

SISTEM KLASIFIKASI KUALITAS KOPRA BERDASARKAN WARNA DAN TEKSTUR MENGGUNAKAN METODE *NEAREST MEAN CLASSIFIER* (NMC)

Abdullah¹, Usman², M. Efendi³

^{1,2,3}Program Studi Sistem Informasi, Fakultas Teknik dan Ilmu Komputer
Universitas Islam Indragiri

Email: ¹abdialam@yahoo.com, ²usmanovsky13411@gmail.com, ³fendym12345@gmail.com

(Naskah masuk: 12 Oktober 2017, diterima untuk diterbitkan: 30 Desember 2017)

Abstrak

Klasifikasi kualitas kopra dengan bantuan komputer menggunakan pengolahan citra dapat membantu mempercepat pekerjaan manusia. Teknik data mining dapat dimanfaatkan untuk melakukan klasifikasi kualitas kopra berdasarkan warna RGB (*red, green, blue*) dan tekstur (*energy, contrast, correlation, homogeneity*). Permasalahannya adalah kesulitan memprediksi kualitas kopra dalam kategori A (80-85%), kategori B (70-75%) dan kategori C (60-65%). Tujuan dari penelitian ini ialah membangun aplikasi untuk klasifikasi kualitas kopra berdasarkan warna dan tekstur. Adapun metode klasifikasi yang digunakan adalah *nearest mean classifier* (NMC). Sebelum proses klasifikasi dilakukan praproses *background subtraction* dengan metode *pixel subtraction* untuk memisahkan objek dengan latarnya. Manfaat dari penelitian ini antara lain dapat menghemat waktu dalam melakukan klasifikasi kualitas kopra dan dapat mempermudah penentuan harga jual beli kopra. Berdasarkan hasil evaluasi dengan menggunakan metode *cross validation* diperoleh ketelitian rata-rata 80.67% dengan simpangan baku 1.17%.

Kata Kunci: *Klasifikasi, citra, kopra, nearest mean classifier, pixel subtraction, warna RGB, tekstur*

Abstract

The classification of copra quality with the help of computer by using image processing can help to speed up human work. Data mining techniques can be utilized for copra quality classification based on RGB color (red, green, blue) and texture (energy, contrast, correlation, homogeneity). The problem is the difficulty in predicting the quality of copra in grade of A (80-85%), grade of B (70-75%) and grade of C (60-65%). The objective of this study is to develop an application for the classification of copra quality based on color and texture. The method used is the nearest mean classifier (NMC). Preprocessing is done before the classification process for background subtraction by using pixel subtraction method to separate the image of object against the background. The benefits of this research are it can save time in classifying the quality of copra and can facilitate the determination of copra price. Based on the evaluation result by using cross validation method obtained the average accuracy is 80.67% with standard deviation is 1.17%.

Keywords: *classification, image, copra, nearest mean classifier, pixel subtraction, RGB color, texture*

1. PENDAHULUAN

Kelapa (*cocos nucifera*) merupakan pohon yang mempunyai nilai ekonomi yang tinggi. Kelapa terbungkus serabut dan batok yang cukup kuat. Setiap bagian dari pohon kelapa dapat dimanfaatkan bagi kepentingan manusia. Oleh karena itu, tanaman kelapa sering disebut sebagai pohon kehidupan.



Gambar 1. Kopra

Salah satu bentuk pengolahan kelapa adalah dengan menjadikannya kopra. Kopra adalah kelapa yang telah dikeluarkan isinya dan dikeringkan. Buah kelapa yang sudah dibelah mesti secepatnya dikeringkan menjadi kopra (lihat Gambar 1). Jika tetap berair permukaan daging buah akan berlendir dan berwarna kuning. Cara pengeringan buah kelapa digolongkan dalam dua cara, yaitu pengeringan menggunakan cahaya matahari dan pengeringan secara buatan.

Adapun cara pengeringan pertama dengan cahaya matahari yaitu daging kelapa yang masih melekat pada tempurung dijemur langsung di bawah terik matahari, sedangkan cara pengeringan kedua dengan pemanasan api yaitu dengan mengadakan kontak langsung daging buah dengan gas-gas atau panas api yang timbul dari pembakaran. Umumnya

cara ini disebut pula dengan pengasapan. Pengasapan bisa dilakukan di ruang terbuka atau mengeringkan di dalam ruang tertutup dengan udara yang dipanaskan.

