

## KLASIFIKASI CITRA PRODUK CHIFFON CAKE DENGAN METODE K-NEAREST NEIGHBORS DAN GREY LEVEL CO-OCCURRENCE MATRIX UNTUK QUALITY CONTROL

Olwin Kirab Novaldy\*<sup>1</sup>, Arief Hermawan<sup>2</sup>, Donny Avianto<sup>3</sup>

<sup>1,2,3</sup>Universitas Teknologi Yogyakarta, Yogyakarta

Email: <sup>1</sup>olwin.6230211011@student.uty.ac.id, <sup>2</sup>ariefdb@staff.uty.ac.id, <sup>3</sup>donny@uty.ac.id

\*Penulis Korespondensi

(Naskah masuk: 14 Maret 2025, diterima untuk diterbitkan: 27 Agustus 2025)

### Abstrak

*Chiffon cake* adalah salah satu kue yang populer, dan kepuasan pelanggan sangat dipengaruhi oleh kualitas produk *chiffon cake*. Oleh karena itu, diperlukan sistem pengendalian kualitas yang efektif untuk mendeteksi *chiffon cake* yang cacat. Dalam penelitian ini, digunakan metode K-Nearest Neighbors (KNN) sebagai alat klasifikasi untuk mendeteksi produk *chiffon cake* yang cacat. Tujuan utama penelitian ini adalah membuat model sistem pengendalian kualitas yang dapat mengklasifikasikan *chiffon cake* secara otomatis ke dalam dua kategori: "lolos" dan "cacat." Sistem ini diharapkan dapat meningkatkan efisiensi proses produksi dan mengurangi kemungkinan produk cacat sampai ke tangan konsumen. Studi ini menggunakan KNN dan *Gray Level Co-Occurrence Matrix* (GLCM). Metode klasifikasi KNN bergantung pada pemilihan tetangga terdekat data untuk menentukan kategori kelasnya, sedangkan GLCM adalah teknik ekstraksi fitur yang digunakan untuk mengukur tekstur gambar dengan menganalisis hubungan antara dua piksel dalam orde kedua. Untuk melatih model KNN, studi ini menggunakan *dataset* yang diambil sendiri melalui pemotretan produk chiffon, kemudian diberi label "lolos" dan "cacat." Setelah melatih model, penulis melakukan pengujian dengan data uji untuk mengevaluasi kinerjanya. Hasil penelitian menunjukkan bahwa penerapan KNN memungkinkan pengklasifikasian *chiffon cake* dengan akurasi 90,4%. Validasi lebih lanjut dengan *dataset* yang lebih besar dan beragam diperlukan untuk memastikan bahwa model tetap *robust* dan dapat diandalkan dalam berbagai kondisi produksi.

**Kata kunci:** klasifikasi, KNN, GLCM, *chiffon cake*, quality control

### CLASSIFICATION OF CHIFFON CAKE IMAGES USING K-NEAREST NEIGHBORS AND GREY LEVEL CO-OCCURRENCE MATRIX METHOD FOR QUALITY CONTROL

#### Abstract

*Chiffon cake* is one of the popular types of cake, and customer satisfaction is greatly influenced by the quality of the *chiffon cake*. Therefore, an effective quality control system is necessary to detect defective *chiffon cakes*. In this research, the K-Nearest Neighbors (KNN) method is used as a classification tool to detect defective *chiffon cakes*. The main objective of this study is to create a quality control system model that can automatically classify *chiffon cakes* into two categories: "Pass" and "Not Pass." This model is expected to increase production efficiency and reduce the risk of defective products reaching consumers. This study uses KNN and the Gray Level Co-Occurrence Matrix (GLCM). The KNN classification method determines the class category by selecting the data's nearest neighbors, while GLCM is a feature extraction method that measures image texture by analyzing the correlation between two pixels in the second order. To train the KNN model, this study used a dataset of manually photographed products, labeled as "lolos" and "cacat" After training the model, this study evaluates its performance using test data. The research results showed that the KNN application can classify *chiffon cakes* with an accuracy of 90.4%. Further validation with larger and more diverse datasets is recommended to enhance the model's robustness and applicability.

**Keywords:** classification, KNN, GLCM, *chiffon cake*, quality control

## 1. PENDAHULUAN

Industri pangan terus berkembang seiring dengan tingginya permintaan konsumen akan ragam produk (Novelina, 2023). Dalam kerangka ini, *chiffon*

*cake* menjadi salah satu produk roti yang sangat diminati karena teksturnya yang lembut dan rasa yang lezat. Kualitas produk *chiffon cake* menjadi aspek kritis yang harus diperhatikan oleh produsen untuk

mempertahankan daya saingnya di pasar yang bersaing. Salah satu tantangan utama dalam memastikan kualitas produk adalah pendeteksian dini terhadap produk cacat. Oleh karena itu, penelitian ini dimulai dengan tujuan mengembangkan sistem kontrol kualitas yang efektif menggunakan Metode K-Nearest Neighbors (KNN) (Ren, 2021) untuk mengklasifikasikan produk *chiffon cake* yang baik dan cacat.

