

BAB II

KAJIAN PUSTAKA

2.1 Landasan Teori

2.1.1 Kopi Robusta (*Coffe Canefora*)

Kopi Robusta (*Coffea canefora*) adalah salah satu jenis kopi yang banyak dibudidayakan di Indonesia dan menjadi salah satu komoditas unggulan. Tanaman kopi Robusta pada beberapa penelitian menunjukkan yang cukup tahan terhadap serangan penyakit, serta mempunyai karakteristik rasa yang lebih pahit, sedikit asam dan mengandung kadar kafein lebih tinggi daripada kopi Arabika (Budi, 2020).

Varian biji kopi robusta bernilai lebih murah dibandingkan dengan kopi arabika, dengan terjangkaunya harganya varian kopi robusta lebih mendominasi terhadap permintaan konsumsi kopi secara global. Adapun keunggulan dari jenis tanaman kopi robusta dibandingkan dengan jenis tanaman kopi arabika yaitu kopi robusta lebih mudah untuk dibudidayakan dan tahan terhadap adanya penyakit, sehingga produksi biji kopi robusta cukup banyak dan menjadi mayoritas tanaman kopi di Indonesia.

Kopi Robusta dapat tumbuh maksimal dengan suhu udara harian 24–30 °C dengan pH tanah sebesar 5,5–6,5 dan curah hujan sebesar 1.500–3.000 mm/th (Er) (Sugito, 2020). Karakter morfologi yang khas pada kopi robusta adalah tajuk lebar, perwatakan besar, ukutan daun yang lebih besar atau lebar dibandingkan daun yang dimiliki tanaman biji kopi arabika, dan memiliki bentuk pangkal tumpul. Selain itu, daunnya juga tumbuh dengan berhadapan dengan batang, cabang, dan ranting – ranting yang dimiliki. Biji kopi Robusta memiliki karakteristik yang membedakan dengan kebanyakan biji kopi lainnya. Secara umum, biji kopi robusta memiliki rendeman yang lebih tinggi daripada biji kopi arabika. Selain itu, karakteristik yang menonjol yaitu bijinya yang agak bulat, lengkungan

bijinya yang lebih tebal dibandingkan dengan biji kopi arabika, dan garis tengah dari atas sampai ke bawah hampir rata (Anshori, 2014).

Pengolahan biji kopi mulai dari proses pemetikan sampai dengan biji kopi siap di sangria merupakan faktor yang sangat penting untuk memperkuat daya saing produk biji kopi dari Indonesia. Adapun hal yang melemahkan daya saing produk kopi dari Indonesia ini bahwa pengolahan biji kopi di Indonesia masih dilakukan dengan sangat sederhana.

2.1.2 Pengolahan Citra Digital

Pengolahan citra adalah pemrosesan citra, khususnya dengan menggunakan sebuah computer menjadi citra yang kualitasnya akan lebih baik. Agar citra yang mengalami gangguan mudah diinterpretasi (baik dilakukan oleh manusia maupun dilakukan oleh mesin), maka citra tersebut perlu dimanipulasi menjadi citra yang lain. Operasi-operasi yang ada pada pengolahan citra diterapkan pada citra apabila:

1. Perbaikan atau memodifikasi citra perlu dilakukan untuk meningkatkan kualitas penampakan atau untuk menonjolkan beberapa aspek informasi yang terkandung di dalam citra.
2. Elemen di dalam citra perlu dikelompokkan, dicocokkan, atau diukur.
3. Sebagian citra perlu digabung dengan bagian citra yang lain.

Pengolahan Citra bertujuan memperbaiki kualitas citra agar mudah diinterpretasi oleh manusia atau mesin (dalam hal ini komputer). Teknik-teknik pengolahan citra mentransformasikan citra menjadi citra lain. Jadi, masukannya adalah citra dan keluarannya juga citra, namun citra keluaran mempunyai kualitas lebih baik dari pada citra masukan. Termasuk kedalam bidang ini juga adalah pemampatan citra (*image compression*).

