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_8768.jpg
/Data_Resized/Blight/IMG_8769.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_8769.jpg
/Data_Resized/Blight/IMG_8764.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_8764.jpg
/Data_Resized/Blight/IMG_8762.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_8762.jpg
/Data_Resized/Blight/IMG_8763.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_8763.jpg
/Data_Resized/Blight/IMG_8761.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_8761.jpg
/Data_Resized/Blight/IMG_8760.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_8760.jpg
/Data_Resized/Blight/IMG_8766.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_8766.jpg
/Data_Resized/Blight/IMG_8765.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_8765.jpg
/Data_Resized/Blight/IMG_9021.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_9021.jpg
/Data_Resized/Blight/IMG_9020.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_9020.jpg
/Data_Resized/Blight/IMG_9018.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_9018.jpg
/Data_Resized/Blight/IMG_9019.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_9019.jpg
/Data_Resized/Blight/IMG_9017.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_9017.jpg
/Data_Resized/Blight/IMG_9013.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_9013.jpg
/Data_Resized/Blight/IMG_9014.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_9014.jpg
/Data_Resized/Blight/IMG_9015.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_9015.jpg
/Data_Resized/Blight/IMG_9016.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Crop/Blight/IMG_9016.jpg
    
```

Gambar 4. Proses Crop

d. *Rename Gambar*

Setiap file gambar diberi nama sesuai kelasnya, misalnya tungau_merah_001.jpg, kutu_daun_202.jpg, dst. Penamaan ini mempermudah proses pelabelan otomatis saat data di baca menggunakan skrip *Python*. Ekstraksi Fitur Setelah proses *preprocessing*, langkah selanjutnya adalah ekstraksi fitur dari masing-masing gambar. Fitur yang digunakan di bagi menjadi dua kategori utama: fitur warna dan fitur tekstur. Gambar 5. menunjukkan proses rename seluruh file gambar sesuai kelasnya, misalnya tungau_merah_001.jpg, kutu_daun_202.jpg, dan seterusnya. Penamaan ini mempermudah proses pelabelan otomatis saat data dibaca menggunakan skrip *Python*.

```

/Data_Crop/Blight/IMG_0894.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_135.jpg
/Data_Crop/Blight/IMG_0889.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_136.jpg
/Data_Crop/Blight/IMG_0888.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_137.jpg
/Data_Crop/Blight/IMG_0883.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_138.jpg
/Data_Crop/Blight/IMG_0891.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_139.jpg
/Data_Crop/Blight/IMG_0887.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_140.jpg
/Data_Crop/Blight/IMG_0884.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_141.jpg
/Data_Crop/Blight/IMG_0882.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_142.jpg
/Data_Crop/Blight/IMG_0881.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_143.jpg
/Data_Crop/Blight/IMG_0886.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_144.jpg
/Data_Crop/Blight/IMG_0876.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_145.jpg
/Data_Crop/Blight/IMG_0880.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_146.jpg
/Data_Crop/Blight/IMG_0877.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_147.jpg
/Data_Crop/Blight/IMG_0879.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_148.jpg
/Data_Crop/Blight/IMG_0878.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_149.jpg
/Data_Crop/Blight/IMG_0875.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_150.jpg
/Data_Crop/Blight/IMG_0869.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_151.jpg
/Data_Crop/Blight/IMG_0873.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_152.jpg
/Data_Crop/Blight/IMG_0871.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_153.jpg
/Data_Crop/Blight/IMG_0874.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_154.jpg
/Data_Crop/Blight/IMG_0870.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_155.jpg
/Data_Crop/Blight/IMG_0868.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_156.jpg
/Data_Crop/Blight/IMG_0872.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_157.jpg
/Data_Crop/Blight/IMG_0866.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_158.jpg
/Data_Crop/Blight/IMG_0867.jpg -> /content/drive/My Drive/Data Penelitian/KlasifikasiHamaSawit/Preprocessing/Data_Rename/Blight/Blight_159.jpg
    
```

Gambar 5. Proses Rename

e. Hasil *Preprocessing*

Berikut ini ditampilkan kondisi gambar daun kelapa sawit sebelum dan sesudah dilakukan *preprocessing*. Tahap *preprocessing* meliputi penyesuaian ukuran, cropping area daun, dan rename file sesuai kelasnya. Perubahan ini memastikan setiap gambar memiliki format, ukuran, dan fokus objek yang seragam sehingga siap digunakan pada tahap ekstraksi fitur. Gambar 6. menunjukkan perbandingan kondisi gambar daun kelapa sawit sebelum dan sesudah dilakukan *preprocessing*.