Dalam beberapa dekade terakhir, metode machine learning (ML) dipilih karena dapat memprediksi nilai variabel kualitatif maupun kuantitatif yang sangat kompleks (Luis, 2023), termasuk KNN, telah menjadi alat yang mumpuni untuk menangani permasalahan klasifikasi dalam berbagai bidang (Huang, 2023). Penggunaan KNN dalam industri pangan memberikan peluang untuk meningkatkan efisiensi *Quality Control* secara signifikan. KNN beroperasi berdasarkan konsep bahwa data yang serupa cenderung berada dalam kelompok yang sama. Dengan menerapkan prinsip ini pada atribut-atribut kualitas *chiffon cake*, diharapkan kita dapat mengidentifikasi secara cepat dan akurat produk-produk yang tidak memenuhi standar.

Penggunaan KNN dan *Gray Level Co-Occurrence Matrix* (GLCM) dalam penelitian ini menjadi pilihan yang tepat untuk secara otomatis mengklasifikasikan produk *chiffon cake* menjadi dua kategori, "lolos" dan "cacat". GLCM dapat menjadi pilihan yang baik karena kemampuannya untuk secara efisien menggambarkan hubungan tekstur antar piksel (Mamun, 2024), KNN efektif dalam memanfaatkan pola-pola kemiringan bentuk *chiffon cake* yang kompleks dari citra produk, dan dengan menggunakan GLCM, penulis dapat mengekstraksi fitur tekstur yang kompleks. Kombinasi kedua metode ini memungkinkan analisis yang lebih holistik terhadap citra produk, mengambil informasi kedekatan nilai fitur menggunakan KNN dan hubungan intensitas piksel GLCM untuk membedakan antara produk lolos dan cacat. Hasilnya diharapkan dapat memberikan sistem kontrol kualitas yang akurat, efisien, dan dapat diandalkan, membantu produsen dalam meningkatkan daya saing di pasar dengan menghasilkan produk *chiffon cake* yang berkualitas tinggi secara konsisten.

Tujuan dari penelitian ini adalah mengembangkan sistem kontrol kualitas terhadap kemiringan permukaan atas *chiffon cake* yang efektif menggunakan KNN untuk mengklasifikasikan produk *chiffon cake* yang baik dan cacat. Selain itu, untuk mengatasi tingginya biaya tenaga kerja dalam kontrol kualitas, penelitian ini juga bertujuan meningkatkan efisiensi dengan mengimplementasikan sistem *Quality Control* (QC) otomatis. Sistem ini dirancang untuk mengklasifikasikan produk *chiffon cake* yang lolos QC atau cacat tanpa perlu campur tangan langsung dari tenaga kerja. Dengan demikian, tidak hanya meningkatkan akurasi kontrol kualitas, tetapi juga

mengurangi biaya operasional yang terkait dengan pekerjaan manual dalam proses QC.

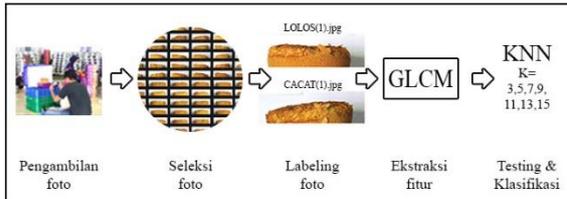
## 2. METODE PENELITIAN

Penelitian ini melibatkan beberapa tahap yang terstruktur, dimulai dari pengambilan foto dan seleksi untuk memastikan data yang relevan. Foto-foto yang dipilih kemudian diberi label lolos dan cacat sebelum dilakukan ekstraksi fitur GLCM. Langkah terakhir melibatkan proses klasifikasi menggunakan metode KNN, di mana informasi fitur yang diekstraksi digunakan untuk mengelompokkan atau mengklasifikasikan data. Dengan pendekatan ini, penelitian ini bertujuan untuk mengoptimalkan pemahaman dan analisis data visual dengan memanfaatkan teknik-teknik tersebut.

