

Pengujian Model Klasifikasi Kesegaran Daging Sapi berbasis GLCM (*Gray Level Co-occurrence Matrix*) dan Algoritma Machine Learning

MUHAMAD IKBAL RAMDANI, HANNY HIKMAYANTI HANDAYANI, YUSUF EKA WICAKSANA, TOHIRIN AL-MUDZAKIR

Program Studi Teknik Informatika, Universitas Buana Perjuangan Karawang
Email: if21.muhamadramdani@mhs.ubpkarawang.ac.id

Received 16 April 2025 | Revised 16 Mei 2025 | Accepted 23 Mei 2025

ABSTRAK

Daging sapi merupakan sumber hewani yang penting, namun konsumsi masyarakat Indonesia masih rendah dan harga yang terus meningkat mendorong adanya praktik curang, seperti mencampur daging segar dan tidak segar. Hal ini berdampak pada kesehatan karena daging sapi tidak segar mengandung bakteri berbahaya. Penelitian ini dilakukan untuk mengklasifikasikan kesegaran daging sapi dengan memanfaatkan metode ekstraksi fitur Gray Level Co-occurrence Matrix (GLCM) dan algoritma Random Forest serta Decision Tree. Penelitian ini menggunakan 400 data citra augmentasi dan dibagi menjadi 238 data latih dan 160 data uji atau dengan rasio 60:40. Hasil penelitian ini menunjukkan Accuracy sebesar 93% untuk Random Forest dan 88% untuk Decision Tree.

Kata kunci: Daging Sapi, Klasifikasi Citra, Gray Level Co-ccurrence Matrix (GLCM), Random Forest, Decision Tree

ABSTRACT

Beef is a vital source of animal protein. However, its consumption in Indonesia remains relatively low. The continuous increase in beef prices has led to fraudulent practices, such as mixing fresh and non-fresh meat, which poses serious health risks due to the presence of harmful bacteria in spoiled meat. This research aims to classify the freshness level of beef using feature extraction techniques through the Gray Level Co-occurrence Matrix (GLCM) and the Random Forest Algorithm. The study uses 400 augmented image datasets, divided into 238 training datasets and 160 testing datasets with a 60:40 ratio. The results show that the Random Forest algorithm achieved an Accuracy of 93%, while the Decision Tree reached 88%.

Keywords: Beef, Image Classification, Gray Level Co-occurrence Matrix (GLCM), Random Forest, Decision Tree

1. PENDAHULUAN

Daging sapi adalah sumber protein hewani yang memiliki manfaat dalam meningkatkan kapasitas intelektual dan ketahanan fisik, sehingga penting untuk mendukung berbagai aktivitas harian (**Muhammad Al-Jabbar et al., 2021**). Daging sapi memiliki protein sebesar 21,5 gram, lebih tinggi dari daging ayam sebesar 20,6 gram dan daging kambing sebesar 19,5 gram (**Siregar, 2018**). Sementara, daging ikan rata-rata memiliki kandungan protein sebesar 18-25 gram (**Karjuan, 2024**). Sehingga kandungan protein pada daging sapi relatif lebih tinggi apabila dibandingkan dengan jenis daging hewani lainnya, meskipun kandungan protein pada ikan cenderung sebanding.

Berdasarkan laporan dari Direktorat Jenderal Peternakan dan Kesehatan Hewan, konsumsi daging sapi di Indonesia sempat turun menjadi 2,36 kg per kapita per tahun pada 2020 akibat dampak pandemi COVID-19. Konsumsi daging sapi nasional sendiri tercatat sekitar 2,66 kg per kapita per tahun, yang masih jauh di bawah rata-rata konsumsi global sebesar 6,4 kg per kapita per tahun. Pada tahun 2022, angka konsumsi daging sapi mengalami peningkatan menjadi 2,62 kg per kapita per tahun, namun kembali menurun menjadi 2,44 kg per kapita per tahun ditahun 2023. Hal ini menyebabkan asupan protein hewani yang rendah di kalangan masyarakat Indonesia, terutama di golongan ekonomi menengah ke bawah. Sementara itu, harga daging sapi cenderung terus meningkat dari Rp. 123.250/kg hingga Rp. 138.533/kg, atau rata-rata 2,63% per tahun (**Kementerian Pertanian Republik Indonesia, 2023**).

Karena kebutuhan daging sapi yang tinggi dan ketersediaan daging sapi yang terbatas di pasar, daging menjadi sangat mahal (**Azis et al., 2024**). Akibat kenaikan harga, sebagian pedagang melakukan kecurangan dengan mencampurkan daging sapi segar dan tidak segar demi menghindari kerugian (**Ekamila et al., 2023**). Daging sapi yang tidak segar tidak aman untuk dikonsumsi karena mengandung banyak kuman penyebab penyakit (**Riftiarrasyid et al., 2021**). Daging sapi yang tidak segar berisiko terkontaminasi bakteri seperti *Salmonella*, *Clostridium Perfringens*, *Escherichia Coli*, *Listeria Monocytogenes* dan *Campylobacter* yang berpotensi menyebabkan keracunan makanan, dengan gejala seperti mual, diare, kram perut, demam dan sakit kepala bila dikonsumsi (**Prasanda, 2021**). Dengan kemajuan teknologi saat ini, klasifikasi menggunakan algoritma *machine learning* adalah salah satu cara yang dapat membantu membedakan daging sapi segar dan tidak segar.

Pada penelitian yang menerapkan ekstraksi fitur dengan metode GLCM dan algoritma KNN dengan menggunakan 120 sampel, terdiri atas 60 data *training* dan 60 data *testing*, untuk mengklasifikasikan kualitas daging sapi berdasarkan kategori segar, inapan dan busuk menghasilkan akurasi 82% (**Prabowo et al., 2021**). Penelitian lain yang menerapkan algoritma CNN dengan arsitektur *mobileNetV2* menggunakan 2.080 citra sebagai data latih dan 624 citra uji, yang terdiri atas 312 citra daging sapi segar dan 312 citra daging busuk, menghasilkan akurasi model sebesar 94% (**Tirtana & Irawan, 2024**). Selanjutnya, penelitian yang menerapkan metode GLCM dan DNN dengan menggunakan 1.896 data dapat menghasilkan nilai akurasi sebesar 93,46% (**Riftiarrasyid et al., 2021**). Penelitian lain yang menggunakan algoritma *Random Forest* untuk mengklasifikasikan buah segar dan buah busuk menghasilkan nilai akurasi sebesar 95,27% untuk kelas segar dan 96,54% untuk kelas busuk (**Santoso & Hartati, 2022**)

