

ANALISIS PERBEDAAN SPEKTRUM WARNA MULTI-CHANNEL UNTUK DETEKSI TINGKAT KESEGRAN DAGING MENGGUNAKAN COLOR- SPACE FUSION

Fahmi Fauzia Al Malik¹; Dian Ade Kurnia²; Yudhistira Arie Wijaya³; Ahmad Rifa'i⁴; Dodi Solihudin⁵;

Program Studi Teknik Informatika¹⁴⁵
Program Studi Manajemen Informatika²
Program Studi Sistem Informasi³

STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
fahmialmalik28@gmail.com

(*) Corresponding Author : fahmialmalik28@gmail.com
Published : 31 Desember 2025

Abstract—This study aims to develop an image-based meat freshness classification system using multi-channel color-space fusion. The research extracts statistical color features from RGB, HSV, Lab, and YCrCb spaces and evaluates their effectiveness for non-destructive freshness detection using a Support Vector Machine classifier. The experimental quantitative method includes image acquisition, visual exploration, color-space transformation, feature extraction, normalization, and model evaluation. The results show that the Lab color space contributes strongly to distinguishing freshness levels, and feature fusion from all four spaces provides a more informative representation for modeling. The SVM model achieved 88.43% accuracy and an F1-Score of 0.96 for the Spoiled class, indicating strong detection of color changes that signal freshness. This research confirms that multi-channel color-space fusion is effective for meat-freshness classification and can serve as a foundation for automated inspection systems in the food industry. The findings open opportunities for applying similar techniques to other food products that rely on color changes as freshness indicators.

Keywords: meat freshness; color-space fusion; color spectrum; image classification; SVM

Abstrak—Penelitian ini bertujuan mengembangkan sistem klasifikasi kesegaran daging berbasis citra menggunakan pendekatan multi-channel color-space fusion. Penelitian ini memanfaatkan fitur statistik warna dari ruang warna RGB, HSV, Lab, dan YCrCb, kemudian menguji efektivitasnya dalam mendeteksi tingkat kesegaran daging secara non-destruktif melalui model Support Vector Machine. Metode yang digunakan bersifat kuantitatif eksperimental dengan tahapan akuisisi citra, eksplorasi visual, transformasi ruang warna, ekstraksi fitur, normalisasi, dan evaluasi klasifikasi. Hasil penelitian menunjukkan bahwa ruang warna Lab memberikan kontribusi signifikan terhadap keterpisahan visual antar kelas, sedangkan fusi fitur dari empat ruang warna menghasilkan representasi yang lebih informatif bagi model. Model SVM mencapai akurasi 88,43% dengan F1-Score tertinggi 0,96 pada kelas Busuk, menandakan kemampuan model dalam mengenali pola perubahan warna yang menjadi indikator kesegaran. Penelitian ini menegaskan bahwa pendekatan multi-channel color-space fusion efektif untuk klasifikasi kesegaran daging serta dapat menjadi dasar bagi pengembangan sistem inspeksi otomatis dalam industri pangan. Temuan ini membuka peluang penerapan metode serupa pada produk pangan lain yang bergantung pada perubahan warna sebagai indikator kualitas.

Keyword: kesegaran daging; color-space fusion; spektrum warna; klasifikasi citra; SVM

INTRODUCTION

Industri pangan modern menuntut sistem pengawasan kualitas yang cepat, akurat, dan konsisten untuk menjaga mutu serta keamanan produk daging. Salah satu tantangan utama dalam rantai pasok daging adalah menentukan tingkat kesegaran secara objektif. Penilaian visual oleh manusia sering kali bersifat subjektif dan tidak konsisten. Oleh karena itu, sistem klasifikasi otomatis berbasis pengolahan citra dan machine learning menjadi solusi penting untuk meningkatkan akurasi dan efisiensi penilaian kesegaran daging Alvarez-García.(2024).

