

Klasifikasi Tingkat Kematangan Buah Salak Sidempuan Menggunakan K-Nearest Neighbor pada Ruang Warna HSV

Hamdi Aulia Ramadhan¹, Sriani²

^{1,2}Ilmu Komputer, Sains dan Teknologi, Universitas Islam Negeri Sumatera Utara, Medan, Indonesia

Email: ¹hamdiaulia1999@gmail.com, ²sriani@uinsu.ac.id

Abstract

Determining the ripeness level of Salak Sidempuan fruit manually is often inaccurate, as it relies on human visual perception, which can be affected by lighting conditions, eye fatigue, and subjective judgment. Such limitations may reduce sorting quality and the market value of the fruit. This study proposes an automated ripeness classification system for Salak Sidempuan based on digital image processing using the K-Nearest Neighbor (K-NN) algorithm combined with the Hue Saturation Value (HSV) color model. The dataset consists of images of Salak Sidempuan at three ripeness stages (unripe, half-ripe, and ripe) captured using a smartphone camera. The process involves preprocessing, converting RGB images to HSV, extracting the average H, S, and V values, and classifying them using K-NN with Euclidean distance and K=5. The aim of this research is to design and implement a MATLAB-based application capable of classifying the ripeness level of Salak Sidempuan fruit quickly, accurately, and consistently. The evaluation was conducted on 15 test images to measure system performance using accuracy, precision, recall, and F1-score metrics. The experimental results show that the system achieved an accuracy of 80%, with high precision and recall values for the unripe and ripe classes. The Hue component proved to be the most stable parameter for distinguishing ripeness levels compared to Saturation and Value. This system is considered effective in supporting the objective sorting process of Salak Sidempuan and has the potential for further development into field-deployable solutions such as Android or IoT-based applications.

Keywords: Salak Sidempuan, Ripeness Classification, Digital Image Processing, HSV, K-Nearest Neighbor.

Abstrak

Penentuan tingkat kematangan buah salak Sidempuan secara manual sering kali kurang akurat karena bergantung pada persepsi visual manusia yang dipengaruhi faktor pencahayaan, kelelahan mata, dan perbedaan persepsi. Hal ini dapat menurunkan kualitas sortir dan nilai jual buah. Penelitian ini mengusulkan sistem klasifikasi otomatis tingkat kematangan buah salak Sidempuan berbasis pengolahan citra digital menggunakan algoritma K-Nearest Neighbor (K-NN) dengan metode Hue Saturation Value (HSV). Dataset terdiri dari citra buah salak pada tiga kategori kematangan (mentah, setengah matang, dan matang) yang diambil menggunakan kamera smartphone. Proses meliputi preprocessing, konversi citra RGB ke HSV, ekstraksi nilai rata-rata komponen H, S, dan V, kemudian klasifikasi menggunakan K-NN dengan jarak Euclidean dan parameter K=5. Tujuan penelitian ini adalah merancang dan mengimplementasikan aplikasi berbasis MATLAB yang mampu mengklasifikasikan tingkat kematangan buah salak secara cepat, akurat, dan konsisten. Evaluasi dilakukan terhadap 15 citra uji untuk mengukur kinerja sistem melalui metrik akurasi, precision, recall, dan F1-score. Hasil pengujian menunjukkan sistem mencapai akurasi 80%, dengan nilai precision dan recall yang tinggi pada kelas mentah dan matang. Nilai Hue terbukti sebagai parameter paling stabil dalam membedakan tingkat kematangan dibandingkan Saturation dan Value. Sistem ini dinilai efektif membantu proses sortasi buah salak secara objektif dan berpotensi dikembangkan lebih lanjut untuk integrasi ke perangkat lapangan seperti aplikasi Android atau IoT.

Kata Kunci: Salak Sidempuan, Klasifikasi Kematangan, Pengolahan Citra Digital, HSV, K-Nearest Neighbor.

1. PENDAHULUAN

Indonesia sebagai negara tropis memiliki kekayaan buah tropis beragam, termasuk buah salak Sidempuan yang dikenal unggul secara komersial. Namun, tingkat kematangan buah masih sering ditentukan secara visual oleh manusia, sehingga bersifat subjektif dan rentan terhadap variasi pencahayaan, persepsi individu, serta kondisi penanganan pascapanen. Untuk meningkatkan akurasi dan konsistensi pengolahan buah, diperlukan pendekatan otomatis berbasis teknologi computer vision yang dapat bekerja lebih objektif dan efisien.

Penelitian di bidang computer vision untuk klasifikasi kematangan buah telah berkembang pesat antara 2020 hingga 2024. Metode berbasis deep learning, seperti CNN, telah banyak digunakan: misalnya model ResNet50 dan MobileNetV2 dengan optimasi SGD mencapai akurasi hingga 95,57 % pada klasifikasi buah secara umum (Haipeng Shi, 2024). CNN juga diaplikasikan untuk penilaian kualitas buah dengan DenseNet, menghasilkan akurasi hingga 99,67 % pada dataset besar (Samin Morshed, 2022). Bahkan untuk klasifikasi kematangan buah sawit, deep CNN dengan transfer learning (ResNet50, InceptionV3) mampu meraih akurasi lebih dari 85 % (Mingqiang Han, 2025).