Oleh karena itu, metode yang digunakan pada penelitian ini adalah menggunakan metode algoritma *Random Forest*, *Decision Tree* dan ekstraksi fitur *Gray Level Co-occurrence Matrix* (GLCM). Algoritma *Random Forest* memiliki sejumlah kelebihan, antara lain tingkat kesalahan yang relatif kecil, performa klasifikasi yang optimal, mampu memproses data pelatihan dalam jumlah besar secara efisien serta kemampuannya dalam mengestimasi data yang tidak

tersedia dengan memanfaatkan sampel (**Agustiani et al., 2022**). Algoritma *Decision Tree* memiliki sejumlah keunggulan, di antaranya mudah untuk dipahami dan diinterpretasikan dan mampu menangani data yang kompleks (**Muriyatmoko et al., 2024**). *Gray Level Co-occurrence Matrix* (GLCM) merupakan metode yang berfungsi untuk mengukur frekuensi kemunculan pasangan *pixel* dengan nilai tertentu serta pola spasial yang terbentuk dalam citra, juga memiliki kelebihan dalam mencirikan tekstur suatu gambar (**Puspaningrum & Ari Aldino, 2021**), seperti tingkat kecerahan dan kekontrasan untuk membedakan daging segar dan tidak segar.

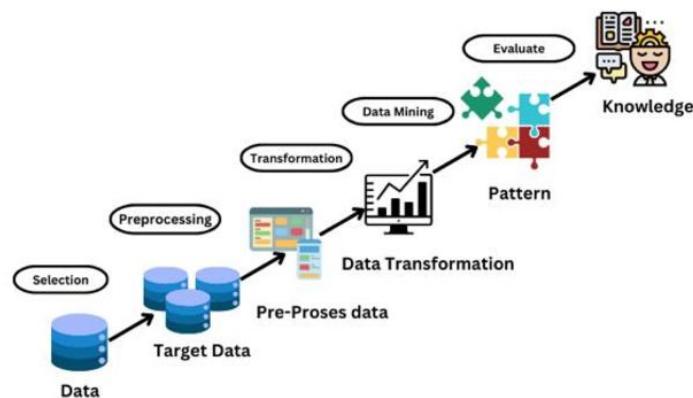
2. METODE PENELITIAN

2.1 Objek Penelitian

Objek yang digunakan dalam penelitian adalah citra daging sapi. *Dataset* diperoleh langsung pada tanggal 22 Desember 2024 dan 9 Mei 2025 di Toko daging wilayah Situ Cipule, Ciampel, Karawang. Daging yang digunakan merupakan bagian paha sapi dan diambil dalam dua bentuk, yaitu potongan utuh dan potongan kecil. Pelabelan kelas untuk data ini dilakukan berdasarkan informasi yang didapatkan dari penjual serta ciri fisik daging seperti warna, bau, dan tekstur, di mana daging sapi tidak segar diperoleh dengan cara menyimpannya pada suhu ruang selama 1-2 hari.

2.2 Tahapan Penelitian

Pada penelitian ini memanfaatkan tahapan dari salah satu metode dalam *data mining* yaitu *Knowledge Discovery in Database* (KDD). Tahapan ini mencakup langkah-langkah seperti *Data Selection*, *Preprocessing*, *Data Transformation*, *Data Mining* dan *Evaluation*.



Gambar 1. Tahapan Penelitian *Knowledge Discovery in Database* (KDD)
(Cahya & Buani, 2024)

2.2.1 *Data Selection*

Data selection adalah tahap yang melibatkan tahap pengambilan, pengumpulan, pemilihan, serta verifikasi data (**Agustian & Darmawan, 2022**).

2.2.2 *Preprocessing*

Preprocessing adalah langkah yang dilakukan untuk membersihkan dan mempersiapkan data agar dapat digunakan pada tahap selanjutnya (**Umair & Susanto, 2024**). Pada penelitian ini melakukan tahapan *preprocessing*, seperti *augmentasi*, *cropping*, *grayscale* dan normalisasi *pixel*.

2.2.3 Data Transformation

Data transformation merupakan tahap yang bertujuan untuk menyesuaikan data dengan format atau struktur yang diperlukan oleh model atau algoritma (**Alghifari & Juardi, 2021**). Penelitian ini melakukan tahap *data transformation*, seperti ekstraksi fitur menggunakan *Gray Level Co-occurrence Matrix* (GLCM), *labeling* dan *train-test split*.

2.2.4 Data Mining

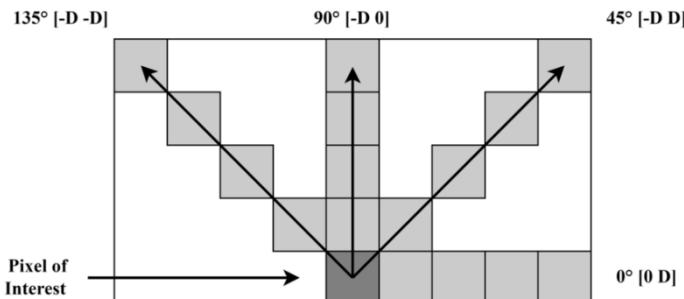
Data mining merupakan tahap dalam proses pencarian dan penggalian pengetahuan untuk menemukan teknik atau algoritma yang dapat digunakan untuk penelitian (**Alghifari & Juardi, 2021**). Pada penelitian ini *data mining* menggunakan algoritma *Random Forest* dan *Decision Tree*.

2.2.5 Evaluation

Evaluation merupakan tahap yang bertujuan untuk menganalisis hasil dari proses *machine learning* serta melakukan interpretasi terhadap performa model algoritma yang digunakan (**Kurniawan & Jajuli, 2022**). Pada tahapan ini melakukan evaluasi dengan memanfaatkan metrik seperti *Accuracy*, *Precision*, *Recall*, *F1-Score* dan *Confusion Matrix*.

2.3 Gray Level Co-occurrence Matrix (GLCM)

Gray Level Co-occurrence Matrix (GLCM) adalah salah satu teknik yang digunakan untuk menganalisis tekstur pada citra. Pada dasarnya, untuk menentukan pasangan *pixel*, GLCM dibagi menjadi empat sudut: 0, 45°, 90, dan 135° dan ditunjukkan pada Gambar 2 (**Agustina & Ardiansyah, 2020**).