Berbagai studi telah menunjukkan keunggulan pendekatan otomatis ini. Alvarez-García, (2024) memanfaatkan visi komputer berbasis AI dan sensor fusion untuk mengukur atribut kualitas daging seperti warna, tekstur, dan komposisi intramuskular secara kuantitatif. Elangovan.(2024). menunjukkan bahwa penggunaan ensembel shallow convolutional neural networks (CNN) mampu mencapai akurasi klasifikasi lebih dari 96%. Sementara itu, Shtepliuk et al (2025) berhasil menggabungkan electronic nose dengan machine learning untuk klasifikasi kesegaran daging babi. Jeong,(2025) juga mengulas peran penting AI dalam proses pengolahan daging dan menekankan konsistensi serta kecepatan keputusan yang dihasilkan oleh machine learning. Secara keseluruhan, sistem klasifikasi otomatis menunjukkan peningkatan presisi, pengurangan variabilitas, dan kemampuan penskalaan yang lebih baik dalam pengawasan kesegaran daging.

Di antara berbagai fitur visual, warna merupakan indikator paling menonjol dalam menilai kesegaran daging secara non-destruktif. Hal ini berkaitan erat dengan kondisi biokimia mioglobin yang memengaruhi perubahan warna daging transformasi antara deoksimioglobin, oksimioglobin, dan metmyoglobin, (Ruedt, 2023).menegaskan bahwa metrik warna seperti L , a , dan b merupakan komponen kunci dalam sistem pengenalan berbasis visi, sedangkan (king, 2023) menyatakan bahwa persepsi warna sangat memengaruhi keputusan konsumen. Penelitian Tomasevic et al.,(2021) mendukung integrasi antara colorimetry tradisional dan teknologi throughput tinggi dalam penilaian kesegaran daging.


Teknologi pengolahan citra dan machine learning memberikan pendekatan evaluasi yang otomatis, objektif, dan non-destruktif terhadap parameter kualitas seperti warna, tekstur, dan senyawa kimia. Liakos et a.,(2025) mencatat bahwa SVM dan CNN sangat efektif dalam tugas pengenalan pola pada pengawasan kualitas pangan. Feng et al.(2024) menyoroti keunggulan penggabungan data dari near-infrared

spectroscopy dan sensor warna menggunakan machine learning. Platform berbasis AI yang dikembangkan oleh (Mehdizadeh et al., 2025) memanfaatkan sensor senyawa volatil dan algoritma machine learning untuk klasifikasi daging dengan presisi tinggi.

Lebih lanjut, pendekatan ekstraksi fitur warna dari berbagai color space telah terbukti meningkatkan akurasi klasifikasi.Modzelewska-Kapituła & Jun, (2022) menemukan bahwa penggabungan fitur dari RGB, HSV, Lab, dan YCrCb menciptakan representasi citra yang lebih kuat dan informatif dibandingkan hanya menggunakan satu ruang warna. Z. Xu, Han, Zhao, et al.(2024a) menekankan pentingnya multi-channel dan hyperspectral image fusion dalam deteksi kualitas non-destruktif. Dengan demikian, analisis spektrum warna multi-channel tidak hanya relevan, tetapi juga mendukung pendekatan yang kuat dalam klasifikasi kesegaran daging secara otomatis.

MATERIALS AND METHODS

Pada tahapan ini, terdapat enam aktivitas utama yang dilakukan secara sistematis sebagaimana ditunjukkan pada Gambar 3.1, yaitu: (1) pengumpulan dan validasi dataset citra daging sapi sebagai data awal penelitian, (2) eksplorasi data awal (EDA) untuk memahami karakteristik visual serta distribusi kelas dalam dataset, (3) pra-pemrosesan dan augmentasi citra guna meningkatkan kualitas serta keragaman data latih, (4) ekstraksi fitur warna dari beberapa ruang warna seperti RGB, HSV, CIELab, dan YCrCb yang menghasilkan representasi numerik dari setiap gambar, (5) klasifikasi menggunakan algoritma Support Vector Machine (SVM) dengan kernel RBF berdasarkan fitur warna yang telah diekstrak, dan (6) evaluasi performa model menggunakan metrik akurasi, presisi, recall, F1-score, serta confusion matrix. Seluruh proses ini dilakukan secara terstruktur dan saling terintegrasi untuk memastikan pengembangan sistem klasifikasi citra kesegaran daging sapi yang adaptif dan akurat.



