



Integrasi KNN, GLCM dan HSV untuk Meningkatkan Klasifikasi Buah Jeruk

Tegar Arifin Prasetyo¹, Rudy Chandra², Immanuel Siahaan³, Maruli Tua Siagian⁴, Dian Esra Vitania Hasibuan⁵

^{1, 2, 3, 4, 5}Departemen Teknologi Informasi, Institut Teknologi Del

¹ tegar.prasetyo@del.ac.id

² rudychandra@del.ac.id

³ if320028@students.del.ac.id

⁴ if320029@students.del.ac.id

⁵ if320053@students.del.ac.id

Corresponding author email: tegar.prasetyo@del.ac.id

Abstract: Oranges (*Citrus sp*) are a significant agricultural product. According to data from the Central Statistics Agency (BPS), orange production experienced a decline from 2.2 million in 2020 to 2.2 million in 2021. One contributing factor to this decrease is the impact of diseases, which can reduce productivity, quantity, and quality of agricultural yields, as well as worsen the stability of varieties. To address these issues, this research developed a web interface to classify types of citrus fruit diseases, aiming to assist both farmers and the public in identifying the diseases and learning effective control methods. The study utilized the K-Nearest Neighbor (KNN) algorithm with feature extraction using Hue, Saturation, and Value (HSV) color and Gray Level Cooccurrence Matrix (GLCM) texture. Four disease categories were classified: blackspot, greening, canker, and fresh, with a dataset comprising 800 instances, 200 for each category. Experimental testing with k values of 1, 3, and 5 revealed the highest accuracy at $k=1$, reaching 89%.

Keywords: Oranges, Classification, K-Nearest Neighbor, Hue Saturation Value, Gray Level Cooccurrence Matrix

Abstrak: Jeruk (*Citrus sp*) merupakan salah satu hasil pertanian. Berdasarkan data dari Badan Pusat Statistik (BPS), produksi buah jeruk mengalami penurunan dari tahun 2020 ke 2021 sebesar 2,2 juta. Salah satu faktor yang menyebabkan produksi jeruk menurun dikarenakan serangan penyakit yang dapat menurunkan produktivitas serta kuantitas dan kualitas hasil pertanian, dan memperburuk varietas, dan stabilitas hasil. Untuk mengatasi permasalahan tersebut, penelitian ini membangun web interface untuk mengklasifikasi jenis penyakit buah jeruk yang diharapkan dapat membantu petani maupun masyarakat untuk mengetahui jenis penyakit serta cara pengendalian yang efektif. Penelitian ini menggunakan algoritma K-Nearest Neighbor (KNN) dengan menggunakan ekstraksi ciri warna Hue, Saturation, dan Value (HSV) dan ekstraksi tekstur Gray Level Cooccurrence Matrix (GLCM). Pada penelitian ini mengklasifikasi 4 jenis kategori yaitu blackspot, greening, canker dan fresh. Dataset yang digunakan sebanyak 800 data dengan masing-masing kategori memiliki 200 data. Penelitian ini melakukan percobaan untuk menguji model dengan menggunakan $k=1$, $k=3$ dan $k=5$. Setelah diperoleh hasil dari percobaan k , hasil akurasi tertinggi terdapat pada $k=1$ sebesar 89%.

Kata kunci: Jeruk, Klasifikasi, K-Nearest Neighbor, Hue Saturation Value, Gray Level Cooccurrence Matrix.