Gambar 2. Arah dan Jarak dalam GLCM
(Handayani et al., 2022)

GLCM memiliki beberapa fitur tekstur yang dapat menggambarkan pola tekstur dalam citra dengan mengandalkan hubungan spasial antar *pixel*. Dalam penelitian ini, fitur tekstur yang dianalisis yaitu, *Contrast*, *Energy*, *Homogeneity* dan *Entropy*.

1) *Contrast*

Fitur ini digunakan untuk mengukur intensitas nilai tingkat keabuan di sekitar area citra (**Andono & Rachmawanto, 2021**). Citra dengan nilai *Contrast* tinggi cenderung memiliki permukaan tekstur yang kasar dan variasi intensitas besar, sedangkan citra dengan nilai *Contrast* rendah memperlihatkan permukaan tekstur yang halus dan variasi intensitas kecil. Perhitungan nilai *Contrast* ditunjukkan pada Persamaan (1).

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

2) Energy

Fitur ini digunakan untuk mengukur keseragaman atau *Angular Second Moment* (ASM) dan *Energy* akan menunjukkan nilai tinggi ketika pola *pixel* yang teratur dan konsisten (**Achmad et al., 2021**). Sedangkan, jika nilai *Energy* rendah maka memiliki pola *pixel* yang acak dan tidak teratur. Perhitungan nilai *Energy* ditunjukkan pada Persamaan (2).

$$Energy = \sum_{i,j} P_{i,j}^2 \quad (2)$$

3) Homogeneity

Fitur ini digunakan untuk mengukur kedekatan dan hubungan antar *pixel* pada citra (**Ullu et al., 2022**). Gambar dengan nilai *Homogeneity* tinggi menunjukkan distribusi intensitas yang seragam (halus), sementara gambar dengan nilai *Homogeneity* rendah menunjukkan distribusi intensitas yang bervariasi (kasar). Perhitungan nilai *Homogeneity* ditunjukkan pada Persamaan (3).

$$Homogeneity = \sum_{i,j} \frac{P_{i,j}}{1+|i-j|} \quad (3)$$

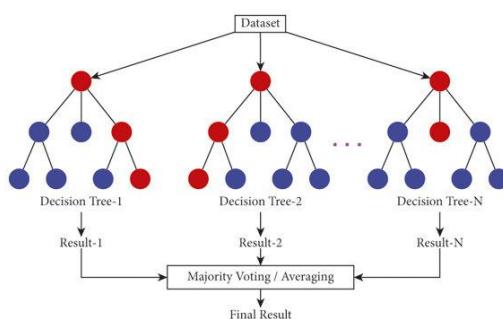
4) Entropy

Fitur ini digunakan untuk menunjukkan seberapa tidak teratur distribusi derajat keabuan pada gambar, fitur ini memiliki nilai yang tinggi jika elemen pada GLCM memiliki nilai yang hampir sama (**Saputri et al., 2022**). Gambar dengan nilai *Entropy* tinggi menunjukkan tekstur yang kompleks dan acak, sedangkan gambar dengan nilai *Entropy* rendah menunjukkan tekstur daging sapi segar teratur dan konsisten. Perhitungan nilai *Entropy* ditunjukkan pada Persamaan (4).

$$Entropy = -\sum_{i,j} P_{i,j} \log (P_{ij}) \quad (4)$$

2.4 Algoritma Random Forest

Random Forest merupakan salah satu algoritma yang menggunakan proses pembagian data secara bertahap dan berulang hingga mencapai node akhir pada setiap pohon keputusan, dengan mengombinasikan sejumlah pohon klasifikasi maupun regresi (**Pamuji & Ramadhan, 2021**). Algoritma *Random Forest* merupakan metode *ensemble* yang dibangun dari algoritma pohon keputusan (*Decision Tree*), yang mencakup beberapa jenis algoritma, seperti *Iterative Dichotomiser 3* (ID3) yang menggunakan nilai *Entropy* dan *Classification and Regression Trees* (CART) yang bergantung pada nilai gini (**Ashfania & Prahasto, 2022**).

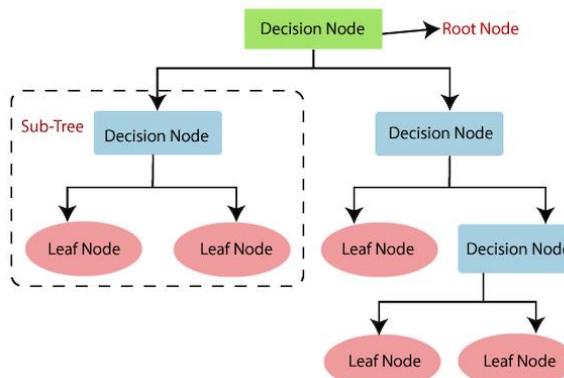


Gambar 3. Cara Kerja Algoritma Random Forest

Gambar 3 menunjukkan cara kerja metode *Random Forest* dapat dijabarkan dalam langkah-langkah berikut (**Trivusi, 2022**), model *Random Forest* menerapkan teknik *bootstrap sampling* dalam proses pemilihan sampel acak dari *dataset*. Setelah sampel dipilih, algoritma membuat bentuk pohon keputusan sehingga hasil prediksi akan didapatkan dari pohon keputusan (*Decision Tree-1*, *Decision Tree-2*, ..., *Decision Tree-N*) yang dibuat. Kemudian, setiap pohon membuat prediksi berdasarkan data uji dan setiap pohon menghasilkan prediksi kelas klasifikasi atau nilai kontinu (regresi) (*Result 1*, *Result-2*, ..., *Result-N*). Setelah itu, *Random Forest* melakukan proses *majority voting/averaging* untuk hasil prediksi dari setiap pohon dan prediksi akhir (*Final Result*) *Random Forest* diputuskan berdasarkan hasil *majority voting* paling banyak.

2.5 Algoritma *Decision Tree*

Decision Tree adalah sebuah model prediktif yang digunakan dalam *data mining* dan *machine learning*, yang dimana model ini berbentuk seperti pohon, di mana setiap simpul pada pohon mewakili sebuah keputusan berdasarkan nilai dari suatu atribut, dan setiap cabang pada simpul mewakili kemungkinan nilai dari atribut tersebut (**Muriyatmoko et al., 2024**).



