

Klasifikasi Tingkat Kematangan Pisang Berdasarkan Ekstraksi Fitur Tekstur dan Algoritme KNN

(Classification of Banana Ripe Level Based on Texture Features and KNN Algorithms)

Rifki Kosasih¹

Abstract—Bananas are fruits that are rich in vitamins, minerals, and carbohydrates. Banana trees are often cultivated as they have many benefits. In growing banana trees, it is necessary to consider the ripeness level of bananas since it can determine the quality of bananas when harvested. The ripeness level of bananas is related to marketing reach. If the marketing reach is far, the banana should be harvested when it is still raw. Therefore, a system that can classify bananas' ripeness levels is needed. In this study, 45 banana images were collected, with a composition of 30 images as training data and 15 images as test data. Afterward, the texture feature extraction method was utilized to determine the parameters affecting the ripeness level of bananas. The texture feature extraction used was based on a histogram that generated several parameters i.e., average intensity, skewness, energy descriptor, and smoothness in the image. In the subsequent stage, the classification based on the features obtained using KNN algorithm was conducted. Based on the results, it was found that the classification accuracy rate was 88.89%.

Intisari—Pisang merupakan buah yang memiliki kandungan vitamin, mineral, dan karbohidrat yang sangat besar. Tanaman pisang sering dibudidayakan karena memiliki banyak manfaat. Dalam membudidayakan tanaman pisang, perlu diperhatikan tingkat kematangan buah pisang tersebut. Hal ini berguna untuk menentukan mutu buah pisang tersebut saat dipanen. Tingkat kematangan pisang ini berhubungan dengan jangkauan pemasaran. Jika jangkauan pemasarannya jauh, sebaiknya pisang dipanen saat tingkat kematangan buah pisang masih cukup rendah. Oleh karena itu, dibutuhkan suatu sistem yang dapat mengklasifikasikan tingkat kematangan pisang. Tahapan pertama dalam pembuatan sistem adalah mengumpulkan data citra pisang sebanyak 45 citra, dengan komposisi 30 citra sebagai data latih dan 15 citra sebagai data uji. Selanjutnya, metode ekstraksi fitur tekstur digunakan untuk menentukan parameter yang berpengaruh terhadap tingkat kematangan buah pisang. Ekstraksi yang digunakan adalah ekstraksi fitur berdasarkan histogram. Pada ekstraksi fitur tekstur berdasarkan histogram ini dihasilkan beberapa parameter seperti rerata, *skewness*, *descriptor* energi, dan kehalusan pada citra. Tahapan selanjutnya adalah melakukan klasifikasi berdasarkan fitur yang telah diperoleh dengan menggunakan algoritme *K Nearest Neighbor* (KNN). Hasil yang diperoleh menunjukkan tingkat akurasi klasifikasi sebesar 88,89%.

Kata Kunci— Pisang, Ekstraksi Fitur, Klasifikasi, KNN.

¹Pusat Studi Komputasi Matematika Universitas Gunadarma, Jln. Margonda Raya No. 100, Depok 16424 INDONESIA (e-mail: rifki_kosasih@staff.gunadarma.ac.id)

I. PENDAHULUAN

Pisang merupakan buah yang mengandung banyak vitamin, karbohidrat, dan mineral. Tanaman pisang tumbuh di sekitar 150 negara, seperti India, Brazil, Filipina, Indonesia, Tiongkok, Ekuador, Kamerun, Meksiko, Kolombia, dan Kosta Rika [1]. Pisang juga menjadi salah satu buah alternatif bagi orang-orang yang mengalami kelelahan sehingga sangat diminati oleh banyak orang. Oleh karena itu, perlu bagi petani pisang untuk memperhatikan kualitas pisang tersebut. Salah satu cara untuk mengetahui kualitas pisang adalah dengan mengetahui tingkat kematangan pisang sehingga petani pisang mengetahui waktu yang tepat pisang tersebut dipanen. Tingkat kematangan pisang dapat dilihat dari perubahan warnanya [2].