Setelah selesai pengasapan kopra selanjutnya dilakukan pemisahan daging kopra dengan tempurungnya. Setelah selesai pemisahan daging kopra dengan tempurung lalu dimuat ke dalam karung. Setelah itu kopra dibawa ke penampung (tokeh) kopra. Tokeh kopra melakukan pengecekan dengan cara membuka karung lalu mencurah kopra ke permukaan lantai gudang kopra. Tokeh kopra melihat kopra dengan cara melihat warna dan ketebalan daging kopra secara kasat mata. Apabila warna kopra coklat kehitaman dan daging kopra tebal maka persentase kekeringan kopra baik. Namun hal ini dapat merugikan penjual kopra karena penentuan yang sepihak dan masih kurang akurat. Diperlukan pengamatan khusus terhadap pembakaran kopra terlebih dahulu untuk memperoleh pengukuran kualitas kopra yang akurat (Harsono and Siregar 2015).

Perkembangan perangkat keras dan perangkat lunak komputer yang begitu cepat dan didukung konsep datamining berupa klasifikasi pola serta teknik-teknik pengolahan citra, maka diharapkan penentuan klasifikasi kualitas kopra dengan bantuan komputer dapat direalisasikan untuk membantu mempercepat pekerjaan manusia pada umumnya dan tokeh kopra secara khususnya. Oleh karena itu tujuan penelitian ini adalah membangun aplikasi untuk memprediksi persentase kekeringan kopra.

2. TINJAUAN PUSTAKA

2.1. Citra Digital

Citra digital merupakan *image* dimana $f(x,y)$ yang telah didigitalisasikan (dibentuk menjadi diskrit) baik koordinat spasialnya atau tingkat intensitasnya (Bhat 2014). Citra yang ada didigitalisasi agar mudah diolah dan disimpan dalam media penyimpanan seperti memori computer, hard disk atau media lain. Dalam penelitian ini prediksi citra kopra dilakukan pada citra warna 24 bit dengan format Jpeg (jpg) dengan ukuran 640 x 480 piksel. Setiap piksel menyatakan kombinasi komponen warna *red*, *green* dan *blue* (RGB). Model RGB adalah model warna 24 bit. Dalam model warna 24 bit masing-masing kanal warna (R,G,B) memiliki 256 bin. Masing-masing komponen warna direpresentasikan dengan 8 *binary digit*. Delapan *binary digit* ini merepresentasikan angka intensitas pada piksel. Oleh karena itu terdapat sebanyak $2^8 = 256$ derajat intensitas (0– 255) untuk masing-masing komponen warna. Citra model warna 24 bit dikenal juga dengan sebutan citra 16 juta warna, sebab citra model ini dapat memproduksi sebanyak $2^{24} = 16.777.216$ kombinasi warna. Setiap citra dalam model RGB, maka pada setiap kanal warna R (*red*), G (*green*) dan B (*blue*) memiliki histogram. Histogram adalah fungsi yang mendistribusikan

jumlah piksel yang ada pada suatu citra untuk setiap level intensitas. Absisnya yang merupakan sumbu x adalah tingkat intensitas, dan ordinatnya yang merupakan sumbu y adalah frekuensi kemunculan atau banyaknya piksel dengan nilai intensitas tertentu.

Objek yang ditangkap melalui kamera digital disimpan dalam bentuk digital. Intensitas RGB pada masing-masing piksel yang membentuk citra dapat diilustrasikan sebagaimana matriks di bawah ini:

$$R = \begin{bmatrix} r_{11} & r_{12} & \dots & r_{1n} \\ r_{21} & r_{22} & \dots & r_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ r_{m1} & r_{m2} & \dots & r_{mn} \end{bmatrix}$$

$$G = \begin{bmatrix} g_{11} & g_{12} & \dots & g_{1n} \\ g_{21} & g_{22} & \dots & g_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ g_{m1} & g_{m2} & \dots & g_{mn} \end{bmatrix}$$

$$B = \begin{bmatrix} b_{11} & b_{12} & \dots & b_{1n} \\ b_{21} & b_{22} & \dots & b_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ b_{m1} & b_{m2} & \dots & b_{mn} \end{bmatrix}$$

2.2. Pengolahan Citra

Tujuan dilakukannya pengolahan citra pada klasifikasi pola adalah untuk memperbaiki mutu citra tersebut sehingga mudah diproses oleh komputer. Pengolahan citra merupakan langkah praproses (*preprocessing*) sebelum proses klasifikasi dilakukan dan termasuk didalamnya *background subtraction* (Kumar and Yadav 2017). Pengolahan citra akan mentransformasi citra yang asalnya kurang baik menjadi citra keluaran yang lebih baik. Dengan demikian, *input* nya merupakan citra dan *output* nya citra pula, hanya saja citra keluaran akan lebih berkualitas dibandingkan citra asal.