Pengenalan Pola mengelompokkan data numerik dan simbolik (termasuk citra) secara otomatis oleh mesin (dalam hal ini komputer). Tujuan pengelompokan adalah untuk mengenali suatu objek di dalam citra. Manusia bias mengenali objek yang dilihatnya karena otak manusia telah belajar mengklasifikasi objek-objek di alam sehingga mampu

membedakan suatu objek dengan objek lainnya. Kemampuan sistem visual manusia yang dicoba ditiru oleh mesin. Komputer menerima masukan berupa citra objek yang akan diidentifikasi, memproses citra tersebut, dan memberikan keluaran berupa deskripsi objek di dalam citra.

2.1.3 *Resize Citra*

Resize Citra atau penskalaan merupakan proses mengubah ukuran citra menjadi lebih kecil. Pada proses *resize* atau penskalaan pada penelitian ini tidak menggunakan metode khusus. Proses untuk melakukan *resize* pada penelitian ini yaitu dengan cara membandingkan ukuran citra dari segmentasi dengan target ukuran citra. *Resize Image* perlu dilakukan agar pada saat pemrosesan citra oleh komputer akan lebih cepat dan tidak banyak menghabiskan memori penyimpanan di dalam memori sementara (Putra, 2010).

2.1.4 *Grayscale*

Citra *grayscale* adalah citra berwarna keabu-abuan dengan memiliki variasi warna yaitu 8 bit ($2^8 = 256$) kemungkinan nilai. Disebut skala keabuan karena pada umumnya warna yang dipakai adalah antara hitam sebagai warna minimal dan putih sebagai warna maksimal, sehingga warna di antara keduanya adalah abu-abu. Namun dalam prakteknya warna yang dipakai tidak terbatas pada warna abu-abu sebagai contoh dipilih warna minimalnya adalah putih dan warna maksimalnya adalah merah, maka semakin besar nilainya semakin besar pula intensitas warna merahnya. Mengonversi citra berwarna RGB ke dalam citra *grayscale* sesuai dengan persamaan 2.1:

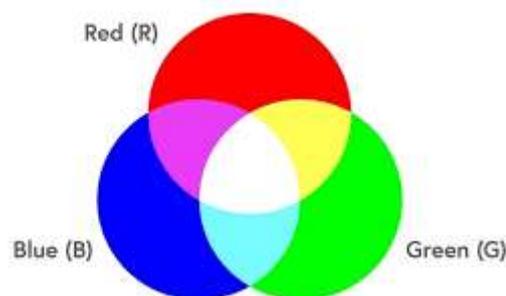
$$GS_{(x,y)} = 0.2989 * R_{(x,y)} + 0.5870 * G_{(x,y)} + 0.1141 * B_{(x,y)} \quad (2.1)$$

2.1.5 *RGB*

RGB adalah suatu model yang terdiri atas 3 buah warna, yaitu merah (*red*), hijau (*green*), biru (*blue*) yang ditambahkan sebagai cara untuk

menghasilkan bermacam – macam warna. Model warna RGB adalah model warna berdasarkan konsep penambahan kuat cahaya primer yaitu *red*, *green* dan *blue*. Dalam suatu ruang yang sama sekali tidak ada cahaya, maka ruangan tersebut adalah gelap total. Tidak ada signal gelombang cahaya yang diserap oleh mata atau RGB (0, 0, 0). Apabila menambahkan cahaya merah pada ruangan tersebut, maka ruangan akan berubah warna menjadi merah misalnya RGB (255, 0, 0), semua benda dalam ruangan tersebut hanya dapat terlihat berwarna merah. Demikian apabila cahaya ganti dengan hijau atau biru.

Seperti yang diketahui tahu bahwa RGB atau *Red*, *Green*, *Blue* merupakan sistem pewarnaan untuk digital *appearance* dan banyak sekali digunakan untuk monitor komputer, video, layar ponsel dll. Sistem warna RGB terdiri dari 100% Red, 100% Green dan 100% Blue yang menghasilkan 100 % putih. Tidak ada hitam di RGB.



Gambar 2.1 Warna RGB

2.1.6 Segmentasi Citra

Segmentasi Citra Digital adalah teknik untuk membagi atau memisahkan suatu citra menjadi beberapa daerah (*region*) atau beberapa objek dimana setiap daerah memiliki kemiripan atribut. Algoritma segmentasi citra didasarkan pada salah satu sifat dari dasar nilai intensitas, yaitu:

- a. *Discontinuity*, pendekatan dengan membagi citra berdasarkan perubahan besar pada nilai intensitasnya, seperti tepi citra.