Pada awalnya, perubahan warna pada pisang dapat diketahui dengan cara melihat menggunakan mata manusia. Akan tetapi, kondisi tersebut tidak mungkin dilakukan karena pisang yang diamati sangat banyak sehingga menyebabkan mata menjadi lelah yang berakibat pada terjadinya kesalahan dalam mengamati perubahan warna pada pisang. Oleh karena itu, dibutuhkan suatu sistem yang dapat mendeteksi tingkat kematangan pisang tersebut.

Pendeteksian tingkat kematangan pisang telah dilakukan peneliti terdahulu, seperti mendeteksi kematangan buah pisang berdasarkan fitur warna citra pisang menggunakan transformasi ruang warna HIS [2]. Data yang digunakan adalah dua puluh citra pisang dan diperoleh tingkat akurasi klasifikasi sebesar 85% [2]. Akan tetapi, klasifikasi yang digunakan hanya menggunakan dua kategori, yaitu mentah dan matang. Penelitian yang lain mengubah citra RGB menjadi format CIELAB untuk mendeteksi tingkat kematangan buah pisang [3]. Data yang digunakan adalah 49 citra pisang, sedangkan fitur yang digunakan adalah fitur L, a*, b*, persentase daerah berwarna coklat pada pisang, dan jumlah titik coklat pada pisang per cm². Dalam penelitian tersebut, klasifikasi dibagi menjadi tujuh kelas dan diperoleh tingkat akurasi sebesar 98%. Akan tetapi, metode yang digunakan menggunakan proses dan rumus yang sangat kompleks.

Penelitian berikutnya menggunakan algoritme *K Nearest Neighbors* (KNN) dan ruang warna YIQ untuk menentukan tingkat kematangan buah pisang [4]. Namun, pada penelitian ini, tingkat kematangan hanya dibagi menjadi empat kelas, yaitu sangat matang, busuk, mentah, dan matang. Data yang digunakan adalah 120 citra pisang dan rerata tingkat akurasi yang diperoleh sebesar 71,6675%.

Pada penelitian selanjutnya dilakukan identifikasi kematangan buah pisang menggunakan teknik jaringan saraf



Gbr. 1 Tahapan klasifikasi tingkat kematangan buah pisang.

tiruan berdasarkan fitur warna RGB [5]. Tingkat kematangan yang digunakan dibagi menjadi empat kelas dan sampel data yang digunakan adalah dua puluh data citra pisang. Pada penelitian ini, rerata tingkat akurasi yang diperoleh sebesar 90%. Akan tetapi, citra uji yang digunakan merupakan citra yang sama dengan citra latih.


Dari beberapa penelitian sebelumnya, untuk mengidentifikasi tingkat kematangan pisang, digunakan fitur ruang warna seperti HIS [2], CIELAB [3], YIQ [4], dan RGB [5]. Akan tetapi, penentuan kelas pada tingkat kematangan menjadi kompleks karena pendefinisian kelas menggunakan jangkauan (*range*) dari ruang warna. Oleh karena itu, pada makalah ini diusulkan pendeteksian tingkat kematangan buah pisang dengan menggunakan pendekatan lain, seperti ekstraksi fitur pisang berdasarkan tekstur. Ekstraksi fitur tekstur yang digunakan adalah tekstur berbasis histogram.

II. METODOLOGI

Gbr. 1 menunjukkan tahapan-tahapan pengklasifikasian tingkat kematangan buah pisang berdasarkan fitur tekstur dengan algoritme KNN. Tahapan pertama adalah pengambilan citra pisang. Citra yang digunakan adalah citra berwarna sehingga perlu dilakukan transformasi menjadi citra *grayscale* menggunakan (1).

$$I = 0,2989 * R + 0,5870 * G + 0,1140 * B. \quad (1)$$

Citra-citra yang sudah dtransformasi memiliki ukuran yang berbeda-beda sehingga perlu dilakukan penyekalaan ulang ukuran citra menjadi citra yang berukuran 150×200 . Tahapan



Gbr. 2 Sampel citra pisang.

selanjutnya adalah melakukan ekstraksi fitur tekstur berbasis histogram. Ekstraksi fitur tekstur ini menghasilkan beberapa parameter seperti rerata intensitas, *skewness*, *descriptor* energi, dan kehalusan intensitas pada citra. Fitur-fitur yang telah diperoleh selanjutnya digunakan sebagai parameter dalam melakukan pengklasifikasian tingkat kematangan buah pisang dengan algoritme KNN.