Alternatif non-deep-learning juga terbukti efektif: penggunaan HSV + K-Nearest Neighbor (K-NN) telah diterapkan untuk berbagai buah. Studi pada buah naga berhasil mencapai akurasi hingga 96,7 % pada kelas matang/mentah (dataset 120 citra, k=9/11) (Alders Paliling, 2025). Pada buah semangka, metode ini juga diujikan dan dipublikasikan tahun 2024 (Ayu Mahriza Agustin Efendi, 2024). Selain itu, klasifikasi kematangan mangga dengan HSV-K-NN menunjukkan akurasi tinggi (98,75 %) melebihi SVM (97,5 %) (Mutmainnah Muchtar, 2024). Demikian pula pada jeruk, akurasi klasifikasi buah segar vs busuk lewat HSV + K-NN mencapai sekitar 88,95 % (Nirma Nur Diana, 2025) (Stifani Napitu, 2023).

Meskipun demikian, belum ada penelitian yang secara khusus membahas klasifikasi kematangan buah salak Sidempuan menggunakan kombinasi HSV dan K-NN dengan validasi yang ketat. Hal ini menjadi gap penting, mengingat karakteristik unik salak Sidempuan dan potensinya sebagai komoditas daerah yang bernilai tinggi.

2. METODOLOGI PENELITIAN


2.1 Tahapan Penelitian

Penelitian ini dilaksanakan mulai Desember 2024 hingga Mei 2025 dengan tahapan: analisis masalah, pengumpulan data, preprocessing citra, ekstraksi fitur, perancangan sistem, implementasi, pengujian, serta dokumentasi. Jadwal penelitian dapat dilihat pada Tabel 1.

Tabel 1. Jadwal Penelitian

Jadwal Kegiatan	1				2				3				4				5				6			
	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4
Analisis Masalah																								
Pengumpulan Data																								
Analisis Data & Sistem																								
Perancangan Sistem																								

3. Ekstraksi Fitur
 - a. Menghitung nilai rata-rata Hue, Saturation, dan Value.
 - b. Dataset berupa vektor [H, S, V] disertai label kelas (Mentah, Setengah Matang, Matang).
4. Klasifikasi dengan K-NN
 - a. Algoritma K-Nearest Neighbor (K-NN) digunakan untuk klasifikasi.
 - b. Jarak yang digunakan: Euclidean Distance.
 - c. Parameter K diuji dengan beberapa nilai (K = 3, 5, 7).
 - d. Nilai K terbaik dipilih berdasarkan akurasi tertinggi.
5. Desain Eksperimen
 - a. Dataset dibagi menggunakan Hold-out Validation dengan proporsi 80% data latih dan 20% data uji.
 - b. Hasil menunjukkan bahwa K=5 menghasilkan akurasi tertinggi pada data uji dibandingkan nilai K lain.
6. Evaluasi Sistem
 - a. Evaluasi menggunakan Confusion Matrix.




Gambar 2. Flowchart Perancangan Sistem

3. HASIL DAN PEMBAHASAN

Bab ini berisi pemaparan hasil penelitian yang telah dilakukan serta pembahasan mendalam mengenai kinerja sistem yang dirancang. Data yang digunakan berupa citra digital buah salak hasil observasi lapangan yang dikategorikan ke dalam tiga tingkat kematangan, yaitu mentah, setengah matang, dan matang. Setiap citra diproses melalui beberapa tahapan, mulai dari representasi data, preprocessing, ekstraksi fitur menggunakan model HSV, hingga proses klasifikasi dengan algoritma K-NN. Selain itu, dilakukan pula pengujian terhadap akurasi, kecepatan pemrosesan, serta faktor-faktor yang memengaruhi kinerja sistem, seperti pencahayaan dan kualitas citra.

1. Analisis Kelemahan Sistem
 - a. Akurasi 80% dipengaruhi oleh keterbatasan dataset (15 citra), sehingga model belum cukup generalisasi. Faktor pencahayaan juga berpengaruh, karena nilai Hue berubah saat intensitas cahaya berbeda.
2. Perbandingan dengan Penelitian Sebelumnya
 - a. Dibandingkan penelitian sebelumnya, akurasi 80% masih lebih rendah dari CNN (95%) namun sebanding dengan KNN pada klasifikasi pisang (82%). Hal ini menunjukkan metode sederhana berbasis HSV dan KNN tetap relevan untuk dataset kecil.
3. Analisis Teknis (Kenapa Hue Dominan)
 - a. Hue terbukti lebih dominan dalam membedakan tingkat kematangan karena perubahan warna kulit salak jelas mengikuti pergeseran nilai Hue dari hijau ke coklat. Hal ini mendukung penggunaan HSV dibanding RGB.
4. Diskusi Kontribusi
 - a. Algoritma sederhana (KNN) + HSV → efisien, bisa dijalankan di MATLAB dan hardware rendah.
 - b. Mudah diimplementasikan ke aplikasi mobile/IoT (misalnya petani bisa foto buah lalu langsung tahu tingkat kematangan).



0,0	0,1	0,2	0,3	0,4	0,5	0,6	0,7
1,0	1,1	1,2	1,3	1,4	1,5	1,6	1,7
2,0	2,1	2,2	2,3	2,4	2,5	2,6	2,7
3,0	3,1	3,2	3,3	3,4	3,5	3,6	3,7
4,0	4,1	4,2	4,3	4,4	4,5	4,6	4,7
5,0	5,1	5,2	5,3	5,4	5,5	5,6	5,7
6,0	6,1	6,2	6,3	6,4	6,5	6,6	6,7
7,0	7,1	7,2	7,3	7,4	7,5	7,6	7,7