Gambar 1 Tahapan Penelitian

Gambar 1 menampilkan alur tahapan penelitian yang bersifat sistematis dan iteratif dalam membangun sistem klasifikasi kesegaran daging sapi berbasis citra digital. Proses dimulai dengan pengumpulan dan validasi dataset citra, yang menjadi fondasi penting dalam menjamin kualitas data. Setelah itu, eksplorasi data awal (EDA) dilakukan untuk menganalisis karakteristik warna dan distribusi kelas guna memahami ciri khas visual dari masing-masing kategori kesegaran. Tahapan selanjutnya yaitu pra-pemrosesan dan augmentasi citra dilakukan untuk menormalkan dimensi, memperbaiki kualitas visual, serta memperkaya variasi data menggunakan teknik transformasi seperti rotasi dan flipping.

Langkah berikutnya adalah ekstraksi fitur warna dari berbagai ruang warna (RGB, HSV, CIELab, YCrCb) yang menghasilkan representasi numerik dari tiap citra berdasarkan nilai rata-rata dan deviasi standar dari masing-masing kanal. Fitur-fitur inilah yang kemudian digunakan dalam proses klasifikasi menggunakan algoritma Support Vector Machine (SVM), yang dirancang untuk mengelompokkan gambar ke dalam kelas segar, setengah segar, atau busuk. Terakhir, dilakukan evaluasi performa model menggunakan metrik seperti akurasi, presisi, recall, F1-score, serta visualisasi melalui confusion matrix untuk menilai ketepatan klasifikasi dan mendeteksi potensi kekeliruan. Keseluruhan tahapan ini saling berhubungan dan memungkinkan perbaikan berulang berdasarkan hasil evaluasi, sehingga menghasilkan sistem yang adaptif dan optimal.

Akuisisi dan Persiapan Data

Dataset diperoleh dari Kaggle <https://www.kaggle.com/datasets/fredy78971/daging-resnet50> dan diorganisasi berdasarkan label kelas kesegaran. Validasi dataset dilakukan untuk memastikan bahwa setiap citra memiliki format, ukuran, dan struktur saluran warna yang konsisten. Proses validasi dimulai dengan pemeriksaan format file, memastikan bahwa seluruh citra menggunakan format RGB tanpa saluran alpha yang dapat mengganggu proses ekstraksi fitur. Validasi juga meliputi pengecekan ukuran resolusi karena perbedaan dimensi citra dapat menyebabkan inkonsistensi dalam pemrosesan awal sebagaimana dijelaskan oleh (Büyükarikan et al., 2024).

Dataset kemudian dibagi menggunakan metode stratified sampling dengan rasio 80% untuk pelatihan dan 20% untuk pengujian. Metode stratifikasi sangat penting untuk menjaga keseimbangan proporsi kelas dalam dataset pelatihan dan pengujian, sehingga model tidak bias terhadap kelas tertentu. Ketidakseimbangan data dapat menyebabkan model cenderung

memprediksi kelas mayoritas meskipun nilai akurasi terlihat tinggi. Dengan penerapan stratifikasi, penelitian memastikan bahwa setiap kelas memiliki representasi yang proporsional sebagaimana dijelaskan oleh (Huang, 2024).

Exploratory Data Analysis (EDA)

Exploratory Data Analysis merupakan tahap penting dalam memahami struktur data, distribusi visual, serta potensi masalah seperti class imbalance, outlier, atau noise warna. Tahap ini mencakup analisis histogram warna, pemeriksaan distribusi jumlah gambar per kelas, serta analisis dimensi citra. Proses EDA dilakukan untuk mengetahui karakteristik visual yang membedakan setiap kelas kesegaran daging. Misalnya, citra daging busuk menunjukkan penurunan intensitas kanal merah akibat proses oksidasi myoglobin sebagaimana ditegaskan oleh (Zou et al., 2024).