Gambar 4. Cara Kerja Algoritma *Decision Tree*

Gambar 4 merupakan cara kerja algoritma *Decision Tree* yang dapat dijabarkan dalam langkah-langkah berikut (**Febriansyah et al., 2023**), beberapa kelompok berdasarkan kondisi atau fitur tertentu. Proses ini dimulai dari simpul akar (*root node*) yang memuat pertanyaan atau aturan, kemudian data akan diarahkan ke cabang-cabang berdasarkan apakah memenuhi kondisi tersebut atau tidak. Setiap percabangan akan terus berlanjut hingga mencapai simpul daun (*leaf node*), yaitu bagian akhir yang memuat keputusan atau hasil klasifikasi.

2.5 Evaluasi

Untuk mengevaluasi kinerja model, metrik evaluasi dan *Confusion Matrix* biasa digunakan dalam klasifikasi seperti *Accuracy*, *Precision*, *Recall*, dan *F1-Score* (**Fadli & Saputra, 2023**). *Confusion Matrix* menyajikan informasi mengenai jumlah data yang berhasil diklasifikasikan dengan tepat (*True Positive* dan *True Negative*) serta data yang salah dalam klasifikasi (*False Positive* dan *False Negative*) (**Romindo et al., 2024**). Kemudian, metode untuk mendapatkan nilai *Accuracy* ditunjukkan pada Tabel 1 (**Handayani et al., 2020**).

Tabel 1. Confusion Matrix

Predict	Actual	
	Positive	Negative
Positive	<i>True Positive (TP)</i>	<i>True Negative (TN)</i>
Negative	<i>False Positive (FP)</i>	<i>False Negative (FN)</i>

1) Accuracy

Nilai *Accuracy* adalah pengujian yang digunakan untuk mengukur seberapa baik prediksi cocok dengan nilai sebenarnya secara menyeluruh (**Suarisman et al., 2023**). Perhitungan nilai *Accuracy* ditunjukkan pada Persamaan (5).

$$\text{Accuracy} = \frac{TP+TN}{TP+FP+TN+FN} \quad (5)$$

Keterangan:

TP = *True Positive*

FP = *False Positive*

TN = *True Negative*

FN = *False Negative*

2) Precision

Nilai *Precision* merupakan proporsi prediksi positif yang sesuai dengan kondisi sebenarnya (**Hafidz & Liliana, 2021**). Perhitungan nilai *Precision* ditunjukkan pada Persamaan (6).

$$\text{Precision} = \frac{TP}{TP+FP} \quad (6)$$

3) Recall

Nilai *Recall* diukur dengan membandingkan jumlah prediksi benar pada kelas positif terhadap total data aktual yang termasuk dalam kelas positif (**Bona et al., 2022**). Perhitungan nilai *Recall* ditunjukkan pada Persamaan (7).

$$\text{Recall} = \frac{TP}{TP+FN} \quad (7)$$

4) F1-Score

Nilai *F1-Score* merupakan jumlah *Precision* dan *Recall* yang dihitung dengan rata-rata harmonik (**Fakhri et al., 2024**). Perhitungan nilai *F1-Score* ditunjukkan pada Persamaan (8).

$$F1 - score = 2 * \frac{\text{precision} * \text{recall}}{\text{precision} + \text{recall}} \quad (8)$$

3. HASIL DAN PEMBAHASAN

3.1 Data Selection

Pada tahapan ini mengumpulkan *dataset* secara langsung dari toko daging. Pengambilan gambarnya menggunakan kamera *smartphone* Redmi Note 13 dengan resolusi 1280x960 pada siang hari tanpa menggunakan *flash* dan dalam dua bentuk potongan, yaitu potongan utuh dan potongan kecil. *Dataset* ini memiliki total awal 50 citra daging sapi yang pelabelan daging sapi segar dan tidak segar nya berdasarkan informasi dari penjual.

Tabel 2. Rincian Jumlah *Dataset* Citra Daging Sapi

Nama Kelas	Jumlah Citra
Fresh	25
Spoiled	25



(a)



(b)

Gambar 5. Citra Daging Sapi a) Segar, b) Tidak Segar

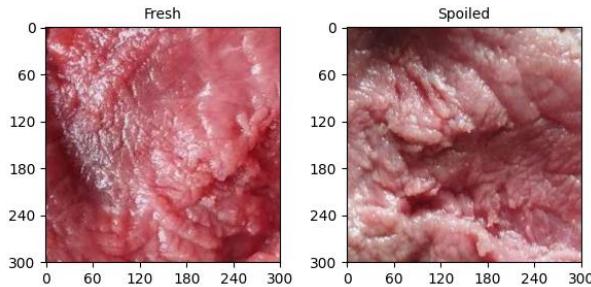
3.2 Preprocessing

Setelah melakukan pengambilan data, citra dikumpulkan untuk melakukan tahapan *preprocessing*, yaitu *augmentasi*, *cropping*, *grayscale* dan normalisasi *pixel* agar dapat digunakan dalam pemodelan.

Tabel 3. Augmentasi Citra

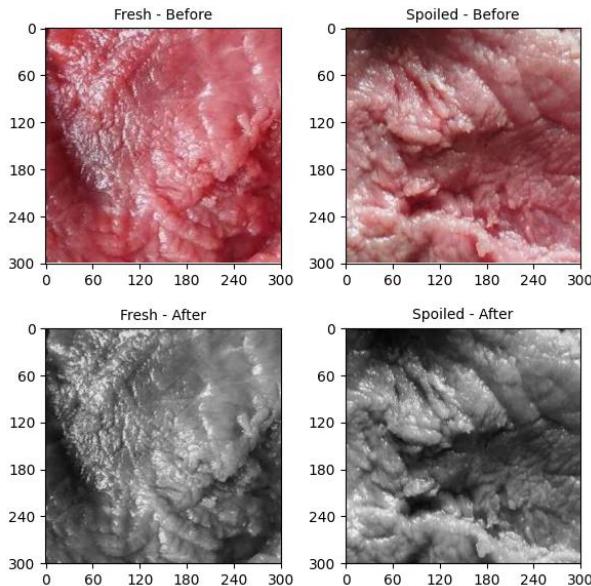
Nama Kelas	Jumlah Citra Sebelum Augmentasi	Jumlah Citra Setelah Augmentasi
Fresh	25	200
Spoiled	25	200

Tabel 3 merupakan hasil tahapan augmentasi yang dilakukan untuk meningkatkan jumlah data *training* dan memperbanyak variasi citra untuk mengurangi risiko *overfitting*. Masing-masing kelas memiliki 25 citra awal dan total 50 citra, kemudian dilakukan augmentasi hingga masing-masing kelas memiliki 200 citra dan total 400 citra. Teknik augmentasi yang digunakan meliputi rotasi acak (*RandomRotation*) antara -30 hingga 30 derajat, pembalikan horizontal dan vertikal (*RandomFlip*), serta perbesaran atau pengecilan acak (*RandomZoom*) dengan skala antara 1.0 hingga 1.3.