A. Sampel Citra

Pada makalah ini sampel citra yang digunakan adalah sampel citra berwarna dari buah pisang yang berjumlah 45 sampel citra berwarna dengan tingkat kematangan yang berbeda-beda, seperti diperlihatkan pada Gbr. 2. Data citra diperoleh menggunakan situs pencarian Google. Sampel-sampel tersebut selanjutnya dibagi menjadi dua data, yaitu data latih dan data uji. Pada data latih digunakan 30 sampel citra, sedangkan pada data uji digunakan 15 sampel citra. Dalam makalah ini data latih digunakan sebagai data historis, sedangkan data uji adalah data yang digunakan untuk menguji metode yang digunakan, baik atau tidak.

Pada Gbr. 2, terdapat tujuh sampel pisang dengan tujuh tingkat kematangan yang berbeda. Gbr. 2(a) menunjukkan tingkat kematangan pertama. Pisang berwarna hijau segar, sangat bagus jika dipanen di perkebunan. Pada tingkat kematangan kedua, Gbr. 2(b), pisang berwarna hijau terang yang siap untuk diambil toko. Pisang dengan tingkat kematangan ketiga, ditunjukkan pada Gbr. 2(c), berwarna hijau dengan sedikit warna kuning, yang baik untuk distok ditoko. Pada Gbr. 2(d), pisang dengan tingkat kematangan keempat berwarna kuning dengan sedikit warna hijau, yang baik untuk dipajang dan dijual di toko. Selanjutnya, pisang dengan tingkat kematangan kelima berwarna kuning dan bertangkai hijau, yang siap untuk dikonsumsi, ditunjukkan pada Gbr. 2(e). Pada tingkat kematangan keenam, tampak pada Gbr. 2(f), pisang berwarna kuning seluruhnya yang

sangat enak untuk dikonsumsi. Pisang dengan tingkat kematangan ketujuh, yang ditunjukkan pada Gbr. 2(g), berwarna kuning dengan sedikit bintik coklat, yang merupakan pisang dengan rasa, aroma, dan gizi yang terbaik [6]. Setelah data sampel diperoleh, tahapan selanjutnya adalah melakukan ekstraksi fitur menggunakan histogram.

B. Ekstraksi Fitur

Fitur merupakan karakteristik unik dari suatu objek di dalam citra yang hendak dibedakan dengan objek lainnya. Informasi yang telah diekstrak kemudian digunakan sebagai parameter masukan untuk membedakan antara objek satu dengan lainnya pada tahapan identifikasi/klasifikasi.

Fitur-fitur yang biasa diamati adalah fitur warna, fitur bentuk, dan fitur tekstur. Fitur-fitur tersebut dapat dikenali karena beberapa objek mempunyai pola-pola tertentu, sehingga mudah dibedakan oleh manusia. Pada fitur warna, biasanya objek benda dikenali dengan adanya perbedaan warna di ruang warna tertentu, seperti ruang warna YIQ [4]. Selanjutnya, pada fitur bentuk, biasanya objek dikenali dengan adanya perbedaan bentuk pada suatu objek. Salah satu cara untuk mendapatkan fitur bentuk tersebut adalah dengan menggunakan momen Zernike [7]. Lalu, pada fitur tekstur, biasanya objek dikenali melalui perubahan tekstur objek tersebut.

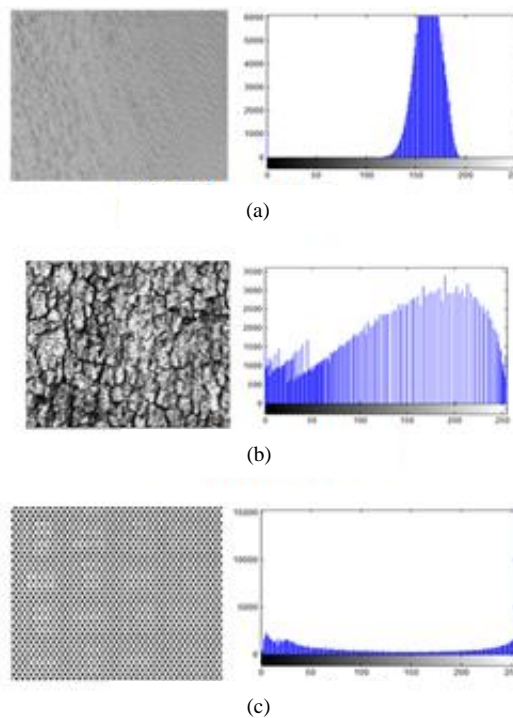
Fitur tekstur telah diaplikasikan di bidang-bidang seperti industri tekstil, analisis citra medis (klasifikasi penyakit paru-paru), dan analisis penginderaan jarak jauh [8]. Tekstur didefinisikan sebagai hubungan *mutual* antar nilai intensitas piksel-piksel yang bertetangga yang berulang di suatu area yang lebih luas daripada jarak hubungan tersebut [9].