- b. *Similarity*, pendekatan dengan membagi citra ke dalam region-region yang serupa sesuai dengan kriteria awal yang diberikan. Contoh pendekatan ini adalah *thresholding*, *region growing*, *region splitting*, *merging*.

Dengan proses segmentasi masing-masing objek pada citra dapat diambil secara individu sehingga dapat digunakan sebagai input bagi proses lain. Ada 2 macam segmentasi:

- a. *Full segmentation* adalah pemisahan suatu objek secara individu dari background dan diberi ID (label) pada tiap-tiap segmen.
- b. *Partial segmentation* adalah pemisahan sejumlah data dari *background* dimana data yang disimpan hanya data yang dipisahkan saja untuk mempercepat proses selanjutnya.

2.1.7 Region Growing

Region growing adalah prosedur untuk mengelompokkan piksel atau *sub-region* ke dalam *region* yang lebih besar berdasarkan pada kriteria yang sudah ditentukan untuk pertumbuhannya. Pendekatan dasarnya adalah memulai dengan sejumlah titik *seed* dan dari sini menumbuhkan *region* oleh penambahan pada setiap *seed* piksel tetangga yang mempunyai properti sama dengan *seed* (seperti range spesifik dari *gray level* atau warna).

Pemilihan sejumlah satu atau lebih *starting point* sering menjadi dasar masalah. Satu prosedur untuk menghitung pada setiap piksel kesamaan sekumpulan properti yang akhirnya akan digunakan untuk memberi nilai piksel pada *region* selama proses *growing*. Jika hasil dari komputasi ini menunjukkan *cluster* nilai, piksel yang tempat propertinya dekat *cluster centroid* dapat digunakan sebagai *seed*.

Pemilihan kesamaan kriteria tidak hanya tergantung pada masalah tersebut, tetapi juga pada jenis data citra yang tersedia. Ketika citranya monokrom, analisis *region* harus dilakukan dengan sejumlah deskriptor

yang didasarkan pada level intensitas (seperti momen atau tekstur) dan properti spesial.

Masalah lain dalam *region growing* adalah formulasi untuk aturan pemberhentian. Dasarnya, penumbuhan *region* seharusnya berhenti ketika tidak ada lagi piksel yang mencapai kriteria untuk inklusi dalam *region* tersebut. Kriteria seperti nilai intensitas, tekstur dan warna adalah lokal dan tidak dipakai dalam perhitungan *history region growing*.

Algoritma dari *Region Growing* adalah sebagai berikut:

1. Menentukan *Seed Point*. Pemilihan seed point tergantung beberapa kriteria pengguna. Bisa menggunakan Histogram untuk memilih *seed point* dengan intensitas antara 0 sampai 255. *Seed point* merupakan daerah awal berkembangnya. Daerah ini kemudian berkembang dari titik-titik benih sampai titik yang berdekatan tergantung pada kriteria keanggotaan daerah. Kriteria bisa berupa, misalnya, intensitas *pixel*, tekstur tingkat abu-abu, atau warna.
2. Menentukan batas minimum *Threshold*. Pemilihan *Threshold* tergantung beberapa kriteria pengguna, sama seperti memilih *seed point*. Daerah ini sebagai batas ambang batas pertumbuhan piksel.
3. Nilai Kesamaan (Homogenitas) berfungsi untuk mengatur mekanisme tumbuhnya seed dan menguji kehomogenan dari *region* setelah satu tahap tumbuh selesai.

2.1.8 Gray Level Co-occurrence Matrix (GLCM)

Gray Level Co-occurrence Matrix (GLCM) adalah suatu metode yang digunakan untuk analisis tekstur/ekstraksi ciri. GLCM merupakan suatu matriks yang menggambarkan frekuensi munculnya pasangan dua piksel dengan intensitas tertentu dalam jarak dan arah tertentu dalam citra (Prasetyo, 2011).