I. PENDAHULUAN

Jeruk, yang secara ilmiah diklasifikasikan sebagai Citrus, merupakan komoditas pertanian yang signifikan. Menurut Badan Pusat Statistik Indonesia, produksi jeruk tercatat sebesar 2,7 juta ton pada tahun 2020, dan mengalami penurunan sedikit menjadi 2,5 juta ton pada tahun 2021. Penurunan ini menekankan perlunya perawatan yang teliti dalam budidaya pohon jeruk. Namun, berbagai tantangan, khususnya penyakit, seringkali menghambat produksi jeruk. Virus, jamur, dan bakteri menyumbang mayoritas penyakit yang mempengaruhi buah jeruk [1]. Dampak dari penyakit buah tidak hanya mengurangi hasil, kuantitas, dan kualitas produk pertanian; ini juga mengganggu stabilitas varietas dan hasil [2]. Tanaman jeruk menghadapi spektrum 11 penyakit yang berbeda. Di antaranya, penyakit bercak hitam, penyakit kanker jeruk, dan penyakit greening jeruk adalah penyakit yang umum pada buah jeruk. Sayangnya, kurangnya informasi tentang penyakit-penyakit ini pada tanaman jeruk menghambat masyarakat dan petani dalam mengenali atau memahami gangguan yang mungkin mempengaruhi



tanaman mereka [3], [4]. Seiring dengan berkembangnya teknologi, penerapan teknologi komputer menjadi semakin berharga dalam mengenali berbagai jenis penyakit manusia dan tanaman. Contoh utama dari integrasi teknologi ini adalah machine learning, sebuah tools yang mampu mengekstrak informasi secara cerdas melalui analisis gambar visual.

Penerapan klasifikasi dalam berbagai aspek kehidupan manusia terbukti bermanfaat bagi individu yang mencari solusi pemecahan masalah yang efektif [5], [6]. Dalam penelitian terbaru mengenai klasifikasi penyakit tanaman, berbagai teknik pengolahan gambar telah muncul untuk deteksi penyakit, yang mengandalkan kompilasi gambar yang menggambarkan gejala penyakit. Gambargambar ini dikumpulkan dari berbagai sumber atau diperoleh melalui perangkat pendeteksi gambar. Para peneliti menggunakan berbagai perangkat, termasuk kamera digital [7], dataset terstandarisasi seperti Plant Village [8], dan perangkat seluler seperti iPad, iPhone, Dell, dan telepon Samsung [9], untuk mengambil gambar yang menggambarkan gejala penyakit dan untuk aplikasi yang lebih luas dalam Agri informatika [10].

Penelitian [11] memperkenalkan metode pengolahan gambar baru untuk identifikasi dan klasifikasi penyakit buah, yang menggabungkan segmentasi K-Means. Temuan secara konsisten menunjukkan akurasi yang lebih unggul dalam klasifikasi penyakit dibandingkan dengan C-Means, khususnya dalam database yang beragam yang menampilkan 34 kelas buah yang berbeda. Dengan memanfaatkan teknologi pengolahan gambar digital, kombinasi metode Gray Level Co-occurrence Matrix (GLCM) dan K-Nearest Neighbor (KNN) menunjukkan tingkat akurasi 80% dalam klasifikasi buah Parijoto untuk jaminan kualitas, sebagaimana dihighlight dalam karya oleh [12]. Namun, peneliti lain menangani tantangan subjektif penentuan kematangan mentimun pasca-panen menggunakan fitur statistik dari metode GLCM Order-Satu dan Order-Dua pada gambar yang diambil dalam warna merah, hijau, biru, dan skala abu-abu, mencapai akurasi 96.05% melalui algoritma K-Nearest Neighbors, dengan gambar skala abu-abu menunjukkan performa yang lebih unggul dan parameter tekstur spesifik [13].