Salah satu cara untuk mendapatkan fitur tekstur tersebut adalah dengan menggunakan informasi dari histogram. Oleh karena itu, informasi histogram tersebut dapat menjadi acuan komputer untuk dapat mengenali jenis-jenis tekstur. Contoh fitur tekstur berdasarkan histogram ditunjukkan pada Gbr. 3.

Pada makalah ini, fitur yang digunakan adalah fitur tekstur. Fitur tekstur dapat dikelompokkan menjadi tiga jenis, yaitu tekstur halus, tekstur kasar, dan tekstur periodik, yang berturut-turut ditunjukkan pada Gbr. 3(a) sampai Gbr. 3(c) [10]. Untuk membedakan tekstur objek satu dengan objek lainnya, dapat digunakan ciri statistik orde pertama atau ciri statistik orde dua [11]. Ciri orde pertama biasanya berdasarkan pada karakteristik histogram citra, seperti rata-rata, *skewness*, energi, dan kehalusan [11]. Selanjutnya, ciri orde dua biasanya berdasarkan pada probabilitas hubungan ketetanggaan antara dua piksel pada jarak dan orientasi sudut tertentu.

C. Fitur Tekstur Berbasis Histogram

Metode yang digunakan untuk mendapatkan tekstur adalah dengan memperhatikan bentuk histogram dari sebuah citra seperti pada Gbr. 3. Pada Gbr. 3 terlihat bahwa setiap tekstur memiliki histogram yang berbeda-beda, sehingga histogram dapat digunakan sebagai acuan untuk mengenali karakteristik suatu objek. Berdasarkan hasil dari histogram, fitur pertama yang dihitung menggunakan statistik adalah rerata intensitas. Komponen fitur ini dihitung menggunakan (2).



Gbr. 3 Contoh histogram, (a) tekstur halus, (b) tekstur kasar, (c) tekstur periodik.

$$\mu = \sum_{i=0}^{L-1} i \cdot p(i) \tag{2}$$

dengan *i* adalah aras keabuan pada citra *f*, *p(i)* menyatakan probabilitas kemunculan *i*, dan *L* menyatakan nilai aras keabuan tertinggi. Persamaan (2) menghasilkan rerata kecerahan objek.

Fitur kedua yang dapat dihitung adalah *skewness*. *Skewness* adalah ukuran ketidaksimetrisan terhadap rerata intensitas. Rumus perhitungannya ditunjukkan pada (3).

$$skewness = \sum_{i=1}^{L-1} (i - \mu)^3 p(i). \tag{3}$$

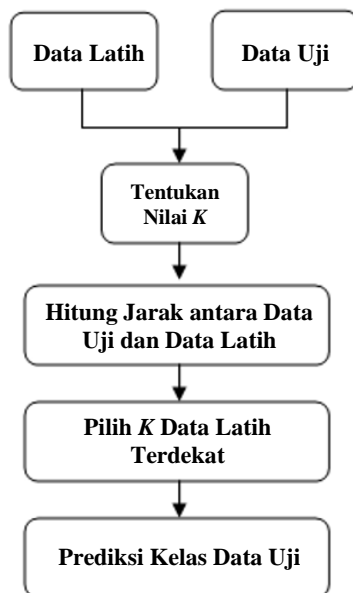
Skewness sering disebut sebagai momen orde tiga ternormalisasi. Nilai negatif menyatakan bahwa distribusi kecerahan condong ke kiri terhadap rerata, sedangkan nilai positif menyatakan bahwa distribusi kecerahan condong ke kanan terhadap rerata. Agar ternormalisasi, nilai *skewness* dibagi dengan $(L-1)^2$.