### 2.1. Penelitian yang terkait

Studi pertama tentang teknologi pengolahan citra dan pembelajaran mesin, khususnya *Convolutional Neural Networks* (CNN), telah menunjukkan potensi besar dalam aplikasi klasifikasi visual untuk makanan tradisional. Salah satu pendekatan yang digunakan adalah *Bag of Visual Words* (BoW) yang dikombinasikan dengan *Support Vector Machine* (SVM), yang dapat mengelompokkan tekstur makanan dengan tingkat akurasi yang signifikan. Selain itu juga diaplikasikan bersamaan dengan sensor magnetik untuk mendukung proses klasifikasi makanan berbasis tekstur. Dalam perkembangan terkini, CNN menjadi pilihan utama dalam mengenali makanan tradisional, termasuk berbagai jenis kue khas Indonesia seperti *klepon* dan *lapis*, dengan hasil akurasi yang bervariasi sesuai dengan dataset yang digunakan. Meski begitu, penelitian lebih lanjut masih dibutuhkan untuk meningkatkan akurasi dan efisiensi, terutama dalam menangani keragaman tekstur dan bentuk makanan tradisional seperti kue khas Indonesia (Karlita, 2022).

Pada studi kedua, penelitian tersebut menjelaskan penggunaan teknik deep learning, khususnya *Convolutional Neural Network* (CNN), untuk mengidentifikasi jenis kue tradisional Indonesia dari gambar. *Dataset* sebanyak 1676 gambar kue tradisional Indonesia digunakan, dengan proses meliputi pra-pengolahan data, visualisasi *dataset*, teknik pemodelan, dan evaluasi performa. Hasil penelitian menunjukkan bahwa model CNN mencapai akurasi sekitar 65% dalam mengklasifikasi gambar kue tradisional Indonesia, menunjukkan potensi teknologi pengolahan citra dan pembelajaran mesin dalam memahami dan mengklasifikasi aspek budaya kuliner Indonesia (Kurnia, 2021).



Gambar 1. Metode penelitian.

Studi terakhir ini memanfaatkan teknologi pengolahan citra dan pembelajaran mesin untuk mengenali kue tradisional dengan menggunakan fitur warna *Hue Saturation Value* (HSV) dan tekstur *Local Binary Pattern* (LBP), yang diklasifikasikan melalui *K-Nearest Neighbor* (KNN). Studi sebelumnya menunjukkan bahwa penggabungan fitur HSV dan LBP menghasilkan akurasi terbaik sebesar 75%, dibandingkan penggunaan fitur tunggal. Dalam pengujian, data latih dan data uji diolah melalui *pre-processing* seperti *resize* citra, konversi warna, dan segmentasi. Akurasi klasifikasi juga diuji pada berbagai nilai  $k$ , menunjukkan performa tertinggi pada  $k=1$  dengan tingkat akurasi mencapai 75%. Meski demikian, penelitian ini menunjukkan bahwa semakin besar nilai  $k$ , akurasi cenderung menurun akibat tingginya ketergantungan pada data tetangga terdekat yang bertambah. Kombinasi fitur warna dan tekstur dalam ruang warna HSV berhasil memberikan informasi visual yang lebih lengkap, meskipun evaluasi menunjukkan adanya tantangan dalam membedakan makanan dengan tekstur atau warna yang mirip. Temuan ini menggarisbawahi pentingnya peningkatan variasi data latih dan eksplorasi fitur tambahan untuk meningkatkan akurasi dalam klasifikasi makanan tradisional (Waluyo, 2021).

## 2.2. Grey-Level Co-occurrence Matrix (GLCM)

Sebuah metode pengambilan ciri yang diterapkan untuk mengukur pola tekstur dalam gambar dengan memperhitungkan keterkaitan antara dua elemen piksel dalam order kedua. (Nyasulu, 2023). Dalam perhitungan ini, GLCM memperhatikan pasangan dua piksel dalam citra asli. Secara kontras, orde pertama melibatkan perhitungan statistik berdasarkan nilai piksel citra asli tanpa mempertimbangkan piksel tetangga. Dalam metode GLCM, langkah awalnya adalah membentuk matriks *co-occurrence* data citra (Rachmad, 2023), dan selanjutnya menetapkan ciri khusus sebagai fungsi dari relasi piksel dalam matriks tersebut. Proses ini melibatkan ekstraksi informasi penting dari hubungan antar elemen citra yang direpresentasikan oleh matriks *co-occurrence*, yang kemudian digunakan untuk menentukan fitur-fitur karakteristik yang menggambarkan sifat-sifat citra.

*Co-occurrence* mengindikasikan kejadian bersama, di mana jumlah kejadian satu tingkat nilai piksel berdekatan dengan satu tingkat nilai piksel lainnya pada jarak ( $d$ ) dan sudut orientasi tertentu ( $\theta$ ). Ini menunjukkan seberapa sering dua piksel dengan intensitas nilai tertentu muncul bersamaan dalam

suatu citra dengan mempertimbangkan jarak dan arah tertentu (Nyasulu, 2023).