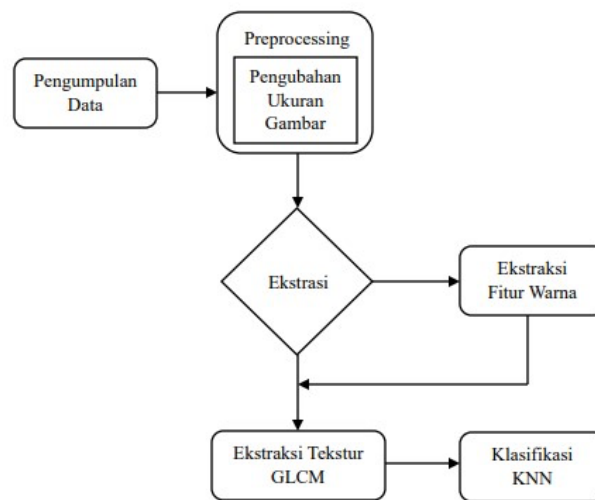
K-Nearest Neighbor (KNN) menonjol sebagai teknik klasifikasi yang banyak digunakan, diakui sebagai salah satu dari sepuluh algoritma paling populer dan berpengaruh di bidangnya [14], [15]. Kekuatan K-Nearest Neighbor (KNN) dalam klasifikasi terletak pada kemampuannya untuk menangani data yang kompleks dan non-linier tanpa mengasumsikan distribusi tertentu, serta kemudahan implementasinya yang membutuhkan pelatihan minimal. Oleh karena itu, dalam studi ini, KNN digunakan untuk pemodelan, dengan memanfaatkan GLCM (Gray Level Co-occurrence Matrix) dan HSV (Hue, Saturation, Value) untuk ekstraksi fitur dan warna. GLCM mengekstrak informasi tekstur dari gambar [16], sementara model warna HSV memungkinkan representasi intuitif dari variasi warna [17]. Keduanya memberikan informasi fitur yang kaya, meningkatkan kinerja KNN dalam klasifikasi gambar.

II. METODOLOGI PENELITIAN

Metode penelitian yang digunakan dalam studi ini dijelaskan dalam Gambar 1.

- a. Data tentang penyakit buah jeruk yang digunakan berjumlah 800 yang dikelompokkan ke dalam 4 kategori dengan masing-masing data sejumlah 200 data bintik hitam (*blackspot*), 200 data kanker (*cancer*), 200 segar (*fresh*), dan *greening*.
- b. Data yang dikumpulkan akan diproses melalui tahap pra-pemrosesan yang bertujuan untuk menyiapkan gambar sebelum gambar diproses untuk analisis lebih lanjut. Data gambar akan menjalani proses perubahan ukuran.

- c. Setelah data diproses, data tersebut kemudian akan masuk ke tahap ekstraksi fitur warna dan tekstur. Untuk mendapatkan nilai ekstraksi, gambar akan dikonversi dari RGB ke HSV dan juga RGB ke skala abu-abu. Setelah data gambar dikonversi menjadi skala abu-abu, nilai dari setiap fitur GLCM dapat dihitung.
- d. Sebelum klasifikasi, nilai akan diambil dari hasil ekstraksi fitur warna dan nilai dari ekstraksi tekstur. Dalam hal ini ekstraksi fitur warna akan di ekstrasi menggunakan HSV dan ekstraksi tekstur menggunakan GLCM. Kedua nilai tersebut akan digabungkan untuk masuk ke tahap klasifikasi. Algoritma yang digunakan dalam klasifikasi adalah KNN.

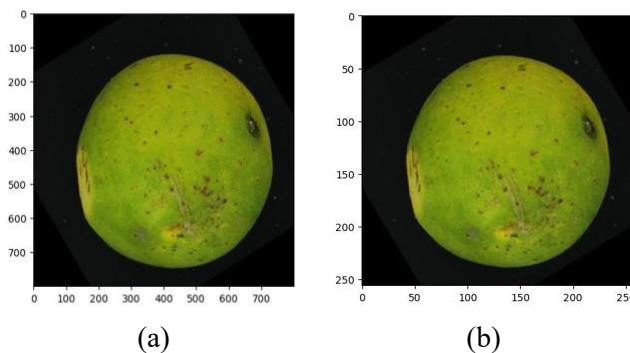


Gambar 1. Metodologi Penelitian

III. HASIL DAN IMPLEMENTASI

III.1. Implementasi Preprocessing Gambar

Data yang dikumpulkan memiliki ukuran 800 x 800 piksel. Pra-pemrosesan gambar melibatkan pengubahan ukurannya menjadi dimensi yang lebih kecil yaitu 256 x 256 piksel. Ukuran ini dipilih setelah melakukan eksperimen dengan dimensi 64 x 64 piksel, 128 x 128 piksel, dan 256 x 256 piksel. Akurasi terbaik dicapai ketika ukuran diatur ke 256 x 256 piksel. Gambar 2 (a) menunjukkan hasil gambar sebelum pengubahan ukuran dan Gambar 2 (b) menunjukkan hasil gambar setelah pengubahan ukuran.