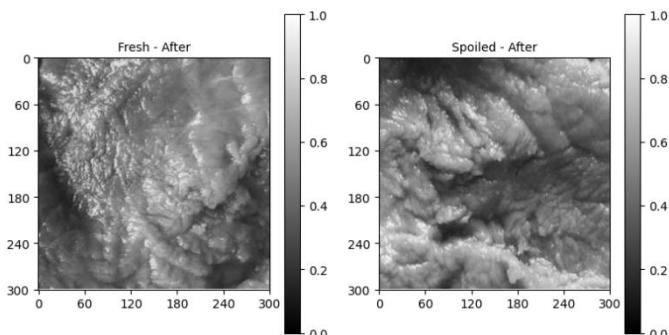
Gambar 6. Hasil *Cropping*

Gambar 6 merupakan hasil dari tahapan *cropping* yang memotong ukuran citra pada bagian tengah yang awalnya 1280x960 menjadi 300x300 *pixel*. Kemudian, hasil ini ditampilkan berdasarkan kelas segar dan tidak segar.



Gambar 7. Hasil *Grayscale*

Gambar 7 merupakan hasil dari tahapan *grayscale*. Setelah melakukan tahapan *cropping*, citra dikonversi yang awalnya berformat BGR (*Blue, Green, Red*) menjadi format *grayscale* atau skala keabu-abuan.



Gambar 8. Hasil Normalisasi *Pixel*

Gambar 8 merupakan hasil tahapan normalisasi *pixel*. Pada tahapan ini mengubah nilai intensitas *pixel* yang awalnya dalam rentang 0-255 *pixel* menjadi rentang 0-1 yang bertujuan untuk memastikan semua input data berada pada skala yang sama dan meningkatkan konsistensi citra pada tahapan ekstraksi fitur GLCM.

3.3 Data Transformation

Setelah melakukan tahapan *preprocessing*, citra yang dihasilkan kemudian diproses lebih lanjut dalam tahap *data transformation* yaitu, ekstraksi fitur GLCM dengan beberapa fitur yang digunakan seperti *Contrast*, *Energy*, *Homogeneity* dan *Entropy*. Tahap ekstraksi fitur menggunakan metode GLCM dihitung berdasarkan empat arah, yaitu sudut 0° , 45° , 90° dan 135° . Setelah itu, tahapan *labeling* pada data dan *train-test split*.

Tabel 4. Hasil Ekstraksi Fitur GLCM

Nama Citra	Fitur GLCM				Kelas
	Contrast	Energy	Homogeneity	Entropy	
Fresh 1	101.677486	0.021379	0.244647	33.078960	Fresh
Fresh 2	125.226895	0.016393	0.203066	34.897384	Fresh
Fresh 3	74.925712	0.019409	0.223586	33.576141	Fresh
Fresh 4	76.945063	0.024461	0.276514	32.246652	Fresh
Fresh 5	183.979652	0.020813	0.194399	33.796459	Fresh
Spoiled 1	445.169760	0.024346	0.192148	35.210036	Spoiled
Spoiled 2	160.249996	0.014364	0.155399	35.483495	Spoiled
Spoiled 3	101.296524	0.018272	0.228881	34.257986	Spoiled
Spoiled 4	422.123268	0.022067	0.188200	35.330588	Spoiled
Spoiled 5	40.532195	0.052439	0.386327	27.024627	Spoiled

Tabel 4 menunjukkan hasil dari ekstraksi fitur menggunakan metode GLCM yang dilakukan pada citra kelas segar dan tidak segar. Pada kelas segar, fitur *Contrast* berkisar antara 74.92 hingga 183.97, sedangkan pada kelas tidak segar, fitur *Contrast* berkisar antara 40.53 hingga 445.16. Fitur *Energy* pada kelas segar memiliki rentang nilai 0.016 hingga 0.024, sementara pada kelas tidak segar berkisar antara 0.014 hingga 0.052. Fitur *Homogeneity*, pada kelas segar memiliki nilai antara 0.194 hingga 0.276, sedangkan pada kelas tidak segar antara 0.155 hingga 0.386. Terakhir, *Entropy* pada kelas segar berkisar antara 32.24 hingga 34.89, sementara pada kelas tidak segar antara 27.02 hingga 35.48.

Berdasarkan hasil ekstraksi fitur GLCM untuk data primer, terdapat perbedaan antara daging sapi segar dan tidak segar. Nilai *Contrast* yang lebih rendah pada kelas segar menunjukkan bahwa memiliki permukaan tekstur yang halus dan variasi intensitasnya kecil, sementara daging sapi tidak segar memiliki permukaan tekstur yang kasar dan variasi intensitas besar. Fitur *Energy* pada kelas segar lebih rendah dibandingkan kelas tidak segar, menunjukkan bahwa daging sapi segar memiliki pola *pixel* yang acak dan tidak teratur, sedangkan daging sapi tidak segar cenderung memiliki pola *pixel* yang teratur dan konsisten.

Selain itu, fitur *Homogeneity* pada kelas segar lebih rendah, yang menunjukkan distribusi intensitas yang bervariasi (kasar), sedangkan daging sapi tidak segar menunjukkan distribusi intensitas yang seragam (halus). Terakhir, fitur *Entropy* pada kelas segar lebih rendah, yang menunjukkan tekstur daging sapi segar teratur dan konsisten, sedangkan daging sapi tidak segar memiliki tekstur yang kompleks dan acak.

```
# Mengubah label menjadi angka: Fresh = 0, Spoiled = 1
y = y.map({'Fresh': 0, 'Spoiled': 1})
```

Gambar 9. Labeling

Gambar 9 menunjukkan setelah proses ekstraksi fitur menggunakan GLCM, dilakukan proses *labeling* dengan mengubah label kelas menjadi nilai numerik, yaitu *Fresh* diberi label 0 dan *Spoiled* diberi label 1.