Dalam GLCM,  $N$  adalah jumlah tingkat keabuan yang dapat diambil oleh piksel dalam citra (misalnya, 0-255). Variabel  $i$  dan  $j$  merujuk pada tingkat keabuan individu. Melalui iterasi  $i$  dan  $j$ , semua pasangan tingkat keabuan dalam citra dijelajahi. Rumus energi menghitung kuadrat probabilitas kemunculan setiap pasangan, yang dijumlahkan untuk menghasilkan nilai energi yang mencerminkan keseragaman distribusi intensitas piksel.

Dalam konteks penelitian ini, fitur-fitur yang akan dievaluasi mencakup *energi*, *homogenitas*, dan *korelasi*, sebagaimana dijelaskan melalui Persamaan (1), Persamaan (2), dan Persamaan (3). Penelitian ini akan memanfaatkan persamaan-persamaan tersebut untuk mendapatkan nilai-nilai yang mencerminkan karakteristik citra dalam aspek-aspek tersebut, sebagai bagian dari analisis yang dilakukan.

$$\text{Energy} = \sum_{i=1}^N \sum_{j=1}^N P(i, j)^2 \quad (1)$$

$$\text{Homogenitas} = \sum_{i=1}^N \sum_{j=1}^N \frac{P(i, j)}{1+|i-j|} \quad (2)$$

$$\text{Korelasi} = \frac{\sum_{i=1}^N \sum_{j=1}^N (i-\mu)(j-\nu)P(i, j)}{\sigma_i \sigma_j} \quad (3)$$

Istilah *co-occurrence* dalam GLCM merujuk pada kejadian bersama, yang mencerminkan frekuensi kemunculan banyaknya pasangan nilai piksel yang bertetangga pada satu level piksel. Faktor-faktor seperti jarak ( $d$ ) dan orientasi sudut ( $\Theta$ ) memainkan peran penting dalam pengukuran *co-occurrence*. Jarak direpresentasikan dalam satuan piksel, sementara orientasi diukur dalam derajat. Orientasi ini dibentuk oleh empat arah sudut dengan interval 45 derajat, yaitu 0 derajat, 45 derajat, 90 derajat, dan 135 derajat. Jarak antar piksel ditentukan sebesar 1 piksel untuk memastikan representasi yang tepat. Keempat arah sudut ini memberikan informasi yang komprehensif mengenai hubungan antara piksel dalam citra.

## 2.3. Metode Pengumpulan Data

### 2.3.1. Observasi

Metode observasi adalah metode pengumpulan data yang melibatkan pemantauan langsung terhadap objek atau kejadian yang menjadi fokus penelitian. Dalam konteks ini, peneliti secara aktif melakukan pengamatan terhadap proses produksi *chiffon cake*, serta mengidentifikasi variabel-variabel kunci yang relevan dengan kontrol kualitas (Abdullah, 2024).



Gambar 2. Contoh foto *chiffon cake* cacat (atas) dan lolos (bawah).



Gambar 3. Proses pengambilan citra *chiffon cake*.

Observasi memberikan keuntungan dalam mendapatkan data langsung dari lapangan, memungkinkan peneliti untuk merinci aspek-aspek tertentu yang mungkin tidak dapat diakses melalui metode lainnya.

### 2.3.2. Pengambilan Citra

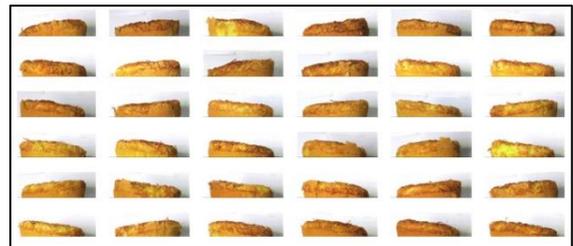
Pengambilan foto digunakan sebagai metode dokumentasi visual untuk merekam kondisi produk *chiffon cake*. Dengan penggunaan kamera, peneliti dapat mengabadikan gambar-gambar yang dapat digunakan fungsi sebagai referensi dalam analisis dan evaluasi kualitas produk. Foto-foto ini dapat membantu dalam mendokumentasikan secara visual perbedaan-perbedaan kemiringan atau karakteristik lainnya pada produk, memperkaya *dataset* penelitian.

### 2.3.3. Studi Pustaka

Tinjauan literatur dilakukan dengan menghimpun informasi dari sumber-sumber tertulis yang relevan dengan subjek penelitian, seperti jurnal ilmiah, buku, dan literatur terkait. Pendekatan ini membantu peneliti memahami konsep-konsep dasar, teori-teori terkini, dan praktik terbaik dalam kontrol kualitas produk *chiffon cake*. Studi pustaka juga dapat memberikan dasar pengetahuan yang kuat untuk merancang dan melaksanakan metode kontrol kualitas yang efektif.



Gambar 4. *Dataset* citra *chiffon cake* lolos.



Gambar 5. *Dataset* citra *chiffon cake* cacat.