Terdapat 4 ciri GLCM yang akan digunakan yang nilainya didapatkan dari matriks GLCM, (Prasetyo, 2011) yaitu:

1. *Contrast*

Contrast merupakan suatu ciri untuk mengukur kekuatan perbedaan intensitas dalam citra. Nilai *contrast* semakin besar apabila variasi intensitas dalam citra tinggi dan sebaliknya nilai *contrast* semakin kecil apabila variasi intensitas dalam citra rendah. *Contrast* didefinisikan pada persamaan 2.2.

$$\text{Contrast} = \sum_{i_1} \cdot \sum_{i_2} \cdot (i_1 - i_2)^2 p(i_1, i_2) \quad (2.2)$$

2. *Homogeneity*

Homogeneity merupakan suatu ciri untuk mengukur kehomogenan variasi intensitas dalam citra dan merupakan kebalikan dari *contrast*. Nilai *homogeneity* semakin besar apabila variasi intensitas dalam citra nilainya mengecil dan sebaliknya nilai *homogeneity* semakin kecil apabila variasinya membesar. *Homogeneity* didefinisikan pada persamaan 2.3.

$$\text{Homogeneity} = \sum_{i_1} \cdot \sum_{i_2} \cdot \frac{p(i_1, i_2)}{1 + |i_1 - i_2|} \quad (2.3)$$

3. *Energy*

Energy merupakan suatu ciri untuk mengukur konsentrasi pasangan intensitas pada matriks GLCM. Nilai *Energy* semakin besar apabila pasangan piksel yang telah memenuhi syarat matriks *co-occurrence* terfokus pada beberapa koordinat dan sebaliknya nilai *energy* semakin kecil apabila letaknya menyebar. *Energy* didefinisikan pada persamaan 2.4.

$$\text{Energy} = \sum_{i_1} \cdot \sum_{i_2} \cdot p^2(i_1, i_2) \quad (2.4)$$

4. *Entropy*

Entropy merupakan suatu ciri untuk mengukur keteracakan dari distribusi intensitas. Nilai *entropy* maksimum apabila semua elemen matriks sama. *Entropy* didefinisikan pada persamaan 2.5.

$$\text{Entropy} = - \sum_{i_1} \cdot \sum_{i_2} \cdot p^2(i_1, i_2) \log p(i_1, i_2) \quad (2.5)$$

Pada empat persamaan diatas, notasi p adalah probabilitas (0-1) yaitu elemen dalam matriks GLCM, kemudian i_1 dan i_2 adalah pasangan intensitas yang berdekatan, nomor baris dan nomor kolom pada matriks GLCM.

2.1.9 Metode K-Nearest Neighbor

Algoritma *K-Nearest Neighbor* (K-NN) adalah sebuah metode untuk melakukan sebuah klasifikasi terhadap objek berdasarkan data pembelajaran yang jaraknya paling dekat dengan obyek tersebut. Prinsip kerja dari *K-Nearest Neighbor* (K-NN) adalah mencari jarak yang terdekat antara data yang akan dievaluasi dengan K tetangga (*Neighbor*) terdekatnya dalam data pelatihan (Sreemathy, 2012).

Algoritma *k-Nearest Neighbor* menggunakan metode pembelajaran *7 supervised*. Adapun perbedaan antara *supervised learning* dengan *unsupervised learning* adalah pada *supervised learning* bertujuan untuk menemukan pola baru dalam sebuah data dengan menghubungkan pola data yang sudah ada dengan data yang baru. Sedangkan pada *unsupervised learning*, data belum memiliki pola apapun, dan tujuan *unsupervised learning* untuk menemukan pola dalam sebuah data.

Pada algoritma *K - Nearest Neighbor* hanya melakukan penyimpanan pada *vector - vector* fitur dan klasifikasi dari adanya data pembelajaran. Pada tahap klasifikasi, fitur - fitur yang sama akan dihitung untuk data tes. Jarak dari *vector* yang baru ini terhadap seluruh *vector* data pembelajaran akan dihitung, dan jumlah k yang paling dekat juga akan diambil. Secara umum, nilai k yang tinggi dapat mengurangi efek *noise* pada klasifikasi, tetapi membuat batasan antara setiap klasifikasi menjadi lebih kabur. Nilai k yang baik dapat dipilih dengan optimasi parameter, misalnya dengan menggunakan *cross-validation*. Kasus khusus di mana klasifikasi diprediksikan berdasarkan data pembelajaran yang paling dekat (dengan kata lain, $k = 1$) disebut algoritma *k-nearest neighbor*. Digunakan rumus pada persamaan 2.6.