Gambar 2. Hasil Gambar Sebelum dan Setelah Pengubahan Ukuran

III.2. Implementasi Preprocessing Gambar

Gambar 3 menyajikan pseudocode untuk mendefinisikan HSV yang akan diterapkan.

```
Title: Defining HSV

Declaration :
VAR hsv_properties;
INT glcm_distances;

Implementation :
BEGIN
    PRINT hsv_properties;
    SET glcm_distances to [1]
    SET glcm_properties = contrast, homogeneity, energy, and
correlation;
END
```

Gambar 3. Pseudocode untuk Mendefinisikan HSV

Dalam Gambar 3, variabel "hsv_properties" didefinisikan untuk menyimpan nilai dengan mengatur daftar yang akan diisi dengan hue, saturation, dan value. Kemudian, variabel "glcm_distances" diatur menjadi 1, menunjukkan perhitungan kejadian pasangan piksel dengan jarak 1. Variabel "glcm_properties" akan menangkap nilai fitur seperti kontras, homogenitas, energi, dan korelasi. Gambar 4 menyajikan pseudocode untuk proses ekstraksi fitur dari HSV dan GLCM.

```
Title: Feature Extraction of HSV and GLCM

Declaration :
INT hsv_image, hsv_values, glcm, glcm_image, glcm_values

Implementation :
BEGIN
    DECLARE list features, labels
    RESIZE image

    CONVERT image color RGB to HSV and SAVE to hsv_image
    PRINT hsv_image to hsv_values

    CONVERT image color to gray and SAVE to glcm_image
    CALCULATE the glcm_image matrix using the greycomatrix and
greycoprops
    PRINT and SAVE to glcm_values
```

Gambar 4. Pseudocode untuk Mendefinisikan HSV dan GLCM


Dalam Gambar 4, proses ekstraksi gambar melibatkan konversi gambar yang telah diubah ukurannya melalui HSV dan GLCM. Gambar yang telah diubah ukuran menjalani proses konversi, dimulai dengan transformasi dari RGB ke HSV. Hasil ekstraksi HSV ini disimpan dalam variabel "hsv_image" dan ditampilkan dengan memanggil "hsv_values". Proses konversi selanjutnya adalah dari RGB ke skala abu-abu. Fungsi "greycomatrix" digunakan untuk mendapatkan matriks GLCM, dan "greycoprops" digunakan untuk menghitung matriks GLCM yang disimpan dalam variabel "glcm". Hasil matriks ditampilkan melalui "glcm_values". Tabel 1 menampilkan salah satu hasil dari proses ekstraksi gambar.



Tabel 1. Hasil Ekstraksi Gambar

	Blackspot	Cancer	Fresh	Greening
HSV	21.55, 126.44, 143.88	23.62, 87.017, 115.52	15.19, 103.16, 207.31	46.37, 137.95, 79.58
GLCM	Contrast: 85.48 Homogeneity: 0.36 Energy: 0.32 Correlation: 0.98	Contrast: 258.75 Homogeneity: 0.42 Energy: 0.15 Correlation: 0.97	Contrast: 232.42 Homogeneity: 0.19 Energy: 0.19 Correlation: 0.97	Contrast: 54.51 Homogeneity: 0.42 Energy: 0.13 Correlation: 0.99