## 2.4. Alat Pengambil Citra

Pada tahap ini, alat pengambil citra yang digunakan dalam penelitian adalah berupa kamera ponsel dengan berikut:

Tabel 1. Spesifikasi device yang digunakan.

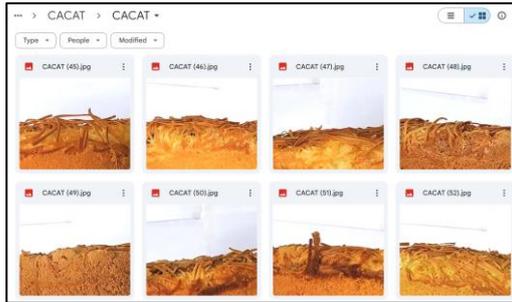
Parameter	Value & Spesifikasi
Camera	Xiaomi
Camera Model	M2007J20CG
F-stop	F1/9
Exposure Time	1/30 Sec
ISO	800
Focal length	5mm
Flash Mode	No Flash

## 2.5. Proses Seleksi *Dataset*

*Dataset* dengan proses manual dengan wawancara (Supriyadi, 2023) tenaga kerja QC untuk membantu mengklasifikasikan foto berdasarkan lolos atau cacat yang selanjutnya dipilih untuk penelitian. Proses seleksi *dataset* melibatkan pemilihan citra produk *chiffon cake* yang mencakup beberapa kriteria termasuk kemiringan, warna, dan tekstur pada produk. Proses ini bertujuan untuk memastikan representasi yang baik dari berbagai kondisi produk *chiffon cake* agar hasil penelitian dapat lebih akurat dan dapat diaplikasikan.

## 2.6. *Dataset* yang digunakan

*Dataset* yang digunakan terdiri dari 104 citra *chiffon cake*, di mana masing-masing terdiri dari 40 citra *chiffon cake* cacat dan 40 citra *chiffon cake* lolos. Selain itu, terdapat 12 citra untuk pengujian cacat dan 12 citra untuk pengujian yang lolos. *Dataset* dibagi ke dalam folder di *Google Drive* sesuai dengan nama label "cacat" atau "lolos".



Gambar 6. Dataset di google drive chiffon cake yang dilabeli cacat.



Gambar 7. Dataset di google drive chiffon cake yang dilabeli lolos.

## 2.7. Labeling Foto

Pada fase ini, setiap foto citra produk *chiffon cake* dalam dataset diberi label atau kategori sesuai dengan karakteristik yang menjadi fokus penelitian, seperti kemiringan atau kualitas umum produk. Label ini digunakan sebagai *ground truth* selama proses pelatihan dan pengujian model KNN. Dalam konteks klasifikasi, setiap foto dilabeli sesuai kondisinya, apakah termasuk dalam kategori "cacat" atau "lolos". Proses pelabelan dapat dilakukan secara manual oleh peneliti atau dengan bantuan algoritma pemrosesan citra yang mampu mengenali dan memberikan label berdasarkan fitur-fitur tertentu. Konsistensi dalam proses pelabelan sangat penting untuk memastikan keakuratan dan keandalan data yang digunakan dalam pelatihan dan pengujian model KNN, serta untuk mengidentifikasi perubahan kondisi produk pada setiap foto.

## 2.8. Ekstraksi Fitur

Proses ekstraksi fitur dengan metode GLCM menjadi tahap esensial dalam penelitian ini. Setiap citra produk *chiffon cake* yang telah diberi label kategori "cacat" atau "lolos" diproses menggunakan GLCM untuk mengekstraksi informasi tekstural orde kedua. Matriks ko-occurrence dihasilkan dari analisis hubungan antara intensitas piksel dalam berbagai arah dan jarak. Dari matriks ini, berbagai fitur seperti *energi*, *homogenitas*, dan *korelasi* diekstraksi untuk setiap citra.

```
#ekstraksi fitur
def extract_glcms(image):
    distances = [1]
```

```
angles = [0, np.pi/4, np.pi/2,
3*np.pi/4]
properties = ['energy', 'homogeneity',
'correlation']
# convert ke array
img_array = np.array(image)
# hitung glcm
glcm = greycomatrix(img_array,
distances=distances, angles=angles,
symmetric=True, normed=True)
# ekstrak properti
features = []
for prop in properties:
    propval = greycoprops(glcm,
prop).ravel()
    features.extend(propval)
return features
```

Tujuan utama dari ekstraksi fitur ini adalah untuk menghasilkan representasi numerik yang menggambarkan karakteristik tekstural dari produk *chiffon cake*. Hasil ekstraksi fitur ini akan berfungsi dalam pelatihan dan pengujian model KNN, yang akan digunakan untuk mengklasifikasikan produk berdasarkan kondisinya, baik itu cacat atau memenuhi standar kualitas.