2.3. Background Subtraction

Background subtraction merupakan *preprocessing* bertujuan untuk memisahkan objek pada citra terhadap latar belakangnya. Proses ini dapat dilakukan dengan metode *pixel subtraction* yaitu dengan cara membaca citra objek dengan latarnya kemudian dilanjutkan membaca citra latar saja. Setelah itu pada kedua citra tersebut dilakukan operasi pengurangan nilai intensitas piksel, yaitu citra dengan objek dikurangi dengan citra latar belakangnya. Hal ini bertujuan agar citra objek benar-benar tersegmentasi dari latarnya.

Pixel subtraction saja tidak cukup, hal ini disebabkan karena pengambilan citra latar dilakukan sebelum pengambilan citra objek sehingga dimungkinkan ada perubahan intensitas cahaya walaupun sangat kecil pada selang waktu pengambilan citra tersebut. Oleh karena itu perlu dilakukan *threshold* (penentuan nilai ambang batas) pada operasi pengurangan nilai intensitas cahaya pada kedua citra. Dengan demikian hasil *background subtraction* yang dilakukan tersebut benar-benar optimal. Operasi pengurangan piksel (*pixel subtraction*) adalah nilai absolut pengurangan citra objek dengan citra latar. Hasil operasi *pixel subtraction* di peroleh dari persamaan (1).

$$Q(i, j) = |P_1(i, j) - P_2(i, j)| \dots \dots \dots (1)$$

dengan P_1 adalah citra objek dan P_2 adalah citra latar. Intensitas R, G dan B hasil background subtraction yang nilainya kurang dari nilai *threshold* yang ditentukan akan dianggap sebagai latar atau bukan objek sehingga tidak perlu diidentifikasi ciri atau fiturnya (Kamate and Yilmazer 2015).

2.4. Fitur

Fitur adalah segala jenis aspek pembeda atau ciri-ciri yang dapat membedakan. Fitur digunakan dalam melakukan identifikasi terhadap objek yang akan dikenali. Fitur yang baik ialah fitur yang mempunyai kemampuan yang besar untuk membedakan, dengan demikian pengelompokkan objek bisa dilakukan dengan baik dan memberikan akurasi yang baik pula. Oleh karena itu pemilihan fitur sangat menentukan keberhasilan dalam pengenalan pola. Pengukuran nilai fitur diperoleh dari hasil ekstraksi fitur pada objek. Beberapa fitur yang dapat digunakan dalam membedakan objek adalah warna RGB dan tekstur.

Fitur warna RGB dapat berupa mean warna. Jika sebuah citra dengan jumlah piksel P maka mean warna red (R), green (G) dan Blue (B) berturut-turut diberikan persamaan (2),(3) dan (4).

$$\bar{x} = (\bar{r}, \bar{g}, \bar{b})^T \text{ dimana:}$$

$$\bar{r} = \frac{\sum r(p)}{P} \quad (2)$$

$$\bar{g} = \frac{\sum g(p)}{P} \quad (3)$$

$$\bar{b} = \frac{\sum b(p)}{P} \quad (4)$$

$r(p), r(g),$ dan $b(p)$ merupakan intensitas pada setiap kanal r (*red*), g (*green*) dan b (*blue*) yang ada pada piksel p .

Adapun tekstur dapat dikalkulasi menggunakan distribusi frekuensi intensitas piksel pada posisi tertentu relatif terhadap posisi piksel lainnya. Citra

direpresentasikan menggunakan matriks yang komponennya bergantung pada jumlah piksel dan intensitas masing-masing piksel. Statistik yang menyatakan keterkaitan antar piksel yang satu dengan piksel yang lain pada citra, dikategorikan menjadi tiga macam: (1) statistik orde pertama, yaitu statistik dikalkulasi melalui intensitas piksel dari citra (misalnya fitur *mean* dan *variance*) dengan mengabaikan hubungan antar piksel bertetangga; (2) statistik orde ke-dua yaitu dikalkulasi melalui intensitas piksel dari citra dengan memperhatikan hubungan antara piksel yang bertetangga; (3) statistik orde ke-tiga atau di atasnya, yaitu dikalkulasi melalui intensitas piksel dari citra dimana hubungan antara tiga atau lebih piksel diperhitungkan.