$$f(v_1, v_2) = \sqrt{\sum_{k=1}^n (v_1(k) - v_2(k))^2} \quad (2.6)$$

Keterangan persamaan diatas:

$f(v_1, v_2)$ = Jarak Euclidean

n = Jumlah sample

v_1 = Proses perhitungan pada data v ke-1

v_2 = Perhitungan pada data v ke-2

Pada persamaan diatas merupakan persamaan jarak *Euclidean* yang nantinya akan digunakan pada metode K-NN. Jarak *Euclidean* digunakan untuk melakukan klasifikasi berdasarkan jarak suatu data dengan data yang lainnya. Jarak akan ditentukan berdasarkan nilai K, nilai K sendiri didapatkan secara random agar hasil akhirnya memiliki presetanse yang tinggi.

2.1.10 Confusion Matrix

Confusion Matrix adalah analisis *prediktif* yang menampilkan dan membandingkan nilai aktual atau nilai sebenarnya dengan nilai hasil prediksi model yang didapat digunakan untuk menghasilkan matrik evaluasi seperti *Accuracy* (akurasi), *Precision*, *Recall*, dan *Error rate* (Afifah, 2021). Nilai yang dihasilkan didalam tabel *confusion matrix* ada 4 yaitu, *True Positive* (TP), *False Positive* (FP), *False Negative* (FN), dan *True Negative* (TN).

		Nilai Aktual	
		Positive	Negative
Nilai Prediksi	Positive	TP	FP
	Negative	FN	TN

Keterangan:

1. True Positive (TP): Jumlah data yang bernilai positif dan diprediksi benar sebagai positif.
2. False Positive (FP): Jumlah data yang bernilai negatif tetapi diprediksi sebagai positif.
3. False Negative (FN): Jumlah data yang bernilai positif tetapi diprediksi sebagai negatif.
4. True Negative (TN): Jumlah data yang bernilai negatif dan diprediksi benar sebagai negatif.

a. *Accuracy*

Nilai akurasi didapatkan dari jumlah data bernilai positif yang diprediksi positif dan data data bernilai negatif yang diprediksi negatif dibagi dengan jumlah seluruh dataset. Digunakan rumus pada persamaan 2.7.

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN} \quad (2.7)$$

b. *Precision*

Precision adalah peluang kasus yang diprediksi positif yang pada kenyataannya termasuk kasus kategori positif. Digunakan rumus pada persamaan 2.8.

$$Precision = \frac{TP}{TP+FP} \quad (2.8)$$

c. *Recall*

Recall adalah peluang kasus dengan kategori positif yang dengan tepat prediksi positif. Digunakan rumus pada persamaan 2.9.

$$Recall = \frac{TP}{TP+FN} \quad (2.9)$$

d. *Error Rate*

Error Rate merupakan presentase jumlah *record* data yang diprediksi secara salah oleh algoritma yang digunakan. Didefinisikan rumus pada persamaan 2.10.

$$\text{Error Rate} = \frac{(FN+FP)}{(TP+FN+FP+TN)} \quad (2.10)$$

2.2 Tinjauan Pustaka

Tinjauan pustaka bertujuan untuk mendapatkan bahan perbandingan dan acuan. Selain itu, untuk menghindari adanya anggapan kesamaan dengan yang dilakukan penelitian ini. Maka, dalam tinjauan pustaka ini peneliti mencantumkan hasil – hasil penelitian terdahulu sebagai berikut:

1. Hasil Penelitian Shafiq Nurdin. (2022)

Penelitian Shafiq Nurdin (2022), berjudul “K – Nearest Neighbor dalam Klasifikasi Green Beans Kopi Robusta Berdasarkan Grade Coffee”. Penelitian ini merupakan penelitian yang menggunakan *K – Nearest Neighbor*. Penelitian ini bertujuan untuk menentukan grade kopi dan penyortiran *green beans* yang dimana digunakan sebagai tolak ukur kualitas kopi secara keseluruhan untuk mempermudah menentukan harga yang wajar.