Tabel 3. Contoh 5 baris value hasil ekstraksi (Cacat)

Korelasi	Homegenitas	Energi
7.074173441	0.386725918	0.166691005
8.866737982	0.289169987	0.057640852
7.466385999	0.503703843	0.395572335
6.397253684	0.534990574	0.427371725
2.900272531	0.379949638	0.037835567

Tabel 3. Contoh 5 baris value hasil ekstraksi (Lolos)

Korelasi	Homegenitas	Energi
9.33060545	0.272000793	0.087575733
9.624295295	0.432830365	0.335154606
8.710908813	0.426431006	0.322152803
3.377845702	0.316260944	0.031527177
8.822826427	0.351053666	0.223064802

## 2.9. Penentuan Nilai K

Penentuan nilai K dalam metode KNN merupakan tahap penting dalam proses klasifikasi. Nilai K menentukan jumlah tetangga terdekat yang akan dipertimbangkan dalam menentukan kelas suatu data (Li, 2024). Penelitian ini akan menjelaskan metode atau pertimbangan yang digunakan untuk menentukan nilai K yang optimal. Nilai K dalam penelitian ini uji coba dilakukan  $K = 3, 5, 7, 9, 11, 13, \text{ dan } 15$ , selain itu uji coba eksperimental dengan variasi nilai K atau menggunakan metode pemilihan otomatis yang dapat meminimalkan kesalahan klasifikasi pada *dataset* tertentu. Penentuan nilai K yang tepat merupakan faktor kritis untuk memastikan keakuratan model KNN dalam mengklasifikasikan citra produk *chiffon cake*.

## 2.10. Klasifikasi menggunakan KNN

Dalam penelitian ini, dilakukan ekstraksi fitur menggunakan metode GLCM pada citra *chiffon cake*. Fungsi `extract_glcms` menghitung GLCM untuk setiap citra dengan menggunakan jarak dan sudut tertentu. Properti yang digunakan dari GLCM adalah *'energy'*, *'homogeneity'*, dan *'correlation'* diekstraksi untuk masing-masing citra. Fitur-fitur ini kemudian digunakan sebagai input untuk melatih dan menguji model klasifikasi.

*Dataset* terdiri dari dua kategori, yaitu cacat dan lolos, di mana setiap kategori memiliki kumpulan citra yang sesuai. Fitur GLCM diekstraksi dari setiap citra dan dicatat ke dalam *array x*, sementara label kategori ('1' untuk 'CACAT' dan '0' untuk 'LOLOS') dicatat dalam *array y*. Selanjutnya, data dibagi menjadi dua set, yaitu data latih dan data uji, dengan proporsi 80:20 (Bichri, 2024). Kemudian, dilakukan penggunaan model KNN untuk mengklasifikasikan citra. Sejumlah nilai K (jumlah tetangga terdekat) ditentukan, yaitu [3, 5, 7, 9, 11, 13, 15]. Model KNN dilatih menggunakan data latih, dan kemudian diuji menggunakan data uji.

```
X = []
y = [] # 1 untuk 'CACAT', 0 untuk 'LOLOS'
for cacat_file in cacat_files:
    img = Image.open(os.path.join(cacat_dir,
    cacat_file)).convert("L")
    features = extract_glcms(img)
    X.append(features)
    y.append(1)
for lolos_file in lolos_files:
    img = Image.open(os.path.join(lolos_dir,
    lolos_file)).convert("L")
    features = extract_glcms(img)
    X.append(features)
    y.append(0)

X_train, X_test, y_train, y_test =
train_test_split(X, y, test_size=0.2,
random_state=42)
nilai_k = [3, 5, 7, 9, 11, 13, 15]
results_df = pd.DataFrame(columns=['K',
'Akurasi', 'Precision', 'Recall', 'F1-
Score'])
for k in nilai_k:
    knn = KNeighborsClassifier(n_neighbors=k)
    knn.fit(X_train, y_train)
    y_pred = knn.predict(X_test)
    accuracy = accuracy_score(y_test, y_pred)
    report = classification_report(y_test,
y_pred, target_names=['Lolos', 'Cacat'],
output_dict=True)
    results_df = results_df.append({
        'K': k,
        'Akurasi': accuracy,
        'Precision':
report['Lolos']['precision'],
'Recall': report['Lolos']['recall'],
'F1-Score': report['Lolos']['f1-
score']
    }, ignore_index=True)
print(results_df)
```

## 3. HASIL & PEMBAHASAN

Penelitian ini menunjukkan hasil positif dalam penerapan metode KNN, dengan akurasi tertinggi dicapai pada nilai K=3 dalam proses klasifikasi citra produk *chiffon cake*. Dari hasil pengujian, diperoleh tingkat akurasi sebesar 90,4%, yang mengindikasikan kemampuan model dalam mengenali dan mengategorikan citra produk sebagai "lolos" atau "cacat" dengan baik. Keberhasilan ini menjadi bukti bahwa penggunaan metode KNN dengan nilai K yang tepat dapat memberikan solusi efektif untuk mengatasi permasalahan kontrol kualitas pada produk *chiffon cake*.