Gambar 6. (a) Citra Daun Kelapa Sawit Sebelum Dilakukan Preprocessing, (b) Setelah Preprocessing

1. Fitur Warna (RGB *Mean* dan RGB *STD*) Fitur warna dihitung dengan mengambil nilai:
 - a. *Mean*: rata-rata nilai warna Merah, Hijau, Biru dari tiap gambar.
 - b. *Standard Deviation (STD)*: untuk mengukur sebaran warna pada tiap kanal RGB.

Nilai ini membantu membedakan warna khas dari berbagai jenis daun yang terinfeksi hama atau dalam kondisi sehat.

2. Fitur Tekstur (GLCM – *Gray Level Co-Occurrence Matrix*) Fitur tekstur diambil menggunakan metode GLCM, Fitur yang diekstraksi antara lain:
 - a. *Contrast*
 - b. *Correlation*
 - c. *Energy*
 - d. *Homogeneity*

Fitur ini sangat penting untuk membedakan pola permukaan daun yang rusak (bercak, lubang, atau kerutan) akibat hama/penyakit. Hasil ekstraksi fitur setelah semua gambar diproses, seluruh fitur dikompilasi ke dalam tabel Excel dengan format berikut.

Tabel 1. Ekstraksi Fitur

R_mean	G_mean	B_mean	R_std	G_std	B_std	Contrast	Energy	Homogeneity	Entropy
162,34	161,22	157,499	44,763	42,865	43,493	223,761	0,01513	0,12555352	12,817
167	167,24	163,992	32,968	32,777	32,223	268,172	0,01428	0,09704535	12,899
155,25	157,32	151,429	54,392	53,492	55,778	242,953	0,0156	0,12829849	12,912
165,2	168,78	167,942	30,905	28,906	28,47	161,9	0,01829	0,13906252	12,28
179,24	179,17	173,024	26,529	25,943	25,659	110,767	0,0229	0,17965718	11,624
171,03	171,63	168,087	28,635	27,393	27,122	95,5742	0,02135	0,1756653	11,809
162,47	161,68	160,169	28,62	29,149	27,111	130,62	0,01804	0,1412375	12,21
173,37	172,3	168,541	37,37	36,753	38,53	138,99	0,021	0,15488918	12,019
166,62	166,49	161,356	30,184	27,412	25,729	32,2482	0,02903	0,25878499	11,091
177,06	173,64	169,527	33,481	30,054	30,765	125,172	0,01938	0,1437003	12,078
140,84	139,56	136,496	34,729	35,163	32,142	133,097	0,01603	0,14646397	12,464
154,52	153,41	148,679	31,393	29,104	33,002	156,181	0,01722	0,13773139	12,379
169,8	172,13	171,433	30,671	29,827	28,068	152,584	0,02104	0,17301309	12,06
148,52	147,95	146,778	33,622	31,893	30,226	121,747	0,01678	0,14237663	12,359
150,63	148,18	141,73	31,65	29,962	31,045	121,657	0,01701	0,14115578	12,298
144,44	143,52	137,69	31,368	30,974	30,62	169,096	0,01574	0,12669252	12,492
147,56	145,87	140,775	30,921	29,551	31,172	128,562	0,0183	0,15069542	12,204

148,8	146,19	140,754	34,812	32,455	32,073	153,838	0,0154	0,12660553	12,569
164,5	168,62	165,66	28,051	25,918	29,462	119,764	0,01803	0,13835056	12,085
152,18	149,94	143,24	39,479	36,529	35,488	136,522	0,01488	0,13607276	12,631

Tabel ini menjadi dataset akhir yang digunakan untuk pemisahan data (*train-test*) dan proses klasifikasi menggunakan metode KNN dan *Naive Bayes*, yang akan dijelaskan pada bagian berikutnya.