Gambar 2. Contoh Piksel Buah Salak 8 x 8

Tabel 3. Contoh Nilai Pixel

x,y	0	1	2	3	4	5	6	7
0	R=225, G=219, B=205	R=226, G=220, B=206	R=226, G=220, B=206	R=222, G=215, B=199	R=65, G=45, B=20	R=215, G=209, B=193	R=210, G=205, B=186	R=209, G=202, B=184
1	R=227, G=221, B=207	R=228, G=222, B=208	R=135, G=108, B=79	R=128, G=92, B=44	R=104, G=81, B=49	R=59, G=45, B=19	R=200, G=192, B=171	R=199, G=191, B=172
2	R=229, G=223, B=211	R=134, G=99, B=71	R=152, G=112, B=53	R=180, G=145, B=89	R=78, G=55, B=21	R=52, G=38, B=11	R=82, G=66, B=40	R=160, G=148, B=124

3	R=228, G=220, B=209	R=117, G=75, B=35	R=180, G=142, B=106	R=146, G=112, B=75	R=154, G=125, B=67	R=68, G=52, B=16	R=51, G=36, B=7	R=37, G=23, B=10
4	R=114, G=80, B=53	R=139, G=98, B=66	R=156, G=123, B=92	R=120, G=84, B=50	R=68, G=38, B=14	R=53, G=36, B=10	R=30, G=17, B=1	R=29, G=16, B=7
5	R=144, G=120, B=96	R=100, G=62, B=39	R=99, G=69, B=45	R=57, G=28, B=12	R=41, G=23, B=3	R=42, G=26, B=10	R=35, G=21, B=8	R=28, G=20, B=9
6	R=224, G=218, B=204	R=67, G=50, B=30	R=40, G=23, B=7	R=44, G=25, B=8	R=41, G=25, B=10	R=32, G=23, B=8	R=44, G=35, B=20	R=73, G=63, B=38
7	R=222, G=216, B=202	R=220, G=212, B=199	R=156, G=149, B=130	R=74, G=60, B=47	R=56, G=49, B=33	R=129, G=121, B=102	R=127, G=116, B=94	R=129, G=121, B=98

Nilai Mean RGB:

Nilai Warna Red : (0,0)=225 (0,1)=226 (0,2)=226 (0,3)=222 (0,4)=65 (0,5)=215 (0,6)=210 (0,7)=209 (1,0)=227 (1,1)=228 (1,2)=135 (1,3)=128 (1,4)=104 (1,5)=59 (1,6)=200 (1,7)=199 (2,0)=229 (2,1)=134 (2,2)=152 (2,3)=180 (2,4)=78 (2,5)=52 (2,6)=82 (2,7)=160 (3,0)=228 (3,1)=117 (3,2)=180 (3,3)=146 (3,4)=154 (3,5)=68 (3,6)=51 (3,7)=37 (4,0)=114 (4,1)=139 (4,2)=156 (4,3)=120 (4,4)=68 (4,5)=53 (4,6)=30 (4,7)=29 (5,0)=144 (5,1)=100 (5,2)=99 (5,3)=57 (5,4)=41 (5,5)=42 (5,6)=35 (5,7)=28 (6,0)=224 (6,1)=67 (6,2)=40 (6,3)=44 (6,4)=41 (6,5)=32 (6,6)=44 (6,7)=73 (7,0)=222 (7,1)=220 (7,2)=156 (7,3)=74 (7,4)=56 (7,5)=129 (7,6)=127 (7,7)=129.

Total Nilai Red : 7859

Total Piksel : 8 x 8 = 64

Mean Red : 7859 / 64 = 122.80

Nilai Warna Green : (0,0)=219 (0,1)=220 (0,2)=220 (0,3)=215 (0,4)=45 (0,5)=209 (0,6)=205 (0,7)=202 (1,0)=221 (1,1)=222 (1,2)=108 (1,3)=92 (1,4)=81 (1,5)=45 (1,6)=192 (1,7)=191 (2,0)=223 (2,1)=99 (2,2)=112 (2,3)=145 (2,4)=55 (2,5)=38 (2,6)=66 (2,7)=148 (3,0)=220 (3,1)=75 (3,2)=142 (3,3)=112 (3,4)=125 (3,5)=52 (3,6)=36 (3,7)=23 (4,0)=80 (4,1)=98 (4,2)=123 (4,3)=84 (4,4)=38 (4,5)=36 (4,6)=17 (4,7)=16 (5,0)=120 (5,1)=62 (5,2)=69 (5,3)=28 (5,4)=23 (5,5)=26 (5,6)=21 (5,7)=20 (6,0)=218 (6,1)=50 (6,2)=23 (6,3)=25 (6,4)=25 (6,5)=23 (6,6)=35 (6,7)=63 (7,0)=216 (7,1)=212 (7,2)=149 (7,3)=60 (7,4)=49 (7,5)=121 (7,6)=116 (7,7)=121.

Total Nilai Green : 6725

Total Piksel : 8 x 8 = 64

Mean Green : 6725 / 64 = 105.08

Nilai Warna Blue : (0,0)=205 (0,1)=206 (0,2)=206 (0,3)=199 (0,4)=20 (0,5)=193 (0,6)=186 (0,7)=184 (1,0)=207 (1,1)=208 (1,2)=79 (1,3)=44 (1,4)=49 (1,5)=19 (1,6)=171 (1,7)=172 (2,0)=211 (2,1)=71 (2,2)=53 (2,3)=89 (2,4)=21 (2,5)=11 (2,6)=40 (2,7)=124 (3,0)=209 (3,1)=35 (3,2)=106 (3,3)=75 (3,4)=67 (3,5)=16 (3,6)=7 (3,7)=10 (4,0)=53 (4,1)=66 (4,2)=92 (4,3)=50 (4,4)=14 (4,5)=10 (4,6)=1 (4,7)=7 (5,0)=96 (5,1)=39 (5,2)=45 (5,3)=12 (5,4)=3 (5,5)=10 (5,6)=8 (5,7)=9 (6,0)=204 (6,1)=30 (6,2)=7 (6,3)=8 (6,4)=10 (6,5)=8 (6,6)=20 (6,7)=38 (7,0)=202 (7,1)=199 (7,2)=130 (7,3)=47 (7,4)=33 (7,5)=102 (7,6)=94 (7,7)=98.