Langkah pertama dalam EDA ini dilakukan dengan menganalisis distribusi jumlah gambar pada masing-masing kelas kesegaran daging (segar, setengah segar, dan busuk). Visualisasi data dilakukan menggunakan diagram batang (bar plot) untuk melihat seberapa seimbang jumlah data antar kelas. Ketidakseimbangan ini penting untuk dideteksi sejak awal, karena dapat menyebabkan model condong dalam mempelajari kelas mayoritas dan mengabaikan kelas minoritas (Huang, 2024). Sebagai tindak lanjut, peneliti merancang strategi augmentasi untuk memperkaya jumlah data pada kelas dengan representasi rendah.

Selanjutnya dilakukan analisis terhadap histogram kanal warna (RGB) dari setiap gambar. Histogram ini memberikan gambaran distribusi intensitas warna yang dominan pada setiap kelas, dan digunakan untuk mengidentifikasi pergeseran warna akibat proses degradasi daging. Misalnya, kelas busuk menunjukkan pergeseran kanal merah (R) yang lebih redup dibandingkan kelas segar, yang memperkuat temuan visual mengenai perubahan warna pada daging yang telah mengalami oksidasi. Analisis ini memberikan insight mengenai fitur-fitur visual yang paling relevan untuk proses klasifikasi (Huang, 2024).

Tahap EDA juga mencakup analisis terhadap ukuran dan resolusi gambar guna menjamin keseragaman input yang akan digunakan dalam pelatihan model. Konsistensi dimensi citra diperlukan agar tidak menimbulkan noise struktural pada proses ekstraksi fitur. Selain analisis statistik deskriptif, dilakukan pula evaluasi representasi fitur dalam ruang dua dimensi menggunakan teknik dimensionality reduction seperti PCA (Principal Component Analysis) dan t-SNE (t-distributed Stochastic Neighbor Embedding). Tujuan dari visualisasi ini adalah

untuk melihat kedekatan antar sampel dalam setiap kelas dan mendeteksi potensi tumpang tindih (class overlapping) atau outlier yang dapat mengganggu proses pelatihan (Dalakleidi et al., 2022).

Untuk menilai keseimbangan distribusi kelas secara kuantitatif, dilakukan pula uji chi-square goodness-of-fit menggunakan rumus berikut:

$$\chi^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i} \quad (1)$$

- a) χ^2 = Chi-Kuadrat
b) $\sum_{i=1}^k$ Penjumlahan (Summation)

Rumus ini digunakan untuk mengukur perbedaan antara frekuensi observasi aktual (O_i) dan frekuensi yang diharapkan (E_i). Dalam penelitian ini, nilai E_i dihitung berdasarkan distribusi kelas yang seimbang, sedangkan O_i merupakan jumlah citra aktual pada setiap kelas. Nilai chi-square yang besar menunjukkan adanya ketidakseimbangan distribusi yang signifikan antar kelas. Uji ini penting dilakukan karena ketidakseimbangan kelas dapat memengaruhi kinerja model klasifikasi secara signifikan sebagaimana dijelaskan oleh (Huang et al., 2024).

Penggunaan uji chi-square dalam EDA telah direkomendasikan pada penelitian machine learning modern dalam konteks deteksi bias distribusi data sebagaimana ditegaskan oleh (Wang et al., 2024).

Rumus uji Chi-Square Goodness-of-Fit digunakan untuk mengukur sejauh mana distribusi observasi aktual dari suatu kategori menyimpang dari distribusi yang diharapkan (expected). Dalam konteks penelitian ini, rumus ini digunakan untuk menilai apakah distribusi jumlah citra pada masing-masing kelas kesegaran daging (segar, setengah segar, busuk) seimbang atau tidak. Rumusnya adalah:

$$\chi^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i} \quad (2)$$

Dengan keterangan:

- a) χ^2 : Nilai statistik chi-square
b) O_i : Frekuensi observasi aktual pada kategori ke- i
c) E_i : Frekuensi yang diharapkan pada kategori ke- i (dalam distribusi yang seimbang)
d) k : Jumlah kategori (kelas)
e) $\sum i$: Penjumlahan terhadap semua kategori dari $i = 1$ sampai k

Di mana O_i adalah jumlah observasi aktual pada kelas ke- i , dan E_i adalah jumlah yang diharapkan untuk distribusi yang seimbang. Nilai chi-square yang tinggi dapat menjadi indikasi perlunya intervensi pada data (misalnya melalui oversampling atau undersampling) untuk memastikan performa klasifikasi yang adil.