Selain akurasi keseluruhan sebesar 90,4% pada nilai K=3, evaluasi model mencakup metrik *precision*, *recall*, dan *f1-score* untuk masing-masing kategori. Pada kategori "lolos", model menunjukkan nilai *precision* dan *recall* sebesar 90%, sementara pada kategori "cacat", *precision* dan *recall* juga mencapai 90%. Hasil ini menunjukkan bahwa model tidak hanya akurat tetapi juga seimbang dalam mengklasifikasikan kedua kategori. Metrik *f1-score* sebesar 0,900 pada nilai K=3 mengonfirmasi performa keseluruhan model yang memadai dalam mengidentifikasi kualitas produk.

Untuk memberikan gambaran yang lebih menyeluruh, hasil pengujian model dengan variasi nilai K ditampilkan pada Tabel 4. Pada nilai K=3, model menunjukkan performa terbaik di semua metrik, termasuk akurasi, *precision*, *recall*, dan *f1-score*. Namun, performa model mulai menurun seiring dengan peningkatan nilai K, seperti terlihat pada K=11, di mana akurasi turun menjadi 66,67% dan *f1-score* menjadi 0,631. Hal ini mengindikasikan bahwa jumlah tetangga terdekat yang lebih besar cenderung menyebabkan model kehilangan kemampuan untuk menangkap pola-pola spesifik dalam dataset.

Tabel 4. Hasil training model dengan variasi nilai K

Nilai K	Akurasi	Precision	Recall	F-1Score
3	0.904762	0.900000	0.9	0.900000
5	0.857143	0.888889	0.8	0.842105
7	0.857143	0.888889	0.8	0.842105
9	0.761905	0.777778	0.7	0.736842
11	0.666667	0.666667	0.6	0.631579
13	0.714286	0.750000	0.6	0.666667
15	0.666667	0.666667	0.6	0.631579

Meskipun model menunjukkan hasil yang memuaskan pada dataset saat ini, generalisasi model terhadap dataset yang lebih besar dan lebih bervariasi tetap menjadi tantangan. Pada dataset yang lebih kompleks, variasi dalam ukuran, bentuk, dan kondisi pencahayaan citra dapat memengaruhi performa model. Oleh karena itu, validasi lebih lanjut dengan dataset yang lebih luas diperlukan untuk memastikan bahwa model tetap robust dalam berbagai kondisi produksi.

Hasil penelitian ini memberikan dasar yang kuat untuk pengembangan sistem kontrol kualitas berbasis machine learning. Namun, disarankan untuk mengeksplorasi metode pembelajaran mesin lainnya guna menangani dataset yang lebih besar dan bervariasi. Pengujian dalam kondisi pencahayaan yang berbeda juga dapat memberikan wawasan tambahan tentang ketahanan model. Akhirnya, integrasi model ini ke dalam proses produksi nyata dapat menjadi langkah penting untuk mengevaluasi efisiensi dan penerapannya dalam skala industri.

#### 4. KESIMPULAN & SARAN

##### 4.1. Kesimpulan

Penelitian ini menunjukkan bahwa metode KNN dengan nilai  $K=3$  memberikan akurasi tertinggi dibandingkan nilai  $K$  lainnya yang digunakan untuk mengklasifikasikan gambar produk *chiffon cake* berdasarkan kondisinya. Hasil pengujian menunjukkan tingkat akurasi sebesar 90,4% pada nilai  $K=3$ , yang mengindikasikan keberhasilan model dalam membedakan antara *chiffon cake* yang memenuhi standar kualitas dan yang tidak.

Hasil evaluasi model menggunakan metrik *precision*, *recall*, dan *f1-score* juga menunjukkan kinerja yang baik di kedua kategori, dengan hasil mencapai 90,4%. Dengan memanfaatkan teknologi pengolahan gambar dan *machine learning* (ML), penelitian ini memberikan kontribusi signifikan terhadap kemajuan dalam kontrol kualitas produk *chiffon cake*. Selain itu, metode ekstraksi fitur GLCM terbukti efektif dalam menggambarkan karakteristik tekstural, khususnya kemiringan citra *chiffon cake*.