Setelah menjalani tahap ekstraksi fitur, dataset akan dibagi menjadi dua bagian: data pelatihan (train) dan data pengujian (test), dengan rasio pembagian 80:20, di mana data pelatihan mencakup 80% dan data pengujian 20%. Untuk mendapatkan hasil yang konsisten, parameter 'random state' digunakan selama pembagian ini. 'Random state' adalah parameter yang digunakan untuk membagi dataset secara acak menjadi data pelatihan dan pengujian. Untuk memastikan bahwa pembagian dataset tetap konsisten di setiap eksekusi kode, parameter 'random state' diatur ke 1, memberikan output yang sama setiap kali kode dijalankan. Gambar 5 menunjukkan hasil validasi keakuratan yang diperoleh di seluruh rentang nilai k dari 1 hingga 6.



Gambar 5. Cross-Validation Akurasi pada Range K

III.4. Hasil Eksperimen

Pada subbagian berikut, eksperimen akan dibahas, yang melibatkan pengujian pengembangan model dengan nilai k yang berbeda, 'random state', dan perubahan ukuran. Tujuannya adalah untuk mengeksplorasi tingkat akurasi yang lebih tinggi untuk model yang dibangun. Empat eksperimen dilakukan untuk masing-masing dari tiga nilai k. Tabel 2 menunjukkan sebuah eksperimen dengan perubahan ukuran (64,64). Dalam eksperimen ini, akurasi tertinggi dicapai ketika k diatur ke 3 dengan 'random state' 32, mencapai 88%.



Tabel 2. Hasil Eksperimen dengan Pengubahan Ukuran (64, 64)

	k-value	Random State	Accuracy	Precision	Recall	F-1 Score
Size (64,64)	1	0	0.86	0.87	0.87	0.87
		1	0.85	0.85	0.85	0.85
		32	0.83	0.82	0.82	0.82
		42	0.83	0.83	0.83	0.83
	3	0	0.80	0.81	0.83	0.85
		1	0.85	0.86	0.85	0.85
		32	0.88	0.87	0.87	0.87
		42	0.85	0.85	0.85	0.85
	5	0	0.78	0.80	0.79	0.79
		1	0.84	0.84	0.84	0.83
		32	0.83	0.82	0.82	0.82
		42	0.83	0.82	0.82	0.82

Tabel 3 menunjukkan eksperimen yang dilakukan dengan pengubahan ukuran (128, 128). Dalam percobaan ini, akurasi tertinggi dicapai dengan k diatur ke 1 dan 'random state' 1, menghasilkan akurasi 88%.

Tabel 3. Hasil Eksperimen dengan Pengubahan Ukuran (128, 128)

	k-value	Random State	Accuracy	Precision	Recall	F-1 Score
Size (128,128)	1	0	0.85	0.85	0.85	0.85
		1	0.88	0.88	0.88	0.88
		32	0.87	0.87	0.86	0.86
		42	0.83	0.83	0.83	0.83
	3	0	0.82	0.83	0.83	0.83
		1	0.86	0.86	0.86	0.86
		32	0.88	0.87	0.87	0.87
		42	0.83	0.83	0.83	0.83
	5	0	0.83	0.82	0.82	0.82
		1	0.85	0.84	0.88	0.88
		32	0.88	0.87	0.87	0.87
		42	0.86	0.85	0.85	0.85

Tabel 4 menunjukkan eksperimen yang dilakukan dengan pengubahan ukuran (256, 256). Dalam percobaan ini, akurasi tertinggi dicapai ketika k diatur ke 1 dengan 'random state' 1, mencapai 89%.