3.1.3 Pemisahan Data dan Klasifikasi

Setelah semua gambar melalui proses *preprocessing* dan fitur berhasil diekstraksi, langkah selanjutnya adalah pemisahan data menjadi data latih (*training data*) dan data uji (*testing data*) untuk keperluan klasifikasi menggunakan algoritma *K-Nearest Neighbor* (KNN) dan *Naive Bayes*. Data kemudian dibagi menjadi data latih (70%) dan data uji (30%). Kinerja kedua metode dievaluasi menggunakan metrik Akurasi, presisi, *recall*, dan *f1-score*. Hasil dari masing-masing metode dibandingkan untuk mengetahui algoritma mana yang lebih optimal dalam mengklasifikasi jenis hama atau kondisi daun kelapa sawit. Dataset yang berjumlah total 3600 citra dibagi dengan rasio 70:30, yaitu:

- a. 70% data (2520 gambar) digunakan sebagai data latih.
- b. 30% data (1080 gambar) digunakan sebagai data uji.

Pembagian dilakukan secara acak terstratifikasi untuk memastikan distribusi data pada masing-masing kelas tetap seimbang pada data latih dan data uji. Proses Klasifikasi. Dua metode *Machine Learning* digunakan dalam penelitian ini untuk mengklasifikasi gambar daun kelapa sawit berdasarkan fitur yang telah diekstraksi:

- a. Pemisahan Data dan Klasifikasi Menggunakan KNN

Untuk metode KNN, pemisahan data dilakukan dengan memisahkan fitur (X) dan label atau target klasifikasi (y). Data kemudian dibagi menjadi data latih dan data uji menggunakan rasio 70:30. Proses normalisasi dilakukan terhadap fitur menggunakan metode *StandardScaler* untuk menghindari dominasi fitur tertentu akibat perbedaan skala. Setelah itu, model KNN dilatih menggunakan nilai $k = 5$, yang berarti lima tetangga terdekat digunakan untuk menentukan kelas dari data uji. Setelah proses pelatihan selesai, model diuji menggunakan data uji dan dievaluasi menggunakan empat metrik utama: Akurasi, presisi, *recall*, dan *f1-score*.

Tabel 2. Hasil Evaluasi Menggunakan KNN

Metrik	Nilai
Akurasi	0,708333
Presisi	0,703104
Recall	0,702188
F1 Score	0,70079

- b. Pemisahan Data dan Klasifikasi Menggunakan *Naive Bayes*

Prosedur pemisahan data untuk metode *Naive Bayes* dilakukan dengan cara yang sama, yaitu dengan membagi dataset menjadi data latih dan data uji menggunakan rasio 70:30 secara terstratifikasi. Meskipun metode *Naive Bayes* tidak secara khusus memerlukan normalisasi data, normalisasi tetap dilakukan untuk menjaga konsistensi eksperimen. *Naive Bayes* mengklasifikasi data berdasarkan prinsip probabilitas *Bayes*, dengan asumsi bahwa antar fitur bersifat independen (*naif*). Model kemudian dilatih dan diuji, dan performanya diukur menggunakan metrik yang sama seperti metode KNN.

Tabel 3. Hasil Evaluasi Menggunakan *Naive Bayes*

Metrik	Nilai
Akurasi	0,415741
Presisi	0,4303
Recall	0,414347
F1 Score	0,399666

3.2 Pembahasan

Bagian ini membahas secara menyeluruh hasil penelitian terkait klasifikasi hama pada daun kelapa sawit menggunakan dua metode: *K-Nearest Neighbor* (KNN) dan *Naive Bayes*. Pembahasan mencakup bagaimana tujuan penelitian tercapai, interpretasi hasil evaluasi, integrasi temuan dengan teori yang ada, serta implikasi dan keterbatasan dari penelitian ini.