Salah satu metode pada statistik orde kedua, yakni GLCM (*Gray-Level Cooccurrence Matrix*). GLCM melakukan tabulasi berkaitan dengan frekuensi intensitas piksel pada berbagai posisi dalam suatu citra. (Angkoso, 2011). Ada empat macam fitur tekstur yang sering digunakan dalam GLCM ialah energi, kontras, korelasi, dan homogenitas (Halim & Hardy, 2015). Energi merupakan fitur yang diukur melalui konsentrasi pasangan intensitas pada matriks *co-occurrence*. Matriks *co-occurrence* ialah suatu matrik yang menunjukkan frekuensi kemunculan pasangan piksel pada citra dengan intensitas, jarak dan arah tertentu. Persamaan yang digunakan untuk menghitung energi adalah persamaan (5). Kontras ialah fitur yang menggambarkan sejauh mana kekuatan perbedaan tingkat intensitas pada suatu citra. Nilai kontras berbanding lurus dengan variasi intensitas citra. Kontras diukur menggunakan formula (6). Korelasi menggambarkan sejauh mana tingkat keteraturan pada citra, apabila nilai pada matriks sama atau merata, maka nilai korelasi yang dihasilkan adalah minimum, sebaliknya apabila nilainya semakin tidak merata, maka korelasi akan maksimum. Korelasi dapat dikalkulasikan melalui formula (7). Homogenitas ialah fitur yang menggambarkan homogen tidaknya variasi intensitas pada citra. Homogenitas akan membesar jika variasi mengecil dan sebaliknya. Homogenitas dihitung dengan menggunakan persamaan (8).

$$E = \sum_{i_1} \sum_{i_2} p^2(i_1, i_2)^2 \quad (5)$$

$$I = \sum \sum (i_1 - i_2)^2 p(i_1, i_2) \quad (6)$$

$$C = - \sum_{i_1} \sum_{i_2} p(i_1, i_2) \log p(i_1, i_2) \quad (7)$$

$$H = \sum_{i_1} \sum_{i_2} \frac{p(i_1, i_2)}{1+|i_1, i_2|} \quad (8)$$

dengan p adalah probabilitas dalam matriks *co-occurrence*, i_1, i_2 adalah pasangan intensitas yang berdekatan, yang merupakan indeks baris dan kolom.

2.5. Data mining

Data mining merupakan proses penggalian pola dari sekumpulan data yang besar, dengan menggunakan teknik tertentu, yang menghasilkan nilai tambah berupa pengetahuan baru yang berharga dimana selama ini belum diketahui. *Data mining* beririsan dengan area lain, antara lain sistem basis data, jaringan syaraf tiruan, *pattern recognition*, data warehouse, statistik, mesin pembelajaran dan pencarian kembali informasi. *Data mining* dapat mempekerjakan satu atau lebih teknik pembelajaran komputer. Proses ini dapat otomatis atau semi otomatis. Pola yang digali lebih berarti dan pola tersebut menghasilkan pengetahuan yang berharga, yang umumnya menghasilkan nilai tambah ekonomi. (Gunawan, Putra, and Renaldi 2016).

2.6. Klasifikasi

Klasifikasi adalah proses pengelompokan objek ke dalam kategori tertentu berdasarkan fiturnya. Algoritma klasifikasi adalah sebuah fungsi yang memetakan objek ke salah satu label kelas tertentu. Algoritma klasifikasi atau *classifier* digunakan untuk melakukan tugas klasifikasi. Klasifikasi bertujuan untuk menentukan kategori objek yang belum diketahui label kelasnya berdasarkan karakteristik yang dimiliki objek tersebut, untuk dikategorikan ke dalam salah satu label kelas tertentu yang telah didefinisikan sebelumnya. Dalam klasifikasi terdapat dua proses yang dilakukan yaitu dengan membangun *classifier* (model) untuk disimpan dalam memori dan selanjutnya dilakukan pengenalan, klasifikasi atau prediksi pada suatu objek untuk ditentukan kategorinya berdasarkan model yang telah disimpan dalam memori tersebut. Model dapat berbentuk aturan (rule), pohon keputusan, jaringan syaraf tiruan ataupun formula matematika.