Tabel 4. Hasil Eksperimen dengan Pengubahan Ukuran (256, 256)

	k-value	Random State	Accuracy	Precision	Recall	F-1 Score
Size (256,256)	1	0	0.87	0.87	0.87	0.85
		1	0.89	0.89	0.89	0.88
		32	0.89	0.89	0.88	0.86
		42	0.86	0.86	0.86	0.83
	3	0	0.83	0.84	0.84	0.83
		1	0.85	0.85	0.85	0.86
		32	0.87	0.86	0.86	0.87
		42	0.86	0.86	0.86	0.83
	5	0	0.86	0.86	0.86	0.82
		1	0.89	0.89	0.88	0.88
		32	0.86	0.85	0.84	0.87
		42	0.85	0.85	0.85	0.85



Dalam studi ini, evaluasi kinerja klasifikasi menggunakan matriks kebingungan, dengan dataset pengujian yang terdiri dari 40 instans per kategori. Detail spesifik dari hasil pengujian tersedia di Tabel 5 di bawah ini.

Tabel 5. Hasil Pengujian

Actual	Prediction			
	Greening	Blackspot	Cancer	Fresh
Greening	36	0	0	0
Blackspot	0	32	8	0
Cancer	0	9	29	0
Fresh	0	0	0	46

Dari Tabel 5, dapat disimpulkan bahwa nilai akurasi yang diperoleh, berdasarkan perhitungan akurasi, adalah 0,89375 atau 89%.

IV. KESIMPULAN

Penelitian ini mengeksplorasi penggunaan teknologi pembelajaran mesin, khususnya algoritma KNearest Neighbor (KNN), untuk mengklasifikasikan penyakit pada tanaman jeruk. Dengan fokus pada identifikasi dan klasifikasi penyakit buah melalui metode pengolahan gambar, studi ini berhasil mencapai akurasi tertinggi sebesar 89% dengan dimensi pengubahan ukuran (256, 256) dan nilai k sebesar 1. Analisis matriks kebingungan lebih lanjut memvalidasi tingkat akurasi ini. Metodologi penelitian yang terstruktur, penggunaan fitur GLCM dan HSV dalam ekstraksi fitur, serta implementasi algoritma KNN menunjukkan efektivitas dalam mengatasi tantangan penyakit tanaman jeruk. Penelitian ini memberikan kontribusi signifikan terhadap aplikasi teknologi pengolahan gambar untuk deteksi penyakit pertanian.

UCAPAN TERIMAKASIH

Kami mengucapkan terima kasih kepada Departemen Teknologi Informasi, Fakultas Studi Vokasional, Institut Teknologi Del, Indonesia.

REFERENSI

1. R. Saha, “Orange Fruit Disease Classification using Deep Learning Approach,” *International Journal of Advanced Trends in Computer Science and Engineering*, vol. 9, no. 2, pp. 2297–2301, Apr. 2020, doi: 10.30534/IJATCSE/2020/211922020.
2. W. Chen, D. Modi, and A. Picot, “Soil and Phytomicrobiome for Plant Disease Suppression and Management under Climate Change: A Review,” *Plants 2023, Vol. 12, Page 2736*, vol. 12, no. 14, p. 2736, Jul. 2023, doi: 10.3390/PLANTS12142736
3. A. F. Catara, M. Bar-Joseph, and G. Licciardello, “Exotic and emergent citrus viruses relevant to the mediterranean region,” *Agriculture (Switzerland)*, vol. 11, no. 9, p. 839, Sep. 2021, doi: 10.3390/AGRICULTURE11090839/S1.
4. E. A. Mohammed and G. H. Mohammed, “Citrus leaves disease diagnosis,” *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 31, no. 2, pp. 925–932, Aug. 2023, doi: 10.11591/IJEECS.V31.I2.PP925-932.
5. R. Vinuesa *et al.*, “The role of artificial intelligence in achieving the Sustainable Development Goals,” *Nature Communications 2020 11:1*, vol. 11, no. 1, pp. 1–10, Jan. 2020, doi: 10.1038/s41467-019-14108-y.
6. I. H. Sarker, “Machine Learning: Algorithms, Real-World Applications and Research Directions,” *SN Comput Sci*, vol. 2, no. 3, pp. 1–21, May 2021, doi: 10.1007/S42979-021-00592-X/FIGURES/11.
7. V. Singh and A. K. Misra, “Detection of plant leaf diseases using image segmentation and soft computing techniques,” *Information Processing in Agriculture*, vol. 4, no. 1, pp. 41–49, Mar. 2017, doi: 10.1016/J.INPA.2016.10.005.