3.2.1 Pencapaian Tujuan Penelitian

Penelitian ini bertujuan untuk membandingkan performa dua algoritma klasifikasi dalam mengidentifikasi sembilan kelas daun kelapa sawit, termasuk jenis-jenis hama dan kondisi daun yang sehat. Dua metode yang dibandingkan adalah *K-Nearest Neighbor* (KNN) dan *Naive Bayes*, yang masing-masing memiliki pendekatan berbeda dalam proses klasifikasinya. Tujuan dari perbandingan ini adalah untuk mengetahui metode mana yang lebih efektif dalam mengenali pola visual dari fitur citra yang telah diekstraksi. Berdasarkan hasil evaluasi terhadap model yang telah dibangun, dapat disimpulkan bahwa metode KNN memberikan hasil klasifikasi yang secara konsisten lebih baik dibandingkan dengan *Naive Bayes*. KNN menunjukkan Akurasi dan stabilitas prediksi yang lebih tinggi pada semua metrik evaluasi utama, seperti Akurasi, presisi, *recall*, dan *f1-score*. Hal ini menunjukkan bahwa pendekatan berbasis jarak yang dimiliki KNN mampu menangkap karakteristik antar fitur secara lebih efektif.

Dengan demikian, penelitian ini berhasil mencapai tujuan utamanya, yakni memberikan evaluasi empiris terhadap dua algoritma klasifikasi dalam konteks pengolahan citra daun kelapa sawit, sekaligus menunjukkan bahwa KNN memiliki potensi lebih besar dalam membangun sistem klasifikasi otomatis di bidang pertanian digital.

3.2.2 Interpretasi dan Komparasi Hasil Evaluasi

Tabel 4. Hasil Evaluasi Dari Kedua Metode

Metode	Akurasi	Presi si	Re call	F1 -Score
K-NN	71%	70%	70%	70%
Naive Bayes	42%	43%	41%	40%

Dari hasil di atas, terlihat jelas bahwa KNN mengungguli *Naive Bayes* pada semua metrik evaluasi yang digunakan. Kinerja rendah dari *Naive Bayes* menandakan bahwa model ini kurang optimal dalam menangani data citra yang memiliki kompleksitas tinggi, seperti warna (*RGB Mean* dan *STD*) dan tekstur (fitur *GLCM*). Kelemahan ini sangat mungkin disebabkan oleh asumsi independensi antar fitur yang digunakan dalam algoritma *Naive Bayes*, padahal pada data citra digital, fitur-fitur tersebut saling terkait erat dan membentuk pola visual yang kompleks. Sebaliknya, KNN yang bekerja berdasarkan kedekatan jarak antar vektor fitur mampu mengenali kemiripan pola visual secara lebih efektif. Meskipun metode ini memiliki keterbatasan dalam hal waktu komputasi, terutama pada skala data besar, namun Akurasi sebesar 71% menunjukkan bahwa KNN merupakan pendekatan yang lebih stabil dan andal untuk tugas klasifikasi multi-kelas berbasis fitur visual. Kinerja KNN juga menunjukkan potensi yang baik untuk diterapkan pada sistem klasifikasi nyata, dengan peluang peningkatan performa yang masih terbuka melalui optimasi parameter atau penambahan fitur.

3.2.3 Integrasi Temuan dengan Teori

Hasil penelitian ini sejalan dengan teori dan temuan sebelumnya yang menyatakan bahwa metode KNN lebih cocok digunakan untuk data berbasis citra atau visual [30]. Dalam data citra, fitur-fitur seperti warna dan tekstur sering kali berkorelasi satu sama lain, dan model KNN yang tidak mengasumsikan bentuk distribusi tertentu atau independensi antar fitur mampu menangani korelasi ini dengan baik. KNN bekerja berdasarkan prinsip pembelajaran *instance-based*, yang menilai kesamaan antara data uji dan data latih secara langsung. Oleh karena itu, model ini lebih fleksibel dan responsif terhadap pola kompleks yang muncul dalam data visual.