Total Nilai Blue : 5238

Total Piksel : 8 x 8 = 64

Mean Blue : 5238 / 64 = 81.84

Tabel 4. Contoh Nilai Pixel Mean

R	122.80
G	105.08
B	81.84

Tabel 5. Nilai Pixel Mean RGB

Nama Citra	R	G	B
Matang 1	125.54	108.21	84.75
Matang 2	114.57	94.97	74.62
Matang 3	114.89	92.47	67.03
Matang 4	107.84	87.48	68.34
Matang 5	105.79	86.48	67.7
Mentah 1	122.01	116.8	73.84
Mentah 2	129.14	118.4	75.02
Mentah 3	127.51	120.36	75.92
Mentah 4	136.37	131.32	90.29
Mentah 5	136.39	130.72	87.08
Setengah Matang 1	119.48	100.05	70.39
Setengah Matang 2	134.34	115.11	78.28
Setengah Matang 3	126.98	114.99	73.16
Setengah Matang 4	118.12	103.16	68.56
Setengah Matang 5	120.62	111.02	66.79

3.1. Metode HSV

Pada penelitian ini, ruang warna HSV (Hue, Saturation, Value) digunakan karena lebih representatif dalam menggambarkan karakteristik warna dibandingkan ruang warna RGB. Model HSV memisahkan aspek warna (Hue), tingkat kejenuhan (Saturation), dan tingkat kecerahan (Value), sehingga variasi warna pada objek citra dapat terdeteksi dengan lebih jelas. Oleh karena itu, sebelum dilakukan proses klasifikasi, nilai RGB terlebih dahulu dikonversi ke HSV sesuai dengan metode yang digunakan dalam penelitian ini.

Normalisasi RGB :

$R=122.8$, $G=105.08$, $B=81.84$ (skala 0–255)

$r = 122.8 / 255 = 0.4816$

$g = 105.08 / 255 = 0.4121$

$b = 81.84 / 255 = 0.3209$

C_{max} , C_{min} , Δ :

$C_{max} = \max(r,g,b) = 0.4816$

$C_{min} = \min(r,g,b) = 0.3209$

$\Delta = C_{max} - C_{min} = 0.1606$

Hue (H, derajat) :

Karena $C_{max} = r$

$H = 60 * (\frac{g-b}{\Delta} = \text{mod } 6)$

$H = 60 * \frac{0.4121-0.3209}{0.1606} \approx 60 * 0.5868 \approx 34.04^\circ$

Saturation (S, %) :

$S = \begin{cases} 0, & \text{jika } C_{max} = 0 \\ \Delta/C_{max}, & \text{lainnya} \end{cases}$

$S = 0.1606 / 0.4816 \approx 0.3335 * 100 = 33.35\%$

Value (V, %)

$V = C_{max} * 100$

$V = 0.4816 * 100 = 48.16\%$

Tabel 4. Contoh Nilai Pixel Mean HSV

H	34.04
S	33.35
V	48.16

Tabel 5. Dataset Citra Buah Sala HSV

Nama Citra	H	S	V
Matang 1	34.51	32.49	49.23
Matang 2	30.56	34.87	44.93
Matang 3	31.89	41.65	45.05
Matang 4	29.07	36.63	42.29
Matang 5	29.59	36.01	41.49
Mentah 1	53.51	39.48	47.85
Mentah 2	48.09	41.91	50.64
Mentah 3	51.68	40.46	50.01
Mentah 4	53.43	33.79	53.48
Mentah 5	53.1	36.16	53.49
Setengah Matang 1	36.25	41.09	46.85
Setengah Matang 2	39.42	41.73	52.68
Setengah Matang 3	46.64	42.38	49.8
Setengah Matang 4	41.89	41.96	46.32
Setengah Matang 5	49.3	44.63	47.3

Tabel berikut menunjukkan hasil conversi dari RGB ke HSV sesuai dengan metode yang digunakan.

3.2. Metode K-NN

K-Nearest Neighbor (KNN) merupakan metode klasifikasi yang menghitung jarak Euclidean untuk menentukan kelas terdekat. Prosesnya meliputi pelabelan citra berdasarkan observasi (Matang, Setengah Matang, Mentah), normalisasi data, perhitungan jarak, serta evaluasi hasil menggunakan confusion matrix.

Tabel 5. Dataset Pelabelan Citra

Nama Citra	H	S	V	Label
Matang 1	34.51	32.49	49.23	Matang
Matang 2	30.56	34.87	44.93	Matang
Matang 3	31.89	41.65	45.05	Matang
Matang 4	29.07	36.63	42.29	Matang
Matang 5	29.59	36.01	41.49	Matang
Mentah 1	53.51	39.48	47.85	Mentah
Mentah 2	48.09	41.91	50.64	Mentah
Mentah 3	51.68	40.46	50.01	Mentah
Mentah 4	53.43	33.79	53.48	Mentah
Mentah 5	53.1	36.16	53.49	Mentah
Setengah Matang 1	36.25	41.09	46.85	Setengah Matang
Setengah Matang 2	39.42	41.73	52.68	Setengah Matang
Setengah Matang 3	46.64	42.38	49.8	Setengah Matang
Setengah Matang 4	41.89	41.96	46.32	Setengah Matang
Setengah Matang 5	49.3	44.63	47.3	Setengah Matang

Normalisasi dilakukan untuk menyamakan skala setiap atribut agar tidak ada variabel yang lebih dominan. Proses ini mengubah nilai atribut ke rentang tertentu, sehingga perhitungan jarak pada algoritma KNN menjadi lebih adil dan akurat.