Tabel 5. Train-Test Split

Pembagian Data	Jumlah
Data Latih	238
Data Uji	160

Tabel 5 menunjukkan setelah tahapan *labeling*, *dataset* dipisahkan ke dalam data latih dan data uji, dengan proporsi 60% untuk data latih dan 40% untuk data uji karena jumlah citra terbatas dan untuk memastikan proporsi uji yang cukup pada saat melakukan evaluasi. Pembagian dilakukan secara acak dengan *random state 42* untuk memastikan hasil yang konsisten.

3.4 Data Mining

Tahapan *data mining* dilakukan dengan menerapkan model algoritma *Random Forest* dan *Decision Tree*. Pemodelan ini dilatih menggunakan beberapa parameter yang terdiri dari jumlah pohon (*n_estimators*), kedalaman pohon maksimum (*max_depth*), jumlah sampel minimum pembagian node (*min_samples_split*) dan jumlah sampel minimum di daun (*min_samples_leaf*). Parameter ini digunakan untuk menghindari *overfitting* pada model dan kemudian diuji untuk memprediksi kesegaran daging sapi.

```
# Random Forest
# Inisialisasi Random Forest Classifier
rf_model = RandomForestClassifier(
    n_estimators=100,
    max_depth=5,
    min_samples_split=10,
    min_samples_leaf=5,
    random_state=42
)

# Melatih model dengan data latih
rf_model.fit(X_train, y_train)

# Prediksi pada data uji
rf_predictions = rf_model.predict(X_test)
```

(a)

```
# Decision Tree
dt_model = DecisionTreeClassifier(
    random_state=42,
    max_depth=5,
    min_samples_split=10,
    min_samples_leaf=10
)

# Melatih model dengan data latih
dt_model.fit(X_train, y_train)

# Membuat prediksi untuk data uji
dt_predictions = dt_model.predict(X_test)
```

(b)

Gambar 10. Parameter Algoritma a) Random Forest, b) Decision Tree

3.5 Evaluation

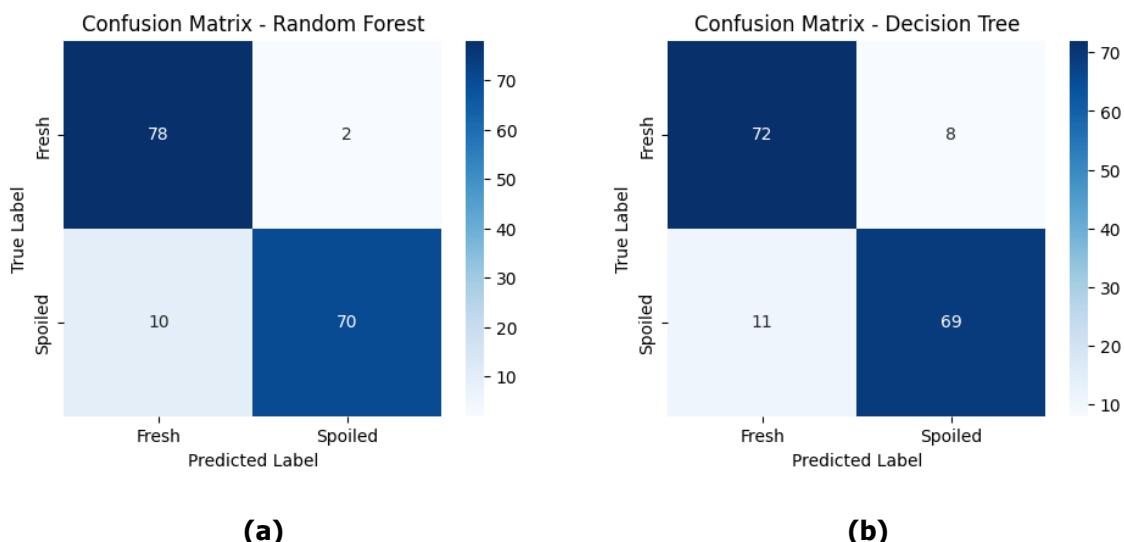
Setelah pemodelan menggunakan algoritma *Random Forest* dan *Decision Tree*, dilakukan tahap evaluasi model untuk menilai kinerja model dalam melakukan klasifikasi berdasarkan fitur GLCM. Evaluasi kinerja ini menggunakan beberapa metrik diantaranya, *Accuracy*, *Precision*, *Recall*, *F1-Score*, serta *Confusion Matrix*.

Tabel 6. Hasil Metrik Evaluasi

Algoritma	Kelas	Precision	Recall	F1-Score	Accuracy
Random Forest	Fresh	89%	97%	93%	93%
	Spoiled	97%	88%	92%	
Decision Tree	Fresh	87%	90%	88%	88%
	Spoiled	90%	86%	88%	

Berdasarkan hasil evaluasi pada Tabel 6, kedua algoritma menunjukkan kinerja klasifikasi yang baik, dengan *Random Forest* mencapai *Accuracy* 93% dan *Decision Tree* 88%. *Random Forest* menunjukkan keseimbangan yang baik antara kedua kelas, dengan *Precision* dan *Recall* yang cukup tinggi untuk kelas *Fresh* (*Precision* 89%, *Recall* 97%) dan *Spoiled* (*Precision* 97%, *Recall* 88%). Sementara itu, pada *F1-Score* juga menunjukkan performa yang baik, yaitu 93% untuk *Fresh* dan 92% untuk *Spoiled*.

Sedangkan, *Decision Tree* memiliki *Precision* yang lebih rendah untuk kelas *Fresh* (87%) dan *Recall* yang sedikit lebih untuk kelas *Spoiled* (86%) dibandingkan dengan *Random Forest*. Namun, *Decision Tree* menunjukkan hasil yang lebih seimbang antara *Precision* dan *Recall* di kedua kelas, dengan *F1-Score* yang serupa untuk kelas *Fresh* (88%) dan *Spoiled* (88%).



Gambar 11. Hasil Confusion Matrix a) Random Forest, b) Decision Tree

Berdasarkan evaluasi performa melalui *Confusion Matrix* pada gambar 11, model *Random Forest* berhasil mengklasifikasikan 78 citra *Fresh* dengan benar, sementara 2 citra *Fresh* salah diklasifikasikan sebagai *Spoiled*. Untuk kelas *Spoiled*, model berhasil mengklasifikasikan 70 citra dengan benar, dan 10 citra *Spoiled* yang keliru diprediksi sebagai *Fresh*. Sementara itu, pada model *Decision Tree*, terdapat 72 citra *Fresh* yang berhasil diklasifikasikan dengan benar, sementara 8 citra *Fresh* salah diklasifikasikan sebagai *Spoiled*. Untuk kelas *Spoiled*, model ini berhasil mengklasifikasikan 69 citra dengan benar, namun terdapat 11 citra *Spoiled* yang keliru diprediksi sebagai *Fresh*.