Berdasarkan penelitian yang dilakukan dapat disimpulkan bahwa, dengan menggunakan deteksi tepi *canny* dapat juga membantu pada proses citra digital dengan metode K-NN dalam klasifikasi green beans kopi Robusta. Dalam penelitian ini peneliti menggunakan nilai K = 1,3,5, dan 7, dan nilai K = 5 memiliki tingkat akurasi yang tinggi terhadap data latih yaitu 97,0%. (Nurdin, 2022)

2. Hasil Penelitian Reni Mardisa (2022)

Penelitian Reni Mardisa (2022), berjudul “Klasifikasi Kualitas Fisik Kopi Beras Arabika Menggunakan Pengolahan Citra Dengan Metode K – Nearest Neighbor (K – NN)”. Penelitian ini merupakan penelitian menggunakan metode *K – Nearest Neighbor*. Penelitian ini bertujuan

untuk mengetahui sebuah tingkat akurasi klasifikasi kualitas fisik kopi beras arabika yang berdasarkan citra biji normal, biji pecah, biji coklat, dan biji hitam sebagian.

Berdasarkan penelitian yang dilakukan dapat disimpulkan bahwa dengan menggunakan nilai $K = 5$ tingkat akurasinya yaitu sebesar 78,625% sedangkan menggunakan $K = 3$ dengan nilai rata – rata akurasi yaitu 58.000%. dengan posisi biji kopi telungkup (down) dengan akurasi yaitu 80,25%.

3. Hasil Penelitian Bowo Eko Cahyono (2022)

Penelitian Bowo Eko Cahyono (2022), berjudul “Klasifikasi Jenis Biji Kopi dengan Menggunakan Metode *Gray Level Co-occurrence Matrix* (GLCM)”. Penelitian ini merupakan penelitian yang menggunakan metode GLCM. Penelitian ini bertujuan untuk mengetahui akurasi mengklasifikasikan jenis biji kopi dengan menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM).

Berdasarkan penelitian yang dilakukan dapat disimpulkan bahwa klasifikasi jenis biji kopi dengan menggunakan metode GLCM didapatkan hasil akurasi sebesar 99% untuk klasifikasi tipe kernel atau *powder*, 93% untuk klasifikasi jenis Robusta atau Arabika, dan 56% untuk klasifikasi daerah asal dengan citra data uji sebanyak 80 citra.

4. Hasil Penelitian Dedy Ikhsan (2020)

Penelitian Dedy Ikhsan (2020), berjudul “Metode Klasifikasi Mutu Green Bean Kopi Arabika Lanang dan Biasa menggunakan $K - Nearest Neighbor$ Berdasarkan Bentuk”. Penelitian ini merupakan penelitian yang menggunakan metode $K - Nearest Neighbor$. Penelitian ini bertujuan untuk mengenali mutu *green bean* kopi sesuai dengan Badan Standar Nasional.

Berdasarkan penelitian yang dilakukan dapat disimpulkan bahwa dengan menggunakan nilai $K = 3$ dan 4 ekstraksi citra diperoleh hasil

akurasi sebesar 63,5 %. Fitur yang diekstraks untuk klasifikasi adalah perimeter, rasio kebulatan, rasio kerampingan, luas dan rasio keliling.

5. Hasil Penelitian Nelly Oktavia Adiwijaya (2022)

Penelitian Nelly Oktavia Adiwijaya (2022), berjudul “The Quality of Coffe Bean Classification System Based on Color by Using $K - Nearest Neighbor$ Method”. Penelitian ini merupakan penelitian yang menggunakan metode $K - Nearest Neighbor$. Penelitian ini bertujuan untuk memudahkan para pekerja lapangan untuk melakukan penyortiran biji kopi.

Berdasarkan penelitian yang dilakukan dapat disimpulkan bahwa dengan menggunakan nilai $K = 3$, $K = 5$, $K = 7$. Didapatkan akurasi sebesar 83%.

6. Hasil Penelitian Muhammad Ainnur Rizal (2019)

Penelitian Muhammad Ainnur Rizal (2019), berjudul “Klasifikasi Mutu Biji Kopi Menggunakan Metode $K - Nearest Neighbor$ Berdasarkan Warna dan Tekstur”. Penelitian ini merupakan penelitian yang menggunakan metode $K - Nearest Neighbor$. Penelitian ini bertujuan untuk mengenali sebuah cacat pada biji kopi sesuai dengan standar mutu yang sudah ditetapkan oleh Badan Standar Nasional.