Sebaliknya, performa *Naive Bayes* yang cenderung rendah pada penelitian ini menguatkan asumsi bahwa algoritma ini lebih cocok untuk data yang lebih sederhana dan memiliki struktur fitur yang independen, seperti data teks atau data numerik tabular. Ketidakmampuan *Naive Bayes* dalam menangani ketergantungan antar fitur membuatnya kurang ideal untuk klasifikasi berbasis citra.

3.2.4 Implikasi dan Keterbatasan Penelitian

Implikasi:

- Metode KNN dapat dijadikan sebagai landasan awal dalam pengembangan sistem klasifikasi hama berbasis citra digital, khususnya untuk tanaman kelapa sawit.
- Sistem klasifikasi ini dapat membantu petani dan petugas lapangan dalam mendeteksi kondisi daun secara cepat dan efisien, sehingga proses pengambilan keputusan dalam pengendalian hama menjadi lebih responsif.
- Dengan Akurasi yang cukup baik, sistem ini juga berpotensi diintegrasikan dalam aplikasi mobile atau sistem monitoring berbasis kamera.

Keterbatasan:

- Meskipun KNN memiliki Akurasi yang lebih tinggi dibandingkan *Naive Bayes*, nilainya masih di bawah 80%, yang menunjukkan bahwa sistem klasifikasi belum mencapai tingkat Akurasi optimal.
- Dataset yang digunakan terbatas hanya pada sembilan kelas dan belum mempertimbangkan faktor-faktor lain seperti pencahayaan, sudut pengambilan gambar, variasi usia daun, atau kondisi lingkungan.
- KNN memiliki kelemahan dalam hal efisiensi komputasi karena proses prediksi memerlukan perhitungan jarak terhadap seluruh data latih, yang tidak ideal untuk sistem *real-time* berskala besar.

3.2.5 Potensi Pengembangan Selanjutnya

Untuk meningkatkan performa dan kapabilitas sistem klasifikasi di masa depan, beberapa potensi pengembangan dapat dilakukan sebagai berikut: Ekspansi Fitur: Menambahkan fitur-fitur lain seperti ciri bentuk (*shape descriptors*), deteksi tepi (*edge detection*), atau fitur morfologi untuk memperkaya representasi data citra. Penggunaan *Deep Learning*: Mengadopsi metode pembelajaran mendalam seperti *Convolutional Neural Network (CNN)* yang mampu mengekstraksi fitur secara otomatis dari citra dan biasanya memberikan hasil yang jauh lebih akurat. Aplikasi Mobile atau Web: Mengembangkan aplikasi berbasis Android atau web yang dapat terhubung langsung dengan kamera perangkat, sehingga klasifikasi dapat dilakukan secara *real-time* di lapangan. Augmentasi Dataset: Menambah jumlah data dan variasi kondisi gambar (misalnya melalui teknik augmentasi citra) agar model lebih robust terhadap perbedaan pencahayaan, sudut pandang, dan kondisi alami daun. Optimasi Parameter: Melakukan tuning terhadap parameter seperti jumlah tetangga pada KNN atau strategi normalisasi untuk mencapai hasil klasifikasi yang lebih optimal.

4. KESIMPULAN

Kesimpulan dari hasil penelitian yang telah dilaksanakan pada “Klasifikasi Citra Daun Kelapa Sawit Menggunakan Metode KNN dan Naive Bayes”, maka dapat diambil kesimpulan yang merangkum jawaban atas permasalahan penelitian efektivitas metode yang digunakan serta potensi penerapan sistem. Penelitian ini bertujuan untuk mengembangkan sebuah sistem klasifikasi yang mampu mengidentifikasi kondisi daun kelapa sawit baik yang sehat maupun yang mengalami kerusakan akibat hama atau penyakit, berdasarkan pengolahan citra digital. Kelas yang digunakan terdiri dari sembilan kategori, yaitu delapan kelas kerusakan (empat akibat hama: ulat api, ulat kantong, belalang, tungau merah; empat akibat penyakit: *blight*, *chlorosis*, *defisiensi boron*, *orange spotting*) serta satu kelas daun sehat.