Penerapan KNN pada tahap klasifikasi dalam studi ini menghasilkan hasil yang objektif. Model yang dikembangkan memiliki potensi besar untuk diintegrasikan ke dalam sistem kontrol kualitas otomatis untuk mendeteksi kualitas produk *chiffon cake* secara *real-time*. Namun, validasi lebih lanjut dengan dataset yang lebih luas dan variasi produk yang lebih kompleks diperlukan untuk memastikan konsistensi performa model dalam berbagai kondisi produksi

##### 4.2. Saran

Untuk pengembangan lebih lanjut, disarankan untuk mengeksplorasi metode pembelajaran mesin lainnya, guna menangani *dataset* yang lebih besar dan variasi produk yang lebih kompleks. Selain itu, pengujian pada berbagai kondisi pencahayaan dan sudut pandang citra dapat dilakukan untuk meningkatkan ketahanan model terhadap variasi lingkungan. Penelitian juga dapat difokuskan pada integrasi sistem ini ke dalam proses produksi nyata untuk mengukur efisiensi operasional dan penerimaannya di lingkungan industri. Melibatkan pakar kontrol kualitas dalam proses validasi juga

dapat memastikan bahwa sistem yang dikembangkan memenuhi standar industri yang berlaku.

#### DAFTAR PUSTAKA

- ABDULLAH, A.A., HASSAN, M.M. AND MUSTAFA, Y.T., 2024. Leveraging Bayesian deep learning and ensemble methods for uncertainty quantification in image classification: A ranking-based approach.
- BICHRI, H., CHERGUI, A. AND HAIN, M., 2024. Investigating the Impact of Train / Test Split Ratio on the Performance of Pre-Trained Models with Custom Datasets. [online] IJACSA) International Journal of Advanced Computer Science and Applications, Available at: <www.ijacsa.thesai.org>.
- HUANG, A., XU, R., CHEN, Y. AND GUO, M., 2023. Research on multi-label user classification of social media based on ML-KNN algorithm. Technological Forecasting & Social Change, 188, p.122271.
- KARLITA, T., AFIF, B.P. AND PRASETYANINGRUM, I., 2022. Indonesian Traditional Cake Classification Using Convolutional Neural Networks. International Conference on Applied Science and Technology on Social Science, pp.924–929.
- KURNIA, D.A., SETIAWAN, A., AMALIA, D.R., ARIFIN, R.W. AND SETIYADI, D., 2021. Image Processing Identification for Indonesian Cake Cuisine using CNN Classification Technique. In: Journal of Physics: Conference Series. IOP Publishing Ltd.
- LI, J., ZHANG, J., ZHANG, J. AND ZHANG, S., 2024. Quantum KNN Classification With K Value Selection and Neighbor Selection. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 43(5), pp.1332–1345.
- LUIS, L., CALVO PASCUAL, L., CASTRO CORREDOR, D., CÉSAR, E. AND MERCHÁN, G., 2023. Machine learning classification of vitamin D levels in spondyloarthritis patients.
- MAMUN, A. AL, UDDIN, M.A., KIM, T. AND BAPPY, M.M., 2024. Analysis of GLCM-feature-based dimensionality reduction and feature extraction methods for classifying fabric design patterns by using video data. Research Square, pp.1–33.
- NOVELINA, AISMAN AND RAMADHANI, A.S., 2023. The Comparative Effect of MOCAF (Modified Cassava Flour) and Corn (Zea mays L.) Flour on the Characteristics of Chiffon Cake. IOP Conference Series: Earth and Environmental Science, 1182(1), p.012052.
- NYASULU, C., DIATTARA, A., TRAORE, A., BA, C., DIEDHIOU, P.M., SY, Y., RAKI, H. AND PELUFFO-ORDÓÑEZ, D.H., 2023. A comparative study of Machine Learning-based

- classification of Tomato fungal diseases: Application of GLCM texture features. *Heliyon*, 9(11).
- RACHMAD, A., HAPSARI, R.K., SETIAWAN, W., INDRIYANI, T., ROCHMAN, E.M.S. AND SATOTO, B.D., 2023. Classification of Tobacco Leaf Quality Using Feature Extraction of Gray Level Co-occurrence Matrix (GLCM) and K-Nearest Neighbor (K-NN). In: *Proceedings of the 1st International Conference on Neural Networks and Machine Learning*. pp.30–38.
- REN, Z., TANG, Y. AND ZHANG, W., 2021. Quality-related fault diagnosis based on k-nearest neighbor rule for non-linear industrial processes. *International Journal of Distributed Sensor Networks*, 17(11).
- SUPRIYADI, A., 2023. Perbandingan Algoritma Naive Bayes dan Decision Tree(C4.5) dalam Klasifikasi Dosen Berprestasi. *Generation Journal*, .
- WALUYO, G.B., SARI, Y.A. AND RAHAYUDI, B., 2021. Pengenalan Citra Makanan Kue Tradisional menggunakan Ekstraksi Fitur HSV Color Moment dan Local Binary Pattern dengan K-Nearest Neighbour. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer (JTIK)*, 5(12), pp.5641–5649.

*Halaman ini sengaja dikosongkan*