Fitur ketiga yang dapat dihitung adalah *descriptor* energi. *Descriptor* energi adalah ukuran yang menyatakan distribusi intensitas piksel terhadap jangkauan aras keabuan. Rumus perhitungannya dituliskan pada (4).

$$E = \sum_{i=0}^{L-1} [p(i)]^2. \tag{4}$$

Citra yang seragam dengan satu nilai aras keabuan akan memiliki nilai energi yang maksimum, yaitu sebesar 1. Secara umum, citra dengan sedikit aras keabuan akan memiliki energi yang lebih tinggi daripada citra yang memiliki banyak nilai aras keabuan. Energi sering disebut sebagai keseragaman.

Fitur keempat yang dapat dihitung adalah kehalusan intensitas pada citra. Rumus perhitungan kehalusan intensitas pada citra diperlihatkan pada (5).



Gbr. 4 Algoritme KNN.

$$R = 1 - \frac{1}{1+\sigma^2} \quad (5)$$

Pada (5), nilai R yang rendah menunjukkan bahwa citra memiliki intensitas yang kasar. Setelah dilakukan ekstraksi fitur tekstur berdasarkan histogram, tahapan selanjutnya adalah melakukan klasifikasi tingkat kematangan buah pisang dengan menggunakan algoritme KNN. Algoritme KNN merupakan algoritme klasifikasi yang tidak memerlukan pengetahuan tentang distribusi data [12]. Jadi, tanpa melihat distribusi data, metode KNN dapat digunakan untuk melakukan klasifikasi.

D. K Nearest Neighbor (KNN)

Algoritme KNN merupakan metode pengklasifikasian objek berdasarkan keserupaan dengan objek lain [13]. Oleh karena itu, jika terdapat sampel yang belum diketahui, sampel tersebut dapat diprediksi dengan melihat sampel tetangga terdekat di sekitarnya. Pada algoritme KNN, tahapan pertama adalah menentukan nilai K . Setelah itu, dihitung semua jarak dari satu data uji ke semua data latih. Selanjutnya, dipilih K data latih yang memiliki jarak terdekat dengan data uji. Dari K objek yang terpilih, jika yang dominan merupakan objek dengan kelas A, maka objek yang belum diketahui kelasnya diprediksi masuk ke kelas A juga [14], [15]. Langkah-langkah algoritme KNN diperlihatkan pada Gbr. 4.

III. HASIL DAN PEMBAHASAN

Berdasarkan tahapan penelitian yang telah dilakukan, data citra masukan yang digunakan adalah citra berwarna. Data citra dibagi menjadi dua, yaitu data latih dan data uji. Pembagian citra data latih dan data uji dilakukan menggunakan metode *n-fold validation*. Metode *n-fold validation* merupakan metode yang digunakan untuk membagi data latih dan data uji dengan bergantung pada nilai n yang dipakai [16]. Nilai n tersebut menentukan banyaknya iterasi yang digunakan. Dalam makalah ini, nilai n yang digunakan

TABEL I
DATA LATIH HASIL EKSTRAKSI FITUR BERBASIS HISTOGRAM (15 DARI 30 DATA LATIH)

Nama	Rerata	Skewness	Descriptor Energi	Kehalusan Citra	Kategori
P1	197,127	-5,9855	0,27598	0,08603	1
P2	208,515	-2,9354	0,25212	0,05683	1
P3	225,378	-2,5108	0,45057	0,03786	2
P4	227,954	-2,2652	0,36086	0,02915	2
P5	232,221	-0,7818	0,26323	0,01682	3
P6	231,471	-0,7911	0,27344	0,01746	3
P7	244,608	-0,7098	0,53331	0,00864	4
P8	244,741	-0,5197	0,35677	0,00629	4
P9	248,322	-0,3359	0,53966	0,00456	5
P10	248,150	-0,4803	0,34777	0,00502	5
P11	251,727	-0,0867	0,46747	0,00135	6
P12	222,000	-8,3781	0,36913	0,05901	7
P13	220,000	-1,2717	0,35407	0,07378	7
P14	234,047	-0,7932	0,28792	0,01605	3
P15	246,826	-0,3143	0,47729	0,00523	4