Ekstraksi fitur dilakukan dengan menggabungkan dua jenis informasi: fitur warna (*mean* dan *standar deviasi kanal RGB*) dan fitur tekstur yang diperoleh dari *Gray Level Co-occurrence Matrix (GLCM)*, mencakup *contrast*, *correlation*, *energy*, dan *homogeneity*. Kombinasi fitur ini bertujuan untuk merepresentasikan baik informasi warna maupun pola permukaan daun, sehingga memudahkan algoritma dalam membedakan kelas yang memiliki perbedaan halus maupun yang sangat mencolok. Proses klasifikasi menggunakan dua metode perbandingan, yaitu *K-Nearest Neighbor (KNN)* dan *Naive Bayes*. Hasil pengujian menunjukkan bahwa KNN dengan nilai $k = 3$ memberikan akurasi tertinggi sebesar 71%, sedangkan *Naive Bayes* hanya mencapai 42%.

Perbedaan ini menunjukkan bahwa KNN lebih efektif dalam memanfaatkan jarak antar data pada ruang fitur, sementara *Naive Bayes* kurang sesuai karena asumsi independensi antar fitur pada data citra tidak terpenuhi sepenuhnya. Secara umum, sistem ini memiliki potensi untuk digunakan sebagai alat bantu deteksi dini di lapangan. Meskipun akurasi belum mencapai tingkat optimal, KNN mampu memberikan prediksi awal yang cukup baik sehingga dapat membantu petani atau pengelola perkebunan dalam melakukan pemantauan kesehatan tanaman. Sistem ini juga berpotensi dikembangkan menjadi aplikasi mobile atau diintegrasikan dengan perangkat seperti drone untuk inspeksi skala luas.

Keterbatasan utama penelitian ini adalah jumlah dan variasi dataset yang masih terbatas, serta kondisi pengambilan citra yang cenderung seragam. Untuk penelitian selanjutnya, disarankan menambah jumlah dan variasi citra, melakukan pengambilan gambar pada kondisi pencahayaan yang beragam, serta mencoba pendekatan berbasis *deep learning* seperti *Convolutional Neural Networks* (CNN) untuk meningkatkan performa klasifikasi. Dengan pengembangan tersebut diharapkan sistem dapat mencapai akurasi yang lebih tinggi dan mampu diimplementasikan secara efektif dalam skala industri perkebunan kelapa sawit.

UCAPAN TERIMAKASIH

Penulis mengucapkan terima kasih kepada Program Studi Sistem Informasi dan pihak universitas atas fasilitas dan dukungan yang diberikan selama proses penelitian ini, kepada dosen pembimbing yang telah memberikan arahan dan masukan yang berharga, serta kepada semua rekan dan pihak yang telah membantu dalam pengumpulan data, pengujian, dan penyusunan penelitian ini sehingga dapat terselesaikan dengan baik.