Dengan demikian, tahap EDA dalam penelitian ini tidak hanya berfungsi sebagai pemeriksaan awal terhadap kualitas data, tetapi juga menjadi dasar dalam pengambilan keputusan pada tahap-tahap selanjutnya, seperti pemilihan fitur, strategi augmentasi, dan pemodelan algoritma klasifikasi.

Preprocessing Data

Untuk meningkatkan performa model dan mengurangi overfitting, dilakukan augmentasi data pada kelas yang memiliki jumlah gambar lebih sedikit. Teknik augmentasi meliputi rotasi, flipping, penyesuaian brightness dan contrast, serta penambahan noise Gaussian. Proses augmentasi dilakukan menggunakan pustaka Albumentations yang fleksibel dalam transformasi citra. Augmentasi memastikan model memperoleh variasi data yang lebih luas tanpa mengubah makna semantik gambar. Tujuannya adalah untuk meningkatkan keragaman data pelatihan dan mencegah overfitting sebagaimana disarankan oleh (Shorten & Khoshgoftaar, 2019).

Flipping horizontal dan vertikal digunakan untuk meningkatkan invarian model terhadap orientasi citra. Rotasi acak hingga 25 derajat membantu model mengenali daging dari sudut pandang yang berbeda. Penyesuaian brightness dan contrast meniru kondisi pencahayaan berbeda yang umum terjadi saat pengambilan gambar. Penambahan Gaussian noise bertujuan membuat model lebih tahan terhadap gangguan visual dan noise pada citra. Setelah augmentasi, jumlah data pada kelas minoritas meningkat hingga seimbang dengan kelas mayoritas.

Ekstraksi Fitur

Tahap ekstraksi fitur merupakan inti dari penelitian ini, karena seluruh informasi visual pada citra disederhanakan menjadi representasi numerik yang dapat diproses oleh algoritma pembelajaran mesin. Proses ini dilakukan dengan mengonversi citra ke empat ruang warna: RGB, HSV, CIE Lab, dan YCrCb. Setiap ruang warna memiliki keunggulan masing-masing; RGB merepresentasikan warna asli, HSV memisahkan informasi warna dari intensitas cahaya, CIE Lab merepresentasikan persepsi warna manusia secara

lebih baik, dan YCrCb memisahkan luminance dari krominansi.

Dari setiap ruang warna, dihitung dua color moments yaitu mean dan standar deviasi untuk masing-masing kanal warna, sehingga diperoleh 24 fitur numerik. Rumus perhitungan mean Adalah Color moments dipilih karena telah digunakan secara luas dalam klasifikasi kualitas pangan dan terbukti efektif dalam menggambarkan pola distribusi warna yang berkaitan dengan kesegaran daging sebagaimana dijelaskan oleh (Wang et al., 2024). Fitur-fitur ini kemudian digabungkan menjadi satu vektor fitur yang merepresentasikan distribusi warna setiap gambar sebagaimana ditegaskan oleh (Ma et al., 2023) Rumus Akurasi

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.7)$$

Dengan:

- TP=(TruePositive)
Model benar memprediksi kelas tertentu (misal: BUSUK → BUSUK)
- FP=(FalsePositive)
Model salah memprediksi kelas tertentu (misal: SEGAR → BUSUK)
- FN=(FalseNegative)
Model gagal mendeteksi kelas tertentu (misal: BUSUK → SEGAR)
- Precision = $TP / (TP + FP)$
- Recall = $TP / (TP + FN)$

Keterangan Rumus Akurasi mengukur persentase prediksi benar dari seluruh prediksi.**Digunakan** Untuk melihat performa umum model dalam membedakan 3 kelas kesegaran daging.