TABEL II
DATA UJI

Nama	Rerata	Skewness	Descriptor Energi	Kehalusan Citra
T1	199,7511	-3,94456	0,03376	0,06100
T2	209,2693	-4,31712	0,11563	0,05634
T3	226,3654	-2,97633	0,21543	0,03164
T4	234,0460	-0,79291	0,28622	0,01605
T5	238,0808	-0,15511	0,68952	0,00245
T6	246,9483	-0,24114	0,23288	0,00367
T7	243,6057	-0,32295	0,37358	0,00623
T8	248,4725	-0,31211	0,40285	0,00390
T9	249,8694	-0,22234	0,43305	0,00316
T10	221,7214	-6,02257	0,23557	0,04961
T11	246,1253	-0,31770	0,52654	0,00570
T12	246,1176	-0,19061	0,29540	0,00453
T13	248,2344	-0,99380	0,49357	0,00770
T14	242,6695	-0,38690	0,30850	0,00712
T15	249,8694	14,34940	-0,22230	0,00316

adalah 3, sehingga 45 data citra yang sudah dikumpulkan dibagi menjadi dua, dengan komposisi sebagai berikut:

Citra data latih adalah $\frac{2}{3}$ dari 45 = 30 citra,

Citra data uji adalah $\frac{1}{3}$ dari 45 = 15 citra.

Jumlah iterasi yang digunakan sebanyak tiga iterasi, karena nilai n yang digunakan adalah 3. Untuk iterasi ke-1, data uji yang digunakan adalah lima belas data pertama dari 45 data. Untuk iterasi ke-2, data uji yang digunakan adalah lima belas data yang berikutnya dari 45 data. Untuk iterasi ke-3, data uji yang digunakan adalah lima belas data terakhir dari 45 data. Data latih dan data uji pada iterasi ke-1 ditunjukkan pada Tabel I dan Tabel II.

Data citra yang digunakan memiliki ukuran yang berbeda-beda sehingga harus dilakukan penyekalaan ulang agar ukuran citra sampel menjadi sama. Tahapan selanjutnya adalah ekstraksi fitur tekstur yang dilakukan berdasarkan histogram masing-masing data citra, baik data latih maupun data uji. Ekstraksi fitur tekstur ini menghasilkan beberapa parameter,

TABEL III
HASIL KLASIFIKASI TINGKAT KEMATANGAN PISANG DENGAN MENGGUNAKAN METODE KNN

	Iterasi ke-1			Iterasi ke-2			Iterasi ke-3		
	Real	KNN	TP	Real	KNN	TP	Real	KNN	TP
T1	1	1	Sesuai	3	3	Sesuai	1	1	Sesuai
T2	1	1	Sesuai	4	4	Sesuai	1	1	Sesuai
T3	2	2	Sesuai	3	3	Sesuai	2	2	Sesuai
T4	3	3	Sesuai	7	7	Sesuai	2	2	Sesuai
T5	3	3	Sesuai	7	7	Sesuai	4	4	Sesuai
T6	4	5	Tidak	1	1	Sesuai	4	4	Sesuai
T7	4	4	Sesuai	1	1	Sesuai	5	5	Sesuai
T8	5	5	Sesuai	7	7	Sesuai	5	5	Sesuai
T9	5	5	Sesuai	1	1	Sesuai	3	3	Sesuai
T10	7	7	Sesuai	5	4	Tidak	3	3	Sesuai
T11	4	4	Sesuai	4	4	Sesuai	4	4	Sesuai
T12	4	5	Tidak	3	3	Sesuai	5	5	Sesuai
T13	5	5	Sesuai	4	4	Sesuai	6	5	Tidak
T14	4	4	Sesuai	5	5	Sesuai	4	4	Sesuai
T15	5	5	Sesuai	5	4	Tidak	5	5	Sesuai
	Jumlah Sesuai		13	Jumlah Sesuai		13	Jumlah Sesuai		14
	Tingkat Akurasi		86,67%	Tingkat Akurasi		86,67%	Tingkat Akurasi		93,33%
Rerata tingkat akurasi = $\frac{86,67\%+86,67\%+93,33\%}{3} = 88,89$									

seperti rerata intensitas, *skewness*, *descriptor* energi, dan kehalusan intensitas pada citra. Hasil dari ekstraksi fitur pada data latih ditunjukkan pada Tabel I.