Berdasarkan penelitian yang dilakukan dapat disimpulkan bahwa untuk preprocessing menggunakan thresholding dengan jumlah K terbesar yaitu 5 mendapatkan akurasi sebanyak 46,57%. Sedangkan 65% tanpa *thresholding* dengan jumlah K terbesar 1, 5, dan 7. Fitur yang digunakan untuk perhitungan sebanyak 18, terbagi menjadi dua ekstraksi yaitu statistika warna (rerata *red*, rerata *green*, rerata *blue*, standar deviasi *red*, standar deviasi *green*, standar deviasi *blue*, *skewness red*, *skewness green*, *skewness blue*, *kurtosis red*, *kurtosis green*, *kurtosis blue*) dan tekstur berbasis histogram (intensitas, standar deviasi, *skewness*, energi, entropi, *smoothness*).

7. Hasil Penelitian Zilvanhisna Emka Fitri (2021)

Penelitian Zilvanhisna Emka Fitri (2021), berjudul “Penerapan Fitur Warna dan Tekstur untuk Identifikasi Kerusakan Mutu Biji kopi Arabika (*Coffe Arabica*) di Kabupaten Bondowoso. Penelitian ini merupakan penelitian yang menggunakan metode GLCM. Penelitian ini bertujuan untuk menentukan kualitas biji kopi berdasarkan warna dan teksturnya.

Berdasarkan penelitian yang dilakukan dapat disimpulkan bahwa dengan metode backpropagasi mampu meklasifikasi kerusakan mutu biji kopi arabika dengan tingkat akurasi sbesar 100% dan tingkat akurasi testing sebesar 97,5% pada variasi learning rate yaitu 0,5. Fitur yang digunakan yaitu fitur warna dan fitur tekstur GLCM pada sudut 0° dan 45° .

8. Hasil Penelitian Ilhamsyah (2022)

Penelitian Ilhamsyah (2022), berjudul “Klasifikasi Kualitas Biji Kopi Menggunakan MultilayerPerceptron Berbasis Fitur Warna LCH”. Penelitian ini merupakan penelitian yang menggunakan metode *Naïve Bayes*, *Decision Tree*, *SVM*, *Multilayer Perceptron*. Penelitian ini bertujuan untuk memperbaiki kinerja klasifikasi kualitas biji kopi.

Berdasarkan penelitian yang dilakukan dapat disimpulkan bahwa proses klasifikasi kualitas biji kopi pada penelitian hanya memiliki nilai akurasi sebesar 47% saja. Pada proses klasifikasi biji kopi didalam penelitian ini tidak menggunakan sistem segmentasi dalam menghilangkan *background* pada biji kopi sehingga nilai akurasinya dibawah 80%.

9. Hasil Penelitian Dwi Anindea Putri (2022)

Penelitian Dwi Anindea Putri (2022), berjudul “Klasifikasi Mutu Fisik Biji Kopi Beras Robusta Menggunakan Pengolahan Citra Digital”. Penelitian ini merupakan penelitian yang menggunakan metode *Linear Discriminant Analysis* (LDA) dan *Support Vector*. Penelitian ini bertujuan untuk menentukan mutu kopi beras robusta dengan

menggunakan pengolahan citra digital dan metode *Support Vector Machine* (SVM).

Berdasarkan Penelitian yang dilakukan dapat disimpulkan bahwa dengan menggunakan metode *Support Vector Machine* (SVM) rata rata akurasi mencapai 80,75%. Dengan menggunakan metode *Linear Discriminant analysis* (LDA) untuk mendapatkan fitur yang terbaik dengan menggunakan fitur warna yang terdiri dari G, B, L*a*b*. selanjutnya ada fitur bentuk yang terdiri dari area, perimeter. Ada juga fitur tekstur terdiri dari energi, kontras, korelasi dan homogenitas.

10. Hasil Penelitian Danang Aditya Nugraha (2018)

Penelitian Danang Aditya Nugraha (2018), berjudul “Klasifikasi Tingkat Roasting Biji Kopi Menggunakan Jaringan Syaraf Tiruan Backpropagation Berbasis Citra Digital”. Penelitian ini merupakan penelitian yang menggunakan metode Jaringan Syaraf tiruan dan algoritma *Backpropagation*. Penelitian ini bertujuan untuk menentukan tingkat *roasting* pada biji kopi.