Normalisasi Min Max Scalling:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}}$$

Cari min dan max tiap fitur:

H = min = 29.07 (Matang 4), max = 53.51 (Mentah 1)

S = min = 32.49 (Matang 1), max = 44.63 (Setengah Matang 5)

V = min = 41.49 (Matang 5), max = 53.49 (Mentah 5)

Contoh Normalisasi Matang 1 (H=34.51, S=32.49, V=49.23):

$$H' = \frac{34.51 - 29.07}{53.51 - 29.07} = \frac{5.44}{24.44} = 0.2227$$

$$S' = \frac{32.49 - 32.49}{44.63 - 32.49} = 0$$

$$V' = \frac{49.23 - 41.49}{53.49 - 41.49} = \frac{7.74}{12} = 0.645$$

Tabel 6. Min dan Max

Keterangan	H	S	V
Max	53,51	44,63	53,49
Min	29,07	32,49	41,49

Tabel 7. Normalisasi

Nama Citra	H'	S'	V'	Label
Matang 1	0,223	0	0,645	Matang
Matang 2	0,061	0,196	0,287	Matang
Matang 3	0,115	0,755	0,297	Matang
Matang 4	0	0,341	0,067	Matang
Matang 5	0,021	0,290	0	Matang
Mentah 1	1	0,576	0,530	Mentah
Mentah 2	0,778	0,776	0,763	Mentah
Mentah 3	0,925	0,657	0,710	Mentah
Mentah 4	0,997	0,107	0,999	Mentah
Mentah 5	0,983	0,302	1	Mentah
Setengah Matang 1	0,294	0,708	0,447	Setengah Matang
Setengah Matang 2	0,423	0,761	0,933	Setengah Matang
Setengah Matang 3	0,719	0,815	0,693	Setengah Matang
Setengah Matang 4	0,525	0,780	0,403	Setengah Matang
Setengah Matang 5	0,828	1	0,484	Setengah Matang

Pembagian data dilakukan dengan metode K-Fold Cross Validation, di mana total 15 data dibagi menjadi K=5 bagian, masing-masing berisi 3 data uji. Setiap fold digunakan secara bergantian sebagai data uji, sementara data lainnya menjadi data latih. Dengan cara ini, seluruh data memperoleh kesempatan untuk diuji sehingga hasil evaluasi model lebih objektif dan menyeluruh.

Pembagian 5-Fold :

Data = 15 → setiap fold = 3 data uji.

Fold 1 (uji): Matang1, Mentah1, Setengah Mentah1

Fold 2 (uji): Matang2, Mentah2, Setengah Mentah2

Fold 3 (uji): Matang3, Mentah3, Setengah Mentah3

Fold 4 (uji): Matang4, Mentah4, Setengah Mentah4

Fold 5 (uji): Matang5, Mentah5, Setengah Mentah5

Metode K-Nearest Neighbor (KNN) bekerja dengan mencari kedekatan antar data menggunakan jarak Euclidean sebagai ukuran kemiripan. Setiap data uji dihitung jaraknya terhadap seluruh data latih, lalu dipilih tetangga terdekat sesuai nilai jarak terkecil. Hasil kedekatan ini menjadi dasar penentuan kelas prediksi.

Tabel 8. Nilai Jarak Euclidean Kfold 1

Nama Citra	Matang 1	Mentah 1	Setengah Matang 1	Label
Matang 2	0,439	1,042	0,585	Matang
Matang 3	0,838	0,932	0,238	Matang
Matang 4	0,707	1,127	0,605	Matang
Matang 5	0,735	1,149	0,670	Matang
Mentah 2	0,962	0,379	0,582	Mentah
Mentah 3	0,964	0,211	0,686	Mentah
Mentah 4	0,858	0,663	1,077	Mentah
Mentah 5	0,892	0,544	0,973	Mentah
Setengah Matang 2	0,838	0,727	0,506	Setengah Matang
Setengah Matang 3	0,955	0,403	0,502	Setengah Matang
Setengah Matang 4	0,871	0,533	0,246	Setengah Matang
Setengah Matang 5	1,180	0,460	0,610	Setengah Matang
Prediksi	Matang	Setengah Matang	Setengah Matang	

Pada Fold 1, data uji terdiri dari Matang 1, Mentah 1, dan Setengah Matang 1.

Jarak Euclidean Fold 1 Matang 1(uji), Matang 2(latih/tetangga) :

$$d = \sqrt{(0,061 - 0,223)^2 + (0,196 - 0)^2 + (0,287 - 0,645)^2}$$

$$d = \sqrt{(0,162)^2 + (-0,196)^2 + (0,358)^2}$$

$$d = \sqrt{0,026 + 0,038 + 0,128}$$

$$d = \sqrt{0,193}$$

$$d = 0,439$$

Jarak Euclidean Fold 1 Matang 1(uji) Matang 3(latih/tetangga) :

$$d = \sqrt{(0,115 - 0,223)^2 + (0,755 - 0)^2 + (0,297 - 0,645)^2}$$

$$d = 0,838$$

Jadi hasil prediksi Fold 1 Matang yaitu Matang, dikarenakan ada 4 data matang tetangga terdekat.