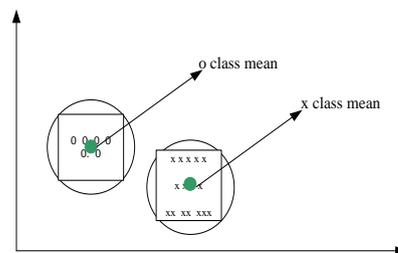
2.7. Nearest Mean Classifier

Nearest mean classifier (NMC) adalah sebuah teknik untuk melakukan klasifikasi (Bhavsar 2017). NMC sebagai sebuah pemilah menggunakan kemiripan antar pola untuk melakukan klasifikasi. Untuk setiap kelas, NMC menghitung rata-rata kelas (*centroid*) dari sampel data. Kemiripan diperoleh melalui perhitungan jarak *Euclidean* antara pola yang tidak diketahui dengan *centroid* dari sampel data. NMC mengklasifikasikan sebarang pola yang tidak diketahui ke kelas dengan *centroid* yang terdekat dengan pola yang akan dikenali. NMC telah berhasil diterapkan pada masalah klasifikasi dan menunjukkan hasil yang baik.

Nearest mean classifier merupakan pemilah linier sederhana untuk mengklasifikasikan sebuah objek yang tidak diketahui ke dalam suatu kelas terdekat. Metode ini disebut juga *minimum euclidean distance classifier*. Metode ini mudah dimengerti dan mudah diimplementasikan karena tidak membuat asumsi tentang distribusi data dalam ruang fitur. Setiap kelas (*cluster*) diwakili oleh rata-

rata vektor fitur objek yang sekelas berdasarkan data sampel. Rata-rata vektor fitur kelas (*class mean*) menjadi titik pusat kelas atau istilah lainnya adalah *centroid*. Selanjutnya klasifikasi didasarkan atas jarak terdekat vektor fitur objek dengan vektor fitur *class mean*.

Ilustrasi pada Gambar 2. di bawah ini menunjukkan dua buah kelas (*cluster*) yang diwakili oleh *class mean/ centroid*.



Gambar 2. Dua Buah Mean Kelas

Class mean pada masing-masing kelas dihitung berdasarkan nilai rata-rata fitur objek yang berada pada kelas yang sama. Aturan klasifikasi pada metode ini dapat dijelaskan sebagai berikut: jika diberikan dua buah kelas w_1 dan w_2 dan himpunan objek dinyatakan dalam himpunan vektor sebagai $\{x_1, \dots, x_n\}$, jika $\bar{x}_{(i)}$ adalah mean kelas w_i maka untuk objek baru z diklasifikasikan ke dalam kelas w_i jika dan hanya jika jarak euclidean $D^2(z, \bar{x}_{(1)}) < D^2(z, \bar{x}_{(2)})$. Algoritma NMC adalah sebagai berikut:

1. Tentukan *class mean* untuk setiap kelas.
2. Untuk setiap objek yang akan diklasifikasikan, hitung jaraknya (norma vektor) ke setiap *class mean* yang ada menggunakan jarak euclidean.
3. Objek diklasifikasikan ke kelas yang jarak objek dengan *class mean* adalah terdekat (minimum).

3. METODOLOGI PENGEMBANGAN SISTEM

Pada pengembangan sistem ini dilakukan penentuan klasifikasi kualitas kopra melalui pengolahan citranya. Prediksi citra kopra dilakukan pada citra warna 24 bit dengan format Jpeg (jpg) dengan ukuran 640x480 piksel. Klasifikasi dilakukan pada sekelompok kopra, bukan per item kopra. Ciri pembeda yang digunakan adalah fitur warna RGB yaitu *red green* dan *blue* serta fitur tekstur yaitu *contrast*, *correlation*, *energy* dan *homogeneity*.

Pengambilan citra dilakukan dengan menggunakan kamera, dimana kamera yang digunakan adalah Sony DSC-W610. Tinggi tripod waktu pengambilan citra adalah 47 cm, pencahayaan -1,0 dan zoom 1.4. Gambar 3 menampilkan perangkat keras yang digunakan. Kategori kualitas kopra selanjutnya dijadikan label kelas yaitu kelas A (80–85%), kelas B (70–75%) dan kelas C (60–65%).