REFERENCES

- [1] P. D. dan S. I. P. (Pusdatin), "Analisis Kinerja Perdagangan Komoditas Kelapa Sawit Tahun 2024," 2024. [Online]. Available: https://satudata.pertanian.go.id/assets/docs/publikasi/1F_Analisis_Kinerja_Perdagangan_Kelapa_Sawit_2024_-_publish.pdf
- [2] P. D. dan S. I. Pertanian, "Outlook Komoditas Kelapa Sawit 2024," Jakarta, 2024. [Online]. Available: https://satudata.pertanian.go.id/assets/docs/publikasi/OUTLOOK_KELAPA_SAWIT_2024_FINAL.pdf
- [3] P. P. B. K. D. RI, "Isu Sepekan II - Pusat Penelitian DPR RI, Juni 2023," Jakarta, 2023. [Online]. Available: https://berkas.dpr.go.id/pusaka/files/isu_sepekan/Isu_Sepekan--II-PUSLIT-Juni-2023-191.pdf
- [4] F. B. L. T. Nelda Zahra Amany, "Respon Indonesia terhadap Kebijakan RED II Uni Eropa," *AEGIS J. Int. Relations*, 2024, [Online]. Available: <https://e-journal.president.ac.id/index.php/AEGIS/article/view/5531>
- [5] B. P. Statistik, "Statistik Kelapa Sawit Indonesia 2023," Jakarta, 2024. [Online]. Available: <https://assets.dataindonesia.id/2025/04/23/1745375094378-88-22.-statistik-kelapa-sawit-indonesia-2023.pdf%0A%0A>
- [6] D. P. K. K. Timur, "Luas dan Produksi Tanaman Perkebunan di Kabupaten Kotawaringin Timur," 2024. <https://data.kotimkab.go.id/dataset/distantabel11%0A%0A>
- [7] A. Sirait, "Pengaruh Serangan Hama terhadap Produksi Kelapa Sawit," Institut Teknologi Sains Bandung (ITSB), 2022.
- [8] Dinas Perkebunan Provinsi Lampung, "Tungau (*Oligonychus* sp): Hama Tanaman Kelapa Sawit," *Dinas Perkebunan Provinsi Lampung*, 2022. <https://disbun.lampungprov.go.id/detail-post/tungau-oligonychus-sp-hama-tanaman-kelapa-sawit>
- [9] F. Y. and D. M. H. and T. A. Husna, "Identifikasi Penyakit Daun pada Tanaman Kelapa Sawit di Kecamatan Tanah Putih Kabupaten Rokan Hilir," *War. PPKS*, 2023, [Online]. Available: <https://warta.iopri.org/index.php/Warta/article/view/101/6>
- [10] D. Ifantiska, "Implementasi Arsitektur Googlenet Dan Xception Untuk Identifikasi Penyakit Pada Daun Tanaman Kelapa Sawit," pp. 1–68, 2022.
- [11] D. Elvira, "Klasifikasi Citra Daun Kelapa Sawit Yang Terkena Dampak Hama Menggunakan Metode K-Nearest Neighbor (KNN)," p. 70, 2021.
- [12] T. J. Kuswanto, "Klasifikasi Citra Buah Sawit Berdasarkan Ketebalan Daging Buah Menggunakan Algoritma Naive Bayes," Universitas Teknologi Digital Indonesia, 2023. [Online]. Available: <https://eprints.utdi.ac.id/9850/>
- [13] N. Eri Yuni, "Klasifikasi Penyakit pada Daun Kelapa Sawit Menggunakan Metode Naive Bayes dengan Ekstraksi Fitur Warna dan Tekstur," Institut Teknologi Sumatera (ITERA). [Online]. Available:

- <https://repository.itera.ac.id/depan/submission/SB2309270008>
- [14] D. J. Perkebunan, "Industri Kelapa Sawit Nasional Menuju Era Digital, Kementerian Pertanian Dukung Transformasi," 2023. <https://ditjenbun.pertanian.go.id/industri-kelapa-sawit-nasional-menuju-era-digital-kementerian-pertanian-dukung-transformasi>
- [15] K. P. R. Direktorat Jenderal Perkebunan, "Generasi Muda Jadi Kunci Transformasi Perkebunan, Kementan Ajak Mahasiswa Perkuat Pertanian Berdaya Saing," 2023. <https://ditjenbun.pertanian.go.id/generasi-muda-jadi-kunci-transformasi-perkebunan-kementan-ajak-mahasiswa-perkuat-pertanian-berdaya-saing/>
- [16] F. P. UGM, "Membangun Ekosistem Digital Sektor Pertanian di Era Revolusi Industri 4.0," *Fakultas Pertanian Universitas Gadjah Mada*, 2024. <https://web.faperta.ugm.ac.id/membangun-ekosistem-digital-setor-pertanian-di-era-revolusi-industri-4-0/>
- [17] N. M. S. Iswari, W. Wella, and R. Ranny, "Perbandingan Algoritma kNN, C4.5, dan Naive Bayes dalam Pengklasifikasian Kesegaran Ikan Menggunakan Media Foto," *J. Ultim.*, vol. 9, no. 2, pp. 114–117, 2017, doi: 10.31937/ti.v9i2.659.