Jarak Euclidean Fold 1 Mentah 1 (uji), Mentah 2 (latih/tetangga) :

$$d = \sqrt{(0,778 - 0,223)^2 + (0,776 - 0)^2 + (0,763 - 0,645)^2}$$

$$d = 0,962$$

Jarak Euclidean Fold 1 Mentah 1 (uji), Mentah 3 (latih/tetangga) :

$$d = \sqrt{(0,925 - 0,223)^2 + (0,657 - 0)^2 + (0,710 - 0,645)^2}$$

$$d = 0,964$$

Tabel 9. Nilai Jarak Euclidean Kfold 2

Nama Citra	Matang 2	Mentah 2	Setengah Matang 2	Label
Matang 1	0,439	0,962	0,838	Matang
Matang 3	0,561	0,810	0,707	Matang
Matang 4	0,270	1,131	1,051	Matang
Matang 5	0,304	1,179	1,120	Matang
Mentah 1	1,042	0,379	0,727	Mentah
Mentah 3	1,067	0,196	0,559	Mentah

Mentah 4	1,179	0,742	0,872	Mentah
Mentah 5	1,171	0,568	0,727	Mentah
Setengah Matang 1	0,585	0,582	0,506	Setengah Matang
Setengah Matang 3	0,990	0,100	0,384	Setengah Matang
Setengah Matang 4	0,755	0,440	0,540	Setengah Matang
Setengah Matang 5	1,128	0,361	0,649	Setengah Matang
Prediksi	Matang	Setengah Matang	Setengah Matang	

Tabel 10. Nilai Jarak Euclidean Kfold 3

Nama Citra	Matang 3	Mentah 3	Setengah Matang 3	Label
Matang 1	0,838	0,964	0,955	Matang
Matang 2	0,561	1,067	0,990	Matang
Matang 4	0,487	1,170	1,064	Matang
Matang 5	0,559	1,206	1,114	Matang
Mentah 1	0,932	0,211	0,403	Mentah
Mentah 2	0,810	0,196	0,100	Mentah
Mentah 4	1,300	0,625	0,820	Mentah
Mentah 5	1,205	0,461	0,653	Mentah
Setengah Matang 1	0,238	0,686	0,502	Setengah Matang
Setengah Matang 2	0,707	0,559	0,384	Setengah Matang
Setengah Matang 4	0,423	0,520	0,351	Setengah Matang
Setengah Matang 5	0,776	0,422	0,299	Setengah Matang
Prediksi	Matang	Mentah	Setengah Matang	

Tabel 11. Nilai Jarak Euclidean Kfold 4

Nama Citra	Matang 4	Mentah 4	Setengah Matang 4	Label
Matang 1	0,707	0,858	0,871	Matang
Matang 2	0,270	1,179	0,755	Matang
Matang 3	0,487	1,300	0,423	Matang
Matang 5	0,087	1,408	0,810	Matang
Mentah 1	1,127	0,663	0,533	Mentah
Mentah 2	1,131	0,742	0,440	Mentah
Mentah 3	1,170	0,625	0,520	Mentah
Mentah 5	1,356	0,196	0,892	Mentah
Setengah Matang 1	0,605	1,077	0,246	Setengah Matang
Setengah Matang 2	1,051	0,872	0,540	Setengah Matang
Setengah Matang 3	1,064	0,820	0,351	Setengah Matang
Setengah Matang 5	1,137	1,045	0,383	Setengah Matang
Prediksi	Matang	Mentah	Setengah Matang	

Tabel 12. Nilai Jarak Euclidean Kfold 5

Nama Citra	Matang 5	Mentah 5	Setengah Matang 5	Label
Matang 1	0,735	0,892	1,180	Matang
Matang 2	0,304	1,171	1,128	Matang
Matang 3	0,559	1,205	0,776	Matang
Matang 4	0,087	1,356	1,137	Matang
Mentah 1	1,149	0,544	0,460	Mentah
Mentah 2	1,179	0,568	0,361	Mentah
Mentah 3	1,206	0,461	0,422	Mentah
Mentah 4	1,408	0,196	1,045	Mentah
Setengah Matang 1	0,670	0,973	0,610	Setengah Matang
Setengah Matang 2	1,120	0,727	0,649	Setengah Matang
Setengah Matang 3	1,114	0,653	0,299	Setengah Matang
Setengah Matang 4	0,810	0,892	0,383	Setengah Matang
Prediksi	Matang	Mentah	Mentah	

Setelah dilakukan perhitungan jarak terdekat dengan ketentuan K=5 menggunakan metode cross-validation dengan 5 fold, setiap pengujian menggunakan 12 data latih dan 3 data uji. Seluruh hasil prediksi dari masing-masing fold kemudian digabungkan ke dalam satu tabel agar lebih jelas dan mudah dianalisis.

Tabel 12. Hasil Prediksi KNN

Nama Citra	Label	Prediksi
Matang 1	Matang	Matang
Matang 2	Matang	Matang
Matang 3	Matang	Matang
Matang 4	Matang	Matang
Matang 5	Matang	Matang
Mentah 1	Mentah	Setengah Matang
Mentah 2	Mentah	Setengah Matang
Mentah 3	Mentah	Mentah
Mentah 4	Mentah	Mentah
Mentah 5	Mentah	Mentah
Setengah Matang 1	Setengah Matang	Setengah Matang
Setengah Matang 2	Setengah Matang	Setengah Matang
Setengah Matang 3	Setengah Matang	Setengah Matang
Setengah Matang 4	Setengah Matang	Setengah Matang
Setengah Matang 5	Setengah Matang	Mentah

Matriks evaluasi adalah ukuran untuk menilai kinerja model. Pada klasifikasi digunakan akurasi, presisi, recall, dan F1-score, sedangkan pada regresi digunakan MAE, RMSE, dan MAPE untuk melihat tingkat kesalahan prediksi.