Gambar 3. Perangkat Keras Penangkap Citra Kopra

4. IMPLEMENTASI SISTEM

Sistem dibagi menjadi dua buah sub sistem yaitu sub sistem pembentukan basis data fitur citra yang menyimpan pengetahuan tentang data sampel kopra dan sub sistem klasifikasi yang akan memprediksi kualitas kopra yang belum diketahui.

4.1. Sub Sistem Pembentuk kelas

Pembentuk kelas digunakan untuk melakukan pelatihan/ pengenalan sampel. Tampilan antar mukanya seperti Gambar 4.



Gambar 4. Sub Sistem Pembentuk Kelas

4.2. Sub Sistem Klasifikasi

Penentuan kualitas kopra dilakukan dengan cara melakukan query citra. Tampilan antar muka pemakai untuk sistem klasifikasi kualitas kopra seperti Gambar 5.



Gambar 5. Sub Sistem Klasifikasi

5. HASIL DAN EVALUASI

Pengujian dilakukan untuk mengetahui sejauh mana kemampuan sistem dalam melakukan klasifikasi kualitas kopra. Pengujian dilakukan dengan beberapa tahapan. Masing-masing pengujian pada kelas A (80-85 %), kelas B (70-75%) dan kelas C (60-65 %). Untuk setiap data uji pada masing-masing kelas dilakukan sepuluh kali eksperimen. Setiap kali eksperimen menggunakan metode *10-fold cross validation*. Selanjutnya terakhir dilakukan pengujian secara global untuk mengukur kemampuan sistem dalam melakukan klasifikasi pada semua kelas. Akurasi yang diperoleh secara global ini yang merupakan ketelitian sistem dalam melakukan klasifikasi kualitas kopra.

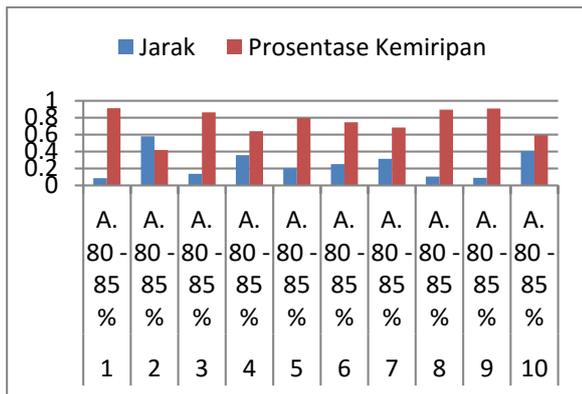
5.1. Pengujian Untuk Data Uji 80–85 %

Dalam rangka pengujian sistem untuk mendeteksi kualitas kopra 80-85% atau kelas A maka dilakukan sepuluh (10) kali eksperimen. Setiap kali eksperimen menghasilkan informasi berupa jarak kemiripan dan prosentase kemiripan. Semakin kecil jarak kemiripan berarti semakin besar persentase kemiripan. Hasil rata-rata diperoleh persentase kemiripan 74,63% dan simpangan baku 16,2%. Untuk lebih lengkapnya hasil pengujian kategori 80-85%, ditampilkan pada Tabel 1.

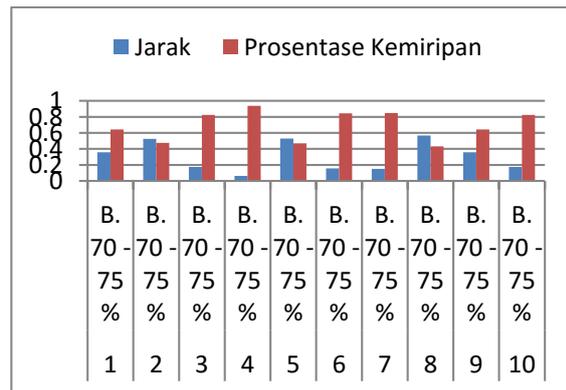
Tabel 1. Pengujian untuk Kategori 80–85%

No.	Kelas	Jarak	Persentase Kemiripan
1	80-85%	0.087391	91.26
2	80-85%	0.580568	41.94
3	80-85%	0.136787	86.32
4	80-85%	0.358948	64.11
5	80-85%	0.203877	79.61
6	80-85%	0.252446	74.76
7	80-85%	0.315572	68.44
8	80-85%	0.104578	89.54
9	80-85%	0.091114	90.89
10	80-85%	0.405636	59.44
Rata – Rata		0.253692	74.63
Simpangan Baku		0.16238	16.2

Gambar 6 merupakan grafik pengujian untuk data uji 80–85 %. Sepuluh (10) data eksperimen digunakan sehingga menghasilkan informasi berupa jarak dan prosentase kemiripan. Pengujian katedori kualitas bisa dilihat pada Gambar 6.