Precision = $TP / (TP + FP)$

Recall = $TP / (TP + FN)$

1. Rumus Precision

$$Recall = \frac{TP}{TP + FN} \quad (3.8)$$

- TP = True Positive Kasus yang *sebenarnya* positif dan berhasil diprediksi oleh model sebagai Positif.
- FN = False Negative Kasus yang *sebenarnya* positif tetapi salah diprediksi oleh model sebagai Negatif (terlewatkan).
- Recall = persentase dari *semua* kejadian positif aktual yang berhasil

Keterangan RumusMengukur kemampuan model dalam menangkap semua data pada kelas sebenarnya.Mengapa penting Pada kualitas daging, recall tinggi memastikan daging busuk tidak lolos terdeteksi penting untuk keamanan pangan.

2. Rumus F1-Score

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (3.9)$$

- TP=True Positive Model memprediksi Positif dan itu Benar.
- FP=False Positive Model memprediksi Positif tetapi itu Salah (seharusnya Negatif).

Keterangan RumusF1 adalah harmonisasi antara precision dan recall.**Mengapa digunakan** Karena dataset awal kamu mengalami sedikit ketidakseimbangan (675–630–510).F1-score memberikan evaluasi lebih adil dibanding akurasi. Rumus Confusion Matrix

Tabel 1 rumus confusion matrix

	Prediksi Positif	Prediksi Negatif
Aktual Positif	TP	FN
Aktual Negatif	FP	TN

Pada tabel 1 Fungsi Melihat kesalahan antar kelas (Busuk diprediksi Segar).Bagian tab merangkum seluruh rumus inti yang digunakan dalam penelitian untuk memastikan bahwa setiap tahapan mulai dari eksplorasi data, ekstraksi fitur, normalisasi, pemodelan, hingga evaluasi berjalan secara objektif, terukur, dan sesuai standar metodologi ilmiah. Rumus-rumus ini dipilih karena mampu merepresentasikan karakteristik citra daging secara akurat serta mendukung kebutuhan analisis komputasional dalam sistem klasifikasi kualitas daging sebagaimana direkomendasikan oleh (König et al., 2024).

Tabel 2 Rumus Yang WAJIB Masuk

Tahapan	Rumus
EDA	Chi-Square
Ekstraksi Fitur	Mean, Standar Deviasi
Normalisasi	Z-Score
Pemodelan	Kernel RBF SVM
Evaluasi	Accuracy, Precision, Recall, F1-Score, Confusion Matrix

Setelah fitur diekstraksi, langkah selanjutnya adalah normalisasi fitur menggunakan teknik Z-score normalization. Normalisasi penting karena skala fitur antar ruang warna berbeda secara signifikan, sehingga tanpa normalisasi fitur dengan nilai besar akan mendominasi perhitungan jarak pada SVM.

RESULTS AND DISCUSSION

Ekstraksi fitur visual pada penelitian ini difokuskan pada pemanfaatan ruang warna RGB, HSV, dan Lab untuk memperoleh informasi yang paling representatif terhadap karakteristik kesegaran daging sapi. Gambar 4.4 menampilkan salah satu contoh citra hasil ekstraksi kanal warna, menunjukkan bagaimana transformasi ke ruang warna alternatif seperti Lab mampu mengungkap kontras yang tidak terlihat jelas dalam representasi RGB asli. Kanal L dan a dari ruang warna Lab secara khusus memperlihatkan distribusi kecerahan dan rona merah yang lebih konsisten dan terdistribusi baik antar kelas, mendukung pemisahan kelas segar, setengah segar, dan busuk. Hal ini sejalan dengan temuan Sánchez et al., (2023b) yang menyatakan bahwa kanal L dan a dari CIELab secara signifikan meningkatkan akurasi klasifikasi daging sapi dibandingkan RGB maupun HSV.