4. KESIMPULAN

Berdasarkan hasil ekstraksi fitur GLCM, dapat disimpulkan bahwa terdapat perbedaan antara daging sapi segar dan daging sapi tidak segar dalam hal tekstur dan pola pixel-nya. Daging

sapi segar memiliki tekstur yang lebih halus dan pola *pixel* yang lebih acak, sedangkan daging sapi tidak segar menunjukkan tekstur yang lebih kasar dan pola *pixel* yang teratur dan konsisten. Maka dari itu, fitur GLCM seperti *Contrast*, *Energy*, *Homogeneity* dan *Entropy* dapat memberikan informasi untuk membedakan kedua kelas ini.

Sementara itu, untuk hasil evaluasi algoritma *Random Forest* menunjukkan kinerja lebih baik dibandingkan algoritma *Decision Tree* dengan *Accuracy* 93% dan keseimbangan *Precision-Recall* yang tinggi di kedua kelas. Sementara itu, *Decision Tree* mencatat *Accuracy* 88% dengan *F1-Score* seimbang di kelas *Fresh* dan *Spoiled*. Hasil evaluasi melalui *Confusion Matrix* juga menunjukkan bahwa algoritma *Random Forest* lebih efektif dalam menghindari kesalahan klasifikasi pada kelas *Spoiled*, sementara algoritma *Decision Tree* lebih sering membuat kesalahan dalam mengklasifikasikan citra *Spoiled*.

Sebagai saran untuk penelitian selanjutnya, disarankan untuk menggunakan jumlah data yang lebih besar serta variasi yang lebih beragam, seperti kondisi pencahayaan (*Brightness*), sudut pengambilan gambar dan jenis potongan daging yang berbeda. Selain itu, untuk penelitian mendatang juga disarankan dapat mempertimbangkan penerapan algoritma klasifikasi lain untuk meningkatkan *Accuracy* dalam klasifikasi kesegaran daging sapi.

DAFTAR RUJUKAN

- Azis, A. S., Febriansyah, A., Khasanah, N., & Manufaktur Negeri Bangka Belitung, P. (2024). *Identifikasi Kandungan Formalin dan Kesegaran Daging Sapi dengan Image Processing*. 26(1).
- Prasanda, A. (2021, July 6). *Makan Daging Busuk agar Timbul Efek Mabuk, Apa Bahayanya?* <https://www.klikdokter.com/info-sehat/kesehatan-umum/makan-daging-busuk-agar-timbul-efek-mabuk-apa-bahayanya>
- Agustian, R. D., & Darmawan, A. B. (2022). *Analisis Clustering Demam Berdarah Dengue Dengan Algoritma K-Medoids (Studi Kasus Kabupaten Karawang)*.
- Agustiani, S., Tajul Arifin, Y., Junaidi, A., Khotimatul Wildah, S., & Mustopa, A. (2022). *Klasifikasi Penyakit Daun Padi menggunakan Random Forest dan Color Histogram* (Vol. 10, Issue 1). <https://www.kaggle.com/vbookshelf/rice-leaf>
- Agustina, F., & Ardiansyah, Z. A. (2020). Identifikasi Citra Daging Ayam Kampung dan Broiler Menggunakan Metode GLCM dan Klasifikasi-NN Image Identification of Local Chicken Meat and Broiler Chicken MeatUsing GLCM Method and K-NN Classification. In 25 JURNAL INFOKAM: Vol. XVI (Issue 1).
- Alghifari, F., & Juandi, D. (2021). *Penerapan Data Mining Pada Penjualan Makanan Dan Minuman Menggunakan Metode Algoritma Naïve Bayes*.
- Andono, P. N., & Rachmawanto, E. H. (2021). Evaluasi Ekstraksi Fitur GLCM dan LBP Menggunakan Multikernel SVM untuk Klasifikasi Batik. *Masa Berlaku Mulai*, 1(3), 1–9. <https://doi.org/10.29207/resti.v5i1.265>

Pengujian Model Klasifikasi Kesegaran Daging Sapi Berbasis GLCM (Gray Level Co-occurrence Matrix) dan Algoritma Machine Learning

- Ashfania, A. M. G., & Prahasto, T. (2022). *Penggunaan Algoritma Random Forest untuk Klasifikasi berbasis Kinerja Efisiensi Energi pada Sistem Pembangkit Daya* (Vol. 24, Issue 3).
- Bona, D., Nurina Sari, B., Singaperbangsa Karawang Jl HSRonggo Waluyo, U., Telukjambe Tim, K., Karawang, K., & Barat, J. (2022). *Implementasi Jaringan Hierarki Attention Untuk Klasifikasi Basis Data Multimodal Biometrik*.
- Cahya, D., & Buani, P. (2024). Deteksi Dini Penyakit Diabetes dengan Menggunakan Algoritma Random Forest. *Jurnal Sains Dan Manajemen*, 12(1).
- Saputri, D. N., kunci-Pempek, K., Blok Citra, T., & Syaraf Tiruan, J. (2022). *Identifikasi Kadar Ikan Pada Pempek Menggunakan Teknik Blok Citra Dengan Fitur GLCM Dan Metode JST* (Vol. 3, Issue 1).
- Ekamila, T., Rahayu, F., Zuchriadi, A., & Indarso, A. O. (2023). Edu Komputika Journal Penerapan Deep Learning Untuk Klasifikasi Kesegaran Daging Sapi Berbasis Mobile Apps. In *Edu Komputika* (Vol. 10, Issue 1). <http://journal.unnes.ac.id/sju/index.php/edukom>
- Karjuan, E. (2024). *Kandungan Protein dalam Daging Ikan*. <https://www.rri.co.id/kesehatan/957160/kandungan-protein-dalam-daging-ikan>
- Fadli, M., & Saputra, R. A. (2023). *Klasifikasi Dan Evaluasi Performa Model Random Forest Untuk Predksi Stroke Classification And Evaluation Of Performance Models Random Forest For Stroke Prediction*. 12. <http://jurnal.umt.ac.id/index.php/jt/index>
- Riftiarrasyid, F. M., Arif Setyawan, D., & Maulana, H. (2021). Klasifikasi Kesegaran Daging Sapi Menggunakan Metode Gray Level Cooccurrence Matrix dan DNN. In *JIFTI-Jurnal Ilmiah Teknologi Informasi dan Robotika* (Vol. 3). <https://www.kaggle.com/crowww/meat-quality-assessment->
- Fakhri, H., Badriyah, T., Syarif, I., Sigit, R., Elektronika Negeri Surabaya, P., & Raya, J. (2024). *Klasifikasi Tumor Otak Menggunakan Convolutional Neural Network*. 9(1), 2024. <https://www.kaggle.com/>
- Achmad, F. Y., Yulfitri, A., & Ulum, M. B. (2021). Identifikasi Jenis Jerawat Berdasarkan Tekstur Menggunakan GLCM dan Backpropagation. *Jurnal Sains Manajemen Informatika Dan Komputer*, 20(2), 139–146. <https://ojs.trigunadharma.ac.id/>
- Febriansyah, F., Asti Dwiyanti, Z., Firdaus, D., & Informatika, T. (2023). *Deteksi Serangan Low Rate DDoS pada Jaringan Tradisional menggunakan Algoritma Decision Tree* (Vol. 6, Issue 1). <https://glints.com/id/lowongan/decision-tree-adalah/>