Gambar 6. Grafik Pengujian untuk Data Uji 80–85 %



Gambar 7. Grafik Pengujian untuk Data Uji 70–75 %

5.2. Pengujian Untuk Data Uji 70–75 %

Seperti halnya pada pengujian kualitas pada kelas A maka pada pengujian kelas B (70-75%) juga dilakukan sepuluh (10) kali eksperimen. Setiap kali eksperimen menghasilkan informasi berupa jarak kemiripan dan prosentase kemiripan. Berdasarkan Pengujian klasifikasi kualitas menggunakan data uji diperoleh rata-rata kemiripan sebesar 69,43% dan simpangan baku 18,6%. Selanjutnya hasil pengujian selengkapnya diperlihatkan pada Tabel 2.

Tabel 2. Pengujian Untuk Kategori 70–75%

No.	Kelas	Jarak	Persentase Kemiripan
1	70-75%	0.357899	64.21
2	70-75%	0.524852	47.51
3	70-75%	0.174955	82.50
4	70-75%	0.061913	93.81
5	70-75%	0.529663	47.03
6	70-75%	0.156025	84.40
7	70-75%	0.150776	84.92
8	70-75%	0.568089	43.19
9	70-75%	0.357899	64.21
10	70-75%	0.174955	82.50
Rata - Rata		0.305703	69.43
Simpangan Baku		0.17678	18.6

Gambar 7 merupakan grafik pengujian untuk data uji kelas B (70–75%). Sepuluh (10) data eksperimen digunakan sehingga menghasilkan informasi berupa jarak dan prosentase kemiripan. Pengujian klasifikasi kualitas bisa dilihat pada Gambar 7.

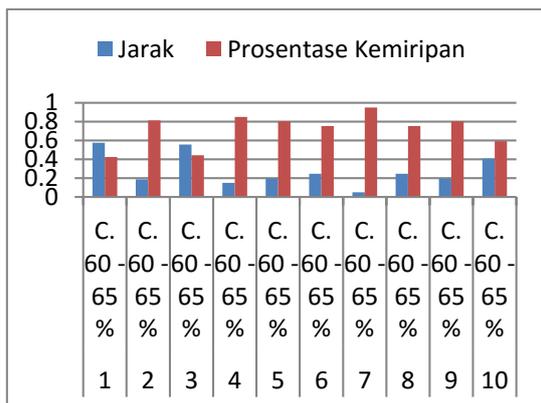
5.3. Pengujian Untuk Data Uji 60–65 %

Sepuluh (10) data eksperimen digunakan pada pengujian kualitas pada kelas C (60-65%) Setiap kali eksperimen menghasilkan informasi berupa jarak kemiripan dan prosentase kemiripan. Berdasarkan pengujian klasifikasi kualitas kelas C menggunakan data uji diperoleh rata-rata kemiripan sebesar 71,89% dan simpangan baku 17,5%. Hasil pengujian selengkapnya disajikan oleh Tabel 3.

Tabel 3. Pengujian Untuk Kategori 60–65%

No.	Kelas	Jarak	Persentase Kemiripan
1	60-65%	0.575948	42.41
2	60-65%	0.186366	81.36
3	60-65%	0.557663	44.23
4	60-65%	0.150148	84.99
5	60-65%	0.195508	80.45
6	60-65%	0.246113	75.39
7	60-65%	0.049931	95.01
8	60-65%	0.246113	75.39
9	60-65%	0.195446	80.46
10	60-65%	0.408213	59.18
Rata - Rata		0.281145	71.89
Simpangan Baku		0.17520	17.5

Gambar 8 merupakan grafik pengujian untuk data uji 60–65%. Sepuluh (10) data eksperimen digunakan sehingga menghasilkan informasi berupa jarak dan prosentase kemiripan. Pengujian klasifikasi kualitas bisa dilihat pada Gambar 8.