- [18] D. A. Royani, "BAB III Metode Pengumpulan Data," Universitas Ngudi Waluyo, 2021. [Online]. Available: [https://repository2.unw.ac.id/2586/7/BAB III - Dika Ade Royani.pdf](https://repository2.unw.ac.id/2586/7/BAB%20III%20-%20Dika%20Ade%20Royani.pdf)
- [19] A. R. S. Nasution, "Identifikasi Permasalahan Penelitian," *ALACRITY J. Educ.*, vol. 1, no. 2, pp. 13–19, 2021, doi: 10.52121/alacrity.v1i2.21.
- [20] N. Rohman, "Mengapa iPhone Lebih Bagus Kamernya?," *Universitas Wira Buana*, 2024.
- [21] T. K. Teknokrat, "Pengolahan Citra Digital Dengan Python," *Universitas Teknokrat Indonesia*, 2025.
- [22] R. Ikhlasul, A. Wijaya, N. David, M. Veronica, and R. Toyib, "Klasifikasi Kualitas Buah Sawit Menggunakan Metode Gray Level Co-occurrence Matrix Dengan Variasi Arah Obyek," *J. Media Infotama*, vol. 20, no. 1, pp. 256–263, 2024.
- [23] G. F. Laxmi and F. S. F. Kusumah, "Region of interest and color moment method for freshwater fish identification," *Telkomnika (Telecommunication Comput. Electron. Control.)*, vol. 17, no. 3, pp. 1432–1438, 2019, doi: 10.12928/TELKOMNIKA.V17I3.11749.
- [24] . J., R. Sigit, and Z. Arief, "Tooth Color Detection Using PCA and KNN Classifier Algorithm Based on Color Moment," *Emit. Int. J. Eng. Technol.*, vol. 5, no. 1, pp. 139–153, 2017, doi: 10.24003/emitter.v5i1.171.
- [25] F. Q. Classification, "Meningkatkan Akurasi KNN Menggunakan Metode Particle Swarm Optimization pada Klasifikasi Kualitas Buah Apel," pp. 23–38, 2025.
- [26] I. Hadianti *et al.*, "PENERAPAN ALGORITMA NAÏVE BAYES UNTUK MENENTUKAN," vol. 7, no. 6, pp. 3616–3620, 2023.
- [27] S. Developers, "Naïve Bayes," *Scikit-learn User Guide*, 2025. https://scikit-learn.org/stable/modules/naive_bayes.html
- [28] T. Carneiro, R. V. M. Da Nobrega, T. Nepomuceno, G. Bin Bian, V. H. C. De Albuquerque, and P. P. R. Filho, "Performance Analysis of Google Colaboratory as a Tool for Accelerating Deep Learning Applications," *IEEE Access*, vol. 6, pp. 61677–61685, 2018, doi: 10.1109/ACCESS.2018.2874767.
- [29] E. Bisong, *Building Machine Learning and Deep Learning Models on Google Cloud Platform: A Comprehensive Guide for Beginners*. 2019. doi: 10.1007/978-1-4842-4470-8.
- [30] E. F. Saraswita, "Akurasi Klasifikasi Citra Digital Scenes RGB Menggunakan Model K-Nearest Neighbor dan Naive Bayes," *Pros. Annu. Res. Semin.*, vol. 5, no. 1, pp. 978–979, 2019, [Online]. Available: <http://seminar.ilkom.unsri.ac.id/index.php/ars/article/view/2131>