Kelebihan pendekatan transformasi fitur dalam studi ini juga tampak pada strategi penggabungan fitur warna manual dengan vektor fitur hasil augmentasi dan normalisasi. Dengan memanfaatkan sifat ruang warna seperti YCrCb dan Lab yang bersifat perceptually uniform dan lebih tahan terhadap variasi pencahayaan, fitur-fitur yang dihasilkan menjadi lebih stabil dan diskriminatif dalam konteks klasifikasi berbasis tekstur dan warna. Büyükarıkan et al. (2024) menunjukkan bahwa fusi antara fitur handcrafted (Lab, YCrCb) dengan fitur CNN mampu memberikan performa terbaik dalam klasifikasi kualitas daging. Penelitian ini mengadopsi prinsip serupa dengan membangun vektor fitur terintegrasi dari berbagai ruang warna sebagai input utama ke dalam model klasifikasi, sekaligus menghindari dominasi satu kanal warna yang mungkin bias terhadap kondisi pencahayaan. Xu et al. (2024) juga merekomendasikan ruang warna Lab sebagai basis visual yang lebih seragam dan tidak terpengaruh oleh pencahayaan, yang valid untuk pengolahan citra daging. Oleh karena itu, strategi ekstraksi dan transformasi fitur pada penelitian ini tidak hanya relevan secara teoritis, tetapi juga memberikan kontribusi praktis terhadap pengembangan sistem klasifikasi mutu daging berbasis visi komputer. Ekstraksi fitur dilakukan menggunakan pendekatan Color-Space Fusion, yang menghasilkan 24 fitur statistik dari empat ruang warna:

- a) RGB (mean & std)
- b) HSV
- c) Lab
- d) YcrCb


Tabel 3 menyajikan daftar lengkap fitur statistik yang diekstraksi dari empat ruang warna berbeda RGB, HSV, Lab, dan YCrCb yang digunakan dalam proses pemodelan. Setiap ruang warna menghasilkan nilai mean dan standard deviation per channel sehingga total fitur yang digunakan berjumlah 24. Tabel 3 menyajikan daftar lengkap fitur yang diekstraksi.

Tabel 3 Daftar Fitur Color-Space Fusion (24 Fitur)

Ruang Warna	Fitur (Mean & Std per Channel)	Total
RGB	R_mean, G_mean, B_mean, R_std, G_std, B_std	6
HSV	H_mean, S_mean, V_mean, H_std, S_std, V_std	6
Lab	L_mean, a_mean, b_mean, L_std, a_std, b_std	6
YCrCb	Y_mean, Cr_mean, Cb_mean, Y_std, Cr_std, Cb_std	6
Total	—	24 Fitur

Tabel 3 menunjukkan bahwa setiap ruang warna memberikan enam fitur statistik yang mewakili distribusi intensitas warna pada citra. Kombinasi fitur dari empat ruang warna ini menghasilkan representasi yang lebih kaya dan komprehensif, karena setiap ruang warna menangkap karakteristik visual yang berbeda. Pendekatan color-space fusion ini meningkatkan kemampuan model dalam membedakan kelas kesegaran daging berdasarkan variasi warna halus, selaras dengan temuan Medeiros et al., (2021) dan Liakos et al. (2025) yang menegaskan efektivitas statistik kanal warna multi-ruang dalam klasifikasi mutu pangan.

Tabel 3 menampilkan jumlah channel warna yang dimiliki setiap citra dalam dataset untuk memastikan konsistensi format gambar sebelum dilakukan proses ekstraksi fitur. Ilustrasi proses ekstraksi fitur ditunjukkan pada Gambar 4.8.



Gambar 4 Diagram Ekstraksi Fitur

Berdasarkan pada Gambar 4 Seluruh citra memiliki tiga channel warna (RGB), yang menunjukkan bahwa dataset bersifat seragam dan tidak mengandung gambar grayscale atau format yang tidak sesuai. Konsistensi ini memastikan bahwa analisis berbasis intensitas warna dapat dilakukan secara akurat dan stabil, sekaligus menghindari inkonsistensi input yang dapat mengganggu proses pelatihan model.