SENADA
Seminar Nasional Sains Data

Seminar Nasional Sains Data 2024 (SENADA 2024)

E-ISSN 2808-5841

UPN “Veteran” Jawa Timur

P-ISSN 2808-7283

8. D. Al Bashish, M. Braik, and S. Bani-Ahmad, “Detection and classification of leaf diseases using Kmeans-based segmentation and neural-networks-based classification,” *Information Technology Journal*, vol. 10, no. 2, pp. 267–275, 2011, doi: 10.3923/ITJ.2011.267.275.
9. Johannes *et al.*, “Automatic plant disease diagnosis using mobile capture devices, applied on a wheat use case,” *Comput Electron Agric*, vol. 138, pp. 200–209, Jun. 2017, doi: 10.1016/J.COMPAG.2017.04.013.
10. U. Barman and R. D. Choudhury, “Smartphone image based digital chlorophyll meter to estimate the value of citrus leaves chlorophyll using Linear Regression, LMBP-ANN and SCGBP-ANN,” *Journal of King Saud University - Computer and Information Sciences*, vol. 34, no. 6, pp. 2938–2950, Jun. 2022, doi: 10.1016/J.JKSUCI.2020.01.005.
11. R. K. N and C. H. K, “Identification and Classification of Fruit Diseases,” *Int. Journal of Engineering Research and Application* www.ijera.com, vol. 6, pp. 11–14, 2016, Accessed: Jan. 25, 2024. [Online]. Available: www.ijera.com
12. I. U. W. Mulyono *et al.*, “Parijoto Fruits Classification using K-Nearest Neighbor Based on Gray Level Co-Occurrence Matrix Texture Extraction,” *J Phys Conf Ser*, vol. 1501, no. 1, p. 012017, Mar. 2020, doi: 10.1088/1742-6596/1501/1/012017.
13. S. Syahrini, D. Syamsudin, D. H. R. Saputra, and A. Ahfas, “K-Nearest Neighbor Algorithm to Identify Cucumber Maturity with Extraction of One-Order Statistical Features and Gray-Level Co-Occurrence,” *IOP Conf Ser Earth Environ Sci*, vol. 819, no. 1, p. 012010, Jul. 2021, doi: 10.1088/17551315/819/1/012010.
14. Z. Fan, J. K. Xie, Z. Y. Wang, P. C. Liu, S. J. Qu, and L. Huo, “Image Classification Method Based on Improved KNN Algorithm,” *J Phys Conf Ser*, vol. 1930, no. 1, p. 012009, May 2021, doi: 10.1088/17426596/1930/1/012009.
15. E. Ozturk Kiyak, B. Ghasemkhani, and D. Birant, “High-Level K-Nearest Neighbors (HLKNN): A Supervised Machine Learning Model for Classification Analysis,” *Electronics 2023*, Vol. 12, Page 3828, vol. 12, no. 18, p. 3828, Sep. 2023, doi: 10.3390/ELECTRONICS12183828.
16. G. Prasad, V. S. Gaddale, R. C. Kamath, V. J. Shekaranai, and S. P. Pai, “A Study of Dimensionality Reduction in GLCM Feature-Based Classification of Machined Surface Images,” *Arab J Sci Eng*, pp. 1–23, May 2023, doi: 10.1007/S13369-023-07854-1/FIGURES/12.
17. G. Moreira, S. A. Magalhães, T. Pinho, F. N. Dos Santos, and M. Cunha, “Benchmark of Deep Learning and a Proposed HSV Colour Space Models for the Detection and Classification of Greenhouse Tomato,” *Agronomy 2022*, Vol. 12, Page 356, vol. 12, no. 2, p. 356, Jan. 2022, doi: 10.3390/AGRONOMY12020356