Gambar 8. Grafik Pengujian untuk Data Uji 60–65%

5.4. Pengujian Secara Global

Sebelumnya telah dilakukan pengujian untuk setiap kelas. Pada bagian ini dilakukan pengujian secara global, untuk menguji tingkat ketelitian aplikasi yang telah dibangun untuk memprediksi semua kelas yang ada yaitu A, B dan C. Berdasarkan hasil *eksperimen* pengujian menggunakan 10×10 -fold *cross validation* (Abdullah and Ku-mahamud 2016), secara umum dihasilkan ketelitian rata-rata 80.67% dengan simpangan baku 1.17%. Hasil evaluasi selengkapnya ditampilkan pada Tabel 4.

Tabel 4. Evaluasi Secara Global

No. Pengujian	Hasil
1	81.67
2	80.00
3	81.67
4	80.00
5	80.00
6	81.67
7	80.00
8	81.67
9	81.67
10	78.33
Rata-Rata	80.67
Simpangan Baku	1.17

6. KESIMPULAN DAN SARAN

Pada penelitian ini, metode *nearest mean classifier* (NMC) digunakan untuk memprediksi klasifikasi kualitas kopra berdasarkan warna RGB dan tekstur. Sebelum proses klasifikasi berjalan dilakukan background subtraction menggunakan metode *pixel subtraction*. Berdasarkan hasil percobaan menggunakan metode 10×10 -fold *cross validation*, dapat diambil kesimpulan pada masing-masing kategori sebagai berikut: pada klasifikasi

kualitas kopra kelas A (80–85%) dihasilkan ketelitian rata-rata 74.63 % dengan simpangan baku 16.2%; pada klasifikasi kualitas kopra kelas B (70–75%) rata-rata dihasilkan ketelitian 69.43% dengan simpangan baku 18.6%; sedangkan pada kualitas kopra kelas C (60–65%) rata-rata dihasilkan ketelitian 71.89% dengan simpangan baku 17.5%. Secara global berdasarkan hasil eksperimen diperoleh ketelitian rata-rata 80.67% dengan simpangan baku 1.17%. Prediksi persentase kekeringan kopra berdasarkan warna dan tekstur bisa dimanfaatkan dan dikembangkan lagi; serta dapat dikembangkan dengan berbasis android; selanjutnya perbaiki user interface sebaiknya dilakukan agar memudahkan pengguna.

7. DAFTAR PUSTAKA

- ABDULLAH, & KU RUHANA KU-MAHAMUD. 2016. Ant System-Based Feature Set Partitioning Algorithm for Classifier Ensemble Construction. *International Journal of Soft Computing* 11(3): 176–84.
- BHAT, MUZAMIL. 2014. Digital Image Processing. *International Journal of Scientific & Technology Research* 3(1): 272–76. www.ijstr.org.
- BHAVSAR, HEMINA. 2017. Review on Feature Extraction Methods of Image Based Sign Language Recognition System. *Indian Journal of Computer Science and Engineering* 8(3): 249–59.
- GUNAWAN, ABDILLAH, PUTRA, F. A. & RENALDI, F. 2016. Penerapan Data Mining Pemakaian Air Pelanggan Untuk Menentukan Klasifikasi Potensi Pemakaian Air Pelanggan Baru Di PDAM Tirta Raharja Menggunakan Algoritma K-Means. *Seminar Nasional Teknologi Informasi Dan Komunikasi (SENTIKA)*, Yogyakarta, 498–506.
- HARSONO, SISBUDI, S. & SIREGAR, K. 2015. Peningkatan Kinerja Mesin Diesel Dengan Produksi Biodiesel Dari Kelapa (Coconut Nufera) Dan Unjuk Kinerjanya Berbasis Transesterifikasi Dengan Sistem Injeksi Langsung. *Jurnal Rona Teknik Pertanian* 8 (2)(Oktober): 62–75.
- KAMATE, SHREYAMSH, & YILMAZER, N. 2015. Application of Object Detection and Tracking Techniques for Unmanned Aerial Vehicles. *Procedia Computer Science* 61: 436–41.
- KUMAR, SATRUGHAN, & YADAV, J.S. 2017. Advances in Intelligent Systems and Computing. *Proceeding of International Conference on Intelligent Communication, Control and Devices*, eds. R Singh and Choudhury.