Hasil Pemodelan Klasifikasi Kualitas Daging

model klasifikasi menunjukkan tingkat akurasi sebesar 88.43%, yang mengindikasikan bahwa mayoritas prediksi model sesuai dengan label ground truth. Jumlah data uji sebanyak 363 gambar memberikan ukuran sampel yang cukup untuk menilai kinerja model secara reliabel. Selain itu, setiap gambar diekstraksi menjadi 24 fitur, yang merupakan hasil perhitungan nilai mean dan standar deviasi pada empat ruang warna yang berbeda. Jumlah fitur ini menandakan bahwa model menggunakan representasi warna yang cukup komprehensif untuk membedakan karakteristik visual antar kelas citra. Secara keseluruhan, metrik-metrik ini menunjukkan bahwa model memiliki performa yang stabil dan fitur warna memberikan kontribusi signifikan terhadap kemampuan Performa Model Secara Keseluruhan

Tabel berikut menyajikan ringkasan metrik utama yang diperoleh dari proses evaluasi model klasifikasi berbasis fitur warna. Informasi ini memberikan gambaran umum mengenai performa model, jumlah data yang digunakan pada tahap pengujian, serta kompleksitas fitur yang dianalisis. Dengan demikian, tabel ini menjadi dasar untuk memahami efektivitas model dalam mengenali pola visual pada citra.

Tabel 4 Properti Dataset Citra Daging untuk Deteksi Kesegaran

No.	Properti	Detail	Keterangan
-----	----------	--------	------------

1	Total Gambar	1.815	Dataset berisi seluruh citra yang digunakan dalam eksperimen.
2	Kelas (Label)	Busuk, Segar, Setengah-Segar	Terdapat tiga kategori kualitas daging yang digunakan sebagai label klasifikasi.
3	Distribusi Kelas	Segar: 675, Setengah-Segar: 630, Busuk: 510	Distribusi menunjukkan ketidakseimbangan: kelas busuk memiliki sampel paling sedikit
4	Imbalanced Dataset	Ya (Tidak Seimbang)	Perlu perhatian pada teknik penanganan imbalance (oversampling/augmentation).
5	Dimensi Gambar	Seragam: 416 × 416 piksel	Seluruh gambar telah dinormalisasi ke ukuran piksel yang sama.
6	Channel Warna	Seragam: 3 (RGB)	Semua gambar merupakan citra berwarna tiga kanal.
7	File Rusak	0	Tidak ada file corrupt; seluruh data siap untuk pemrosesan lanjutan.

Tabel 4 menyajikan ringkasan metrik utama yang diperoleh dari proses evaluasi model klasifikasi berbasis fitur warna. Informasi ini memberikan gambaran umum mengenai performa model, jumlah data yang digunakan pada tahap pengujian, serta kompleksitas fitur yang dianalisis. Dengan demikian, tabel ini menjadi dasar untuk memahami efektivitas model dalam mengenali pola visual pada citra. Model Support Vector Machine (SVM) yang dilatih menggunakan fitur Color-Space Fusion dari 4 ruang warna (RGB, HSV, Lab, YCrCb) mencapai akurasi keseluruhan yang tinggi pada data uji.

Rincian Metrik Per Kelas :

Setiap gambar dianalisis melalui 24 fitur warna, yang terdiri dari nilai rata-rata (mean) dan standar deviasi (std) pada empat ruang warna berbeda. Jumlah fitur yang cukup kaya ini membantu model menangkap variasi warna secara lebih detail, sehingga meningkatkan kemampuan model dalam membedakan karakteristik visual antar kelas citra. Secara keseluruhan, hasil evaluasi menunjukkan bahwa penggunaan fitur berbasis

ruang warna memberikan kontribusi signifikan terhadap performa model.

Berdasarkan hasil pada tabel, model klasifikasi menunjukkan performa yang cukup baik dengan akurasi 88.43%, menandakan bahwa sebagian besar prediksi sesuai dengan label sebenarnya. Dengan 363 gambar sebagai data uji, evaluasi