Tabel I menyajikan lima belas sampel data latih dari tiga puluh data yang digunakan. Dari data latih tersebut, terdapat tujuh kelompok/kategori dengan empat fitur yang berbeda-beda. Fitur-fitur yang dihasilkan adalah fitur rerata, *skewness*, *deskriptor* energi, dan kehalusan citra. Fitur-fitur yang telah diperoleh digunakan sebagai parameter yang dapat mencirikan suatu kelas. Data latih ini selanjutnya digunakan sebagai data historis. Setelah itu, ekstraksi fitur juga dilakukan pada data uji, seperti ditunjukkan pada Tabel II.

Tabel II menyajikan lima belas data uji yang digunakan untuk menguji empat fitur tersebut dalam mengelompokkan data berdasarkan tingkat kematangan pisang. Untuk melakukan pengelompokan, digunakan algoritme KNN dengan nilai *K* adalah 1. Berdasarkan Tabel II, diketahui bahwa fitur rerata memiliki nilai ratusan, sedangkan fitur lainnya bernilai satuan, sehingga penggunaan KNN pada kasus ini akan membuat rerata menjadi fitur yang dominan dalam pengelompokan tingkat kematangan pisang.

Hasil pengelompokan dengan algoritme KNN diperlihatkan pada Tabel III. Tahapan selanjutnya adalah menghitung tingkat akurasi algoritme KNN menggunakan (6) [17].

$$Tingkat\ Akurasi = \frac{TP}{TP+FP} \times 100\% \quad (6)$$

dengan

TP = True Positive (pengamatan nyata sesuai dengan pengamatan dari komputer)

FP = False Positive (pengamatan nyata tidak sesuai dengan pengamatan dari komputer).

Dapat dilihat dari Tabel III bahwa pada iterasi pertama dan iterasi kedua jumlah sesuai (*TP*) = 13 dan *FP* = 2, sehingga diperoleh:

$$Tingkat\ Akurasi = \frac{13}{15} \times 100\% = 86,67\%.$$

Untuk iterasi ketiga, jumlah sesuai (*TP*) = 14 dan *FP* = 1, sehingga diperoleh:

$$Tingkat\ Akurasi = \frac{14}{15} \times 100\% = 93,33\%.$$

Berdasarkan ketiga iterasi tersebut diperoleh rata-rata tingkat akurasi:

$$Rata - Rata\ Tingkat\ Akurasi = \frac{86,67\%+86,67\%+93,33\%}{3} = 88,89\%.$$

IV. KESIMPULAN

Tingkat kematangan pisang biasanya dapat dilihat dari perubahan warnanya. Oleh karena itu, beberapa penelitian telah menggunakan fitur ruang warna untuk mendeteksi tingkat kematangan buah pisang. Namun, pendefinisian *range* nilai di dalam ruang warna menjadi kompleks sehingga dibutuhkan pendekatan lain untuk mendeteksi tingkat kematangan buah pisang. Makalah ini menggunakan metode ekstraksi fitur tekstur berdasarkan histogram untuk menentukan parameter yang berpengaruh pada tingkat kematangan buah pisang. Ekstraksi fitur tekstur ini menghasilkan beberapa parameter, seperti rerata intensitas, *skewness*, *descriptor* energi, dan kehalusan intensitas pada citra. Berdasarkan fitur yang telah diperoleh, dilakukan klasifikasi tingkat kematangan pisang menggunakan algoritme KNN. Dari hasil pengujian, diperoleh bahwa tingkat akurasi pengklasifikasian dengan algoritme KNN adalah sebesar 88,89%. Untuk penelitian selanjutnya, data citra pisang dapat diperbanyak dan dilakukan pengklasifikasian buah pisang menggunakan metode lain, seperti *Support Vector Machine* (SVM).