Tabel 12. Confusion Matrix

Actual \ Pred	Matang	Mentah	Setengah Matang	Total
Matang	5	0	0	5
Mentah	0	3	2	5
Setengah Matang	0	1	4	5
Total	5	4	6	15

Akurasi = jumlah prediksi benar / total data

Jumlah prediksi benar = 5 (Matang) + 3 (Mentah) + 4 (Setengah Matang) = 12
 Total = 15

$$Akurasi = \frac{12}{15} = 0.8 = 80\%$$

Precision, Recall, F1 per kelas

Rumus:

$$Precision = TP / (TP + FP)$$

$$Recall = TP / (TP + FN)$$

$$F1 = 2 * (Precision * Recall) / (Precision + Recall)$$

Kelas Matang:

$$TP = 5, FP = 0, FN = 0$$

$$Precision = 5 / (5 + 0) = 1$$

$$Recall = 5 / (5 + 0) = 1$$

$$F1 = 1$$

Kelas Mentah

TP = 3, FP = 1 (1 dari Setengah Matang diprediksi Mentah), FN = 2 (2 Mentah diprediksi Setengah Matang)

$$Precision = 3 / (3 + 1) = 0.75$$

$$\text{Recall} = 3 / (3 + 2) = 0.6$$

$$F1 = 2 * (0.75 * 0.6) / (0.75 + 0.6) = 0.6667$$

Kelas Setengah Matang

TP = 4, FP = 2 (2 dari Mentah diprediksi Setengah Matang), FN = 1 (1 Setengah Matang diprediksi Mentah)

$$\text{Precision} = 4 / (4 + 2) = 0.6667$$

$$\text{Recall} = 4 / (4 + 1) = 0.8$$

$$F1 = 2 * (0.667 * 0.8) / (0.667 + 0.8) = 0.7273$$

Macro Average (rata-rata per kelas)

$$\text{Precision} = (1 + 0.75 + 0.667) / 3 = 0.806$$

$$\text{Recall} = (1 + 0.6 + 0.8) / 3 = 0.80$$

$$F1 = (1 + 0.667 + 0.727) / 3 = 0.798$$

Hasil akhir evaluasi:

Akurasi = 80%

Precision (macro avg) = 80.6%

Recall (macro avg) = 80%

F1-score (macro avg) = 79.8%

Tabel 12. Evaluation Metrics

Keterangan	Nilai
Akurasi	80%
Presisi	80.6%
Recall	80%
F1-score	79.8%

1. Analisis Kelemahan Sistem

- a. Akurasi 80% dipengaruhi oleh keterbatasan dataset (15 citra), sehingga model belum cukup generalisasi. Faktor pencahayaan juga berpengaruh.

2. Perbandingan dengan Penelitian Sebelumnya

- a. Dibandingkan penelitian sebelumnya, akurasi 80% masih lebih rendah dari CNN (95%) namun sebanding dengan KNN pada klasifikasi pisang (82%). Hal ini menunjukkan metode sederhana berbasis HSV dan KNN tetap relevan untuk dataset kecil.


3. Analisis Teknis (Kenapa Hue Dominan)

- a. Hue terbukti lebih dominan dalam membedakan tingkat kematangan karena perubahan warna kulit salak jelas mengikuti pergeseran nilai Hue dari hijau ke coklat. Hal ini mendukung penggunaan HSV dibanding RGB.


4. Diskusi Kontribusi

- a. Algoritma sederhana (KNN) + HSV → efisien, bisa dijalankan di MATLAB dan hardware rendah.
- b. Mudah diimplementasikan ke aplikasi mobile/IoT (misalnya petani bisa foto buah lalu langsung tahu tingkat kematangan).

Proses selanjutnya adalah untuk mengetahui hasil dari klasifikasi dengan dengan melalui proses menekan tombol "Masukkan Gambar" sebagai inputnya untuk mengunggah citra salak.



Gambar 12. Hasil Citra Matang 1 Setelah Gambar Dimasukkan



Gambar 12. Hasil Citra Mentah 1 Setelah Gambar Dimasukkan



Gambar 12. Hasil Citra Setengah Matang 1 Setelah Gambar Dimasukkan

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi tingkat kematangan buah salak Sidempuan berdasarkan warna kulit menggunakan algoritma K-Nearest Neighbor (K-NN) dan metode warna Hue Saturation Value (HSV). Sistem yang diimplementasikan dalam bentuk antarmuka pengguna berbasis MATLAB mampu melakukan klasifikasi secara otomatis dan memberikan hasil yang akurat. Berdasarkan hasil pengujian terhadap 15 gambar uji, sistem mencapai akurasi sebesar 80%, dengan nilai precision, recall, dan F1-score yang tinggi, terutama pada kelas buah matang.

Nilai Hue terbukti menjadi parameter paling dominan dan stabil dalam membedakan tingkat kematangan, dibandingkan Saturation dan Value yang lebih rentan terhadap pengaruh pencahayaan. Sistem ini menunjukkan performa yang efektif dan efisien dalam mendukung proses identifikasi kematangan buah secara objektif, sehingga berpotensi membantu petani dan pelaku industri pertanian dalam proses sortasi dan distribusi buah salak.