Berdasarkan penelitian ini dapat disimpulkan bahwa pada proses klasifikasi ini terdiri dari tahap training dan testing dan berdasarkan hasilnya didapatkan hasil yang terbaik dengan nilai performa 0,107, dan akurasi pada proses *training* ini mencapai 82,7% sedangkan pada proses testing akurasi mencapai 76,7%.

11. Hasil Penelitian Agyztia Premana (2020)

Penelitian Agyztia Premana (2020), berjudul “Segmentasi K – Means Clustering pada Citra Menggunakan Ekstraksi Fitur warna dan Tekstur”. Penelitian ini merupakan penelitian yang menggunakan metode *K – Means Clustering*. Penelitian ini bertujuan untuk membagi citra digital kedalam beberapa wilayah yang unik berdasarkan piksel yang homogen.

Berdasarkan penelitian ini dapat disimpulkan bahwa dengan penggunaan fitur tekstur meningkat menjadi 17,5%, dan ekstraksi warna keabu-abuan meningkat 16,24%. Sedangkan fitur filter gabor dapat

meningkatkan akurasi segmentasi citra digital 2% pada ekstraksi warna pada ruang warna L^*a^*b meningkat 0.3%.

12. Hasil Penelitian Rizky Rahmadianto (2019)

Penelitian Rizky Rahmadianto (2019), berjudul “Implementasi Pengolahan Citra dan Klasifikasi K-Nearest Neighbor untuk Mendeteksi Kualitas Telur Ayam”. Penelitian ini merupakan penelitian yang menggunakan metode *K-Nearest Neighbor*. Penelitian ini bertujuan untuk mencari klasifikasi data uji dan membedakan telur ayam beromega dengan telur ayam biasa dengan analisa tekstur menggunakan *statistic* orde pertama.

Berdasarkan penelitian ini dapat disimpulkan bahwa dengan metode *K-Nearest Neighbor* berhasil dilakukan, dengan hasil $K = 7$ mencapai akurasi sebesar 86%.

13. Hasil Penelitian Mochamad Aryo Aji Kurniawan (2020)

Penelitian Mochamad Aryo Aji Kurniawan (2020), berjudul “Pemanfaatan Pengolahan Citra dan Klasifikasi K – Nearest neighbor pada Citra Telur Ayam”. Penelitian ini merupakan penelitian yang menggunakan metode *K-Nearest Neighbor*. Penelitian ini bertujuan untuk mengidentifikasi telur ayam *fertile* dan telur ayam *infertile* dengan mengekstraksi ciri warna pada telur.

Berdasarkan penelitian ini dapat disimpulkan bahwa dengan menggunakan metode *K – Nearest Neighbor* dengan percobaan nilai $K = 1$ didapat nilai akurasinya sebesar 100%.

14. Hasil Penelitian Joan Angelina Widians (2019)

Penelitian Joan Angelina Widians (2019), berjudul “Klasifikasi Jenis Bawang Menggunakan Metode KNearest Neighbor Berdasarkan Ekstraksi Fitur Bentuk dan Tekstur”. Penelitian ini merupakan penelitian yang menggunakan metode *K-Nearest Neighbor*. Penelitian ini bertujuan untuk klasifikasi jenis bawang dengan menerapkan metode

K-Nearest Neighbor (K-NN) berdasarkan ekstraksi fitur bentuk dan tekstur.

Berdasarkan penelitian ini dapat disimpulkan bahwa rata-rata akurasi penggunaan nilai K pada 5 kali pengujian yang terbaik pada $K = 7$ dengan akurasi 83.13%, sedangkan akurasi berdasarkan 5 kali pengujian terbaik dan penggunaan K terbaik dihasilkan sebesar 83.56%. Untuk ekstraksi fitur bentuk dengan parameter *metric* dan *eccentricity*, ekstraksi fitur tekstur dengan parameter *contrast*, *correlation*, *energy*, dan *homogeneity* dapat diterapkan dalam klasifikasi jenis bawang dengan akurasi sebesar 83.56%.