REFERENSI

- [1] D.S. Prabha dan J.S. Kumar, "Assessment of Banana Fruit Maturity by Image Processing Technique," *J. Food Sci. Technol.*, Vol. 52, No. 3, hal. 1316–1327, 2015.
- [2] Indarto dan Murinto, "Deteksi Kematangan Buah Pisang Berdasarkan Fitur Warna Citra Kulit Pisang Menggunakan Metode Transformasi Ruang Warna HIS," *JUITA*, Vol. 5, No. 1, hal. 15-21, 2017.
- [3] F. Mendoza dan J.M. Aguilera, "Application of Image Analysis for Classification of Ripening Bananas," *J. Food Sci.*, Vol. 69, No. 9, hal. 471-477, 2004.
- [4] G.A. Bere, E.N. Tamatjita, dan A. Kusumaningrum, "Klasifikasi untuk Menentukan Tingkat Kematangan Buah Pisang Sunpride," *Sem. Nas. Teknol. Inf. Kedirgantaraan (Proc. SENATIK)*, Vol. 2, hal. 109-113, 2016.
- [5] T.M. Siregar, L.A. Harahap, dan A. Rohanah, "Identifikasi Kematangan Buah Pisang (*Musa Paradisiaca*) dengan Teknik Jaringan Saraf Tiruan," *J. Rekayasa Pangan Pert.*, Vol. 3, No. 2, hal. 261-265, 2015.
- [6] (2018) "Mengenal Tingkat Kematangan Pisang," [Online], <http://balitbu.litbang.pertanian.go.id/eng/index.php/publikasi-mainmenu-47/leaflet/1232-mengenal-tingkat-kematangan-pisang>, tanggal akses 23-Jun-2020.
- [7] R. Kosasih, A. Fahrurrozi, dan D. Riminarsih, "Temu Kembali Citra dengan Menggunakan Momen Zernike dan City Block," *J. Ilmiah KOMPUTASI*, Vol. 17, No. 3, hal. 169-174, 2018.
- [8] M. Tuceryan dan A.K. Jain, "Texture Analysis," dalam *Handbook of Pattern Recognition and Computer Vision*, C.H. Chen, L.F. Pau, dan P.S.P. Wang, Eds., New Jersey, AS: World Scientific Publishing, 1998, hal. 207-248.
- [9] A.D. Kulkarni, *Artificial Neural Networks for Image Understanding*, New York, AS: Van Nostrand Reinhold, 1994.
- [10] P. Brodatz, *Textures: A Photographic Album for Artists and Designers*, New York, AS: Dover Publications, 1999.
- [11] A. Kadir dan A. Susanto, *Teori dan Aplikasi Pengolahan Citra*, Jogjakarta, Indonesia: Penerbit Andi, 2012.
- [12] Murni, R. Kosasih, A. Fahrurrozi, T. Handhika, I. Sari, dan D.P. Lestari, "Travel Time Estimation for Destination In Bali Using kNN Regression Method with Tensorflow," *IOP Conf. Ser.: Mater. Sci. Eng.*, Vol. 854, No. 1, hal. 1-8, 2020.
- [13] L. Devroye, L. Györfi, A. Krzyżak, dan G. Lugosi, "On the Strong Universal Consistency of Nearest Neighbor Regression Function Estimates," *Ann. Statist.*, Vol. 22, No. 3, hal. 1371–1385, 1994.
- [14] S.B. Imandoust dan M. Bolandraftar, "Application of K-Nearest Neighbor (KNN) Approach for Predicting Economic Events: Theoretical Background," *J. Eng. Res. App.*, Vol. 3, No. 5, hal. 605-610, 2013.
- [15] C. Domeniconi, J. Peng, dan D. Gunopulos, "Locally Adaptive Metric Nearest-Neighbor Classification," *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol. 24, No. 9, hal. 1281–1285, 2002.
- [16] D.P. Lestari, R. Kosasih, T. Handhika, I. Sari, dan A. Fahrurrozi, "Fire Hotspots Detection System on CCTV Videos Using You Only Look Once (YOLO) Method and Tiny YOLO Model for High Buildings Evacuation," *Proc. 2019 2nd Int. Conf. Comp. and Inf. Eng. (IC2IE)*, 2019, hal. 87–92.
- [17] R. Kosasih, "Kombinasi Metode Isomap dan KNN pada Image Processing untuk Pengenalan Wajah," *CESS (J. Comp. Eng. System Sci.)*, Vol. 5, No. 2, hal. 166-170, 2020.