- Hafidz, N., & Yanti Liliana, D. (2021). Klasifikasi Sentimen pada Twitter Terhadap WHO Terkait Covid-19 Menggunakan SVM, N-Gram, PSO. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(2), 213–219. <https://doi.org/10.29207/resti.v5i2.2960>
- Handayani, S., Zuhdi, A., & Shofiaty, R. (2022). *Implementation of Grey Level Co-Occurrence Matrix (GLCM) and Support Vector Machine*.
- Handayani, H., Madenda, S., Prasetyo Wibowo, E., Maulana Kusuma, T., Widiyanto, S., & Fitri Nur Masruriyah, A. (2020, November 3). The best classification algorithm for identification beef quality based on marbling. *2020 5th International Conference on Informatics and Computing, ICIC 2020*. <https://doi.org/10.1109/ICIC50835.2020.9288624>
- Kementerian Pertanian Republik Indonesia. (2023). *Outlook Daging Sapi 2023*. <https://satudata.pertanian.go.id/datasets/publikasi>
- Kurniawan, T., & Jajuli, M. (2022). Clustering Data Kecelakaan Lalu Lintas di Kecamatan Cileungsi Menggunakan Metode K-Means. In *Januari 2022 Generation Journal* (Vol. 6, Issue 1).
- Al-Jabbar, M. H., Fitriyah, H., & Maulana, R. (2021). *Sistem Klasifikasi Kesegaran Daging Sapi berdasarkan Citra menggunakan Metode Naïve Bayes berbasis Raspberry Pi* (Vol. 5, Issue 4). <http://j-ptiik.ub.ac.id>
- Muryatmoko, D., Musthafa, A., & Wijaya, M. H. (2024). *Klasifikasi Profil Kelulusan Nilai AKPAM Dengan Metode Decision Tree C4.5*.
- Prabowo, A., Erwanto, D., & Rahayu, P. N. (2021). Klasifikasi Kesegaran Daging Sapi Menggunakan Metode Ekstraksi Tekstur GLCM dan KNN Freshness Classification of Beef Using GLCM Texture Extraction Method and KNN. In *JEC* (Vol. 7, Issue 1).
- Romindo, R., Barus, O. P., & Pangaribuan, J. J. (2024). Implementasi Metode Naive Bayes Classifier Terhadap Klasifikasi Topik Kemacetan Lalu Lintas Indonesia Melalui Tweet. *Jurnal Media Informatika Budidarma*, 8(2), 1087. <https://doi.org/10.30865/mib.v8i2.7470>
- Santoso, F., & Hartati, E. (2022). *Penggunaan Algoritma Random Forest Dalam Klasifikasi Buah Segar Dan Busuk*. 3(1), 133–140. <https://doi.org/10.35957/algoritme.xxxx>
- Puspaningrum, S. A., & Ari Aldino, A. (2021). *Perbandingan Hasil Klasifikasi Jenis Daging Menggunakan Ekstraksi Ciri Tekstur Gray Level Co-occurrence Matrices (GLCM) Dan Local Binary Pattern (LBP)*. 5.
- Siregar, R. S. (2018). *Analisis Faktor-Faktor Yang Mempengaruhi Perilaku Konsumen Dalam Membeli Daging Sapi (Studi Kasus : Di Pasar Petisah Kecamatan Medan Petisah Kota Medan)*, 1.

Pengujian Model Klasifikasi Kesegaran Daging Sapi Berbasis GLCM (Gray Level Co-occurrence Matrix) dan Algoritma Machine Learning

- Suarisman, A., Nazir, A., Syafria, F., & Afriyanti, L. (2023). Perbandingan Jarak Metrik pada Klasifikasi Jamur Beracun Menggunakan Algoritma K-Nearest Neighbor (K-NN). *Journal of Computer System and Informatics (JoSYC)*, 5(1), 10–19. <https://doi.org/10.47065/josyc.v5i1.4511>
- Tirtana, A., & Irawan, R. S. (2024). *Implementasi Convolutional Neural Network dengan Arsitektur MobileNetV2 Untuk Pengklasifikasi Kesegaran Daging*. 8(1), 41–47. <http://ejournal.unipma.ac.id/index.php/doubleclick>
- Trivusi. (2022). *Algoritma Random Forest: Pengertian dan Kegunaannya*. <https://www.trivusi.web.id/2022/08/algoritma-random-forest.html>
- Ullu, H. H., Baso, B., Risald, R., Manek, P. G., & Chrisinta, D. (2022). Ekstraksi Fitur Berbasis Tekstur Pada Citra Tenun Timor Menggunakan Metode Gray Level Co-occurrence Matrix (GLCM). *Journal of Information and Technology*, 2(2), 70–74. <https://doi.org/10.32938/jitu.v2i2.3245>
- Umair, M., & Susanto, E. R. (2024). Analisis Sentimen Ulasan Pengguna Pada Aplikasi BRIMo BRI Menggunakan Metode Klasifikasi Algoritma Naive Bayes. *Jurnal Media Informatika Budidarma*, 8(2), 1149. <https://doi.org/10.30865/mib.v8i2.7381>
- Yulian Pamuji, F., & Puspaning Ramadhan, V. (2021). *Komparasi Algoritma Random Forest Dan Decision Tree Untuk Memprediksi Keberhasilan Immunotherapy*. 7, 46–50. <http://http://jurnal.unmer.ac.id/index.php/jtmi>