REFERENCES

- Arifin, A., & Sari, N. (2021). Sistem Identifikasi Buah Berdasarkan Warna Menggunakan Ekstraksi HSV dan K-NN. *Jurnal Teknologi dan Informatika*, 10(1), 88–94.
- Fadhilah, I., & Ramadhan, D. (2023). Deteksi Kematangan Buah Naga Menggunakan Analisis Warna dan Metode K-NN. *Jurnal Sains dan Informatika*, 12(2), 132–139.
- Fahrul, A., Yulia, R., & Katsum, B. R. (2020). Analisis Mutu dari Produk Sirup Salak Sidempuan Quality Analysis Product of Salak Sidempuan Syrup. *Jurnal TEKSAGRO e-ISSN*, 2723, 6528.
- Handayani, F., & Basri, M. (2022). Penerapan Metode K-Nearest Neighbor untuk Klasifikasi Warna Buah Jeruk. *Jurnal Sistem Informasi dan Komputersisasi Akuntansi (JUSIKA)*, 4(4), 113–119.
- Hayati, N. (2023). Klasifikasi Jenis Bunga Mawar Menggunakan Algoritma K-Nearest Neighbour. *Jurnal Informatika dan Riset*, 1(1), 31–37.
- Hidayat, M., & Nurhayati, S. (2021). Implementasi K-NN pada Sistem Pengenalan Warna Buah Apel Menggunakan Citra RGB dan HSV. *Jurnal Sistem Informasi dan Komputer Terapan Indonesia (JSIKTI)*, 3(2), 45–50.
- Indriyanto, J. (2021). Algoritma K-Nearest Neighbor untuk prediksi nasabah asuransi. Penerbit NEM.
- Muhammad, D. I., Ermatita, E., & Falih, N. (2021). Penggunaan K-Nearest Neighbor (KNN) untuk Mengklasifikasi Citra Belimbing Berdasarkan Fitur Warna. *Informatik: Jurnal Ilmu Komputer*, 17(1), 9–16.
- Pramudiya, R., Asyraq, C., Kadafi, A., & Sardika, R. P. (2024). Analisis Gambar Menggunakan Metode Grayscale Dan Hsv (Hue, Saturation, Value). *Just IT: Jurnal Sistem Informasi, Teknologi Informasi dan Komputer*, 174–180.
- Putra, P. H., Novelan, M. S., & Rizki, M. (2022). Analysis k-nearest neighbor method in classification of vegetable quality based on color. *J. Appl. Eng. Technol. Sci*, 3(2), 126–132.
- Razka, M. H., Wiratomo, D. S., Prasvita, D. S., Komp, S., & Kom, M. (2021). Klasifikasi Tingkat Kematangan Buah Apel Berdasarkan Fitur Warna Menggunakan Algoritma K-Nearest Neighbor dan Ekstraksi Warna HSV. In *Prosiding Seminar Nasional Mahasiswa Bidang Ilmu Komputer dan Aplikasinya* (Vol. 2, No. 2, pp. 176–182).
- Rizky, A., & Supriyadi. (2020). Analisis Citra Digital dalam Penentuan Kematangan Buah Menggunakan HSV dan K-NN. *Jurnal Rekayasa Teknologi dan Sistem Komputer*, 8(1), 78–84.
- Safithri, M., Ritonga, A. P. D., Indariani, S., & Dwicesaria, M. A. (2024). Kandungan Nutrisi dan Daya Inhibisi α -glukosidase Ekstrak Daging Buah Salak Sidempuan (*Salacca sumatrana*). *Current Biochemistry*, 11(1), 1–13.
- Saputra, J., Sa'adati, Y., Ardhana, V. Y. P., & Afriansyah, M. (2023). Klasifikasi Kematangan Buah Alpukat Mentega Menggunakan Metode K-Nearest Neighbor Berdasarkan Warna Kulit Buah. *Resolusi: Rekayasa Teknik Informatika dan Informasi*, 3(5), 347–354.
- Siregar, B., & Fadli, A. (2022). Identifikasi Kematangan Buah Salak Sidempuan Berdasarkan Karakteristik Warna Menggunakan CNN. *Jurnal Teknologi dan Komputer*, 10(2), 61–69.
- Siswanto, I., Utami, E., Raharjo, S., & Yogyakarta, A. (2020). Klasifikasi tingkat kematangan buah berdasarkan warna dan tekstur menggunakan metode k-nearest neighbor dan nearest neighbor classifier. *Inspiration: Jurnal Teknologi Informasi dan Komunikasi*, 10(1), 93–101.
- Sudipa, I. G. I., Azdy, R. A., Arfiani, I., & Setiohardjo, N. M. (2024). Leveraging k-nearest neighbors for enhanced fruit classification and quality assessment. *Indonesian Journal of Data and Science*, 5(1), 30–36.

- Utami, Rina, dkk. (2020). Klasifikasi Citra Digital Buah Mangga Menggunakan Metode K-NN. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, 7(1), 15–21.
- Wibowo, Arif, dan Fitriani, E. (2021). Penerapan Ekstraksi Warna HSV pada Identifikasi Kematangan Buah Tomat. *Jurnal Teknologi dan Sistem Komputer*, 9(4), 321–327.
- Yana, Y. E., & Nafi'iyah, N. (2021). Klasifikasi Kematangan Pisang Berdasarkan Fitur Warna, Tekstur, Bentuk Citra Menggunakan SVM dan KNN. *Res. J. Comput. Inf. Syst. Technol. Manag*, 4(1), 28.
- Yuliana, D., & Hadi, S. (2022). Pengolahan Citra Digital untuk Klasifikasi Kematangan Buah Pisang. *Jurnal Ilmiah Informatika*, 5(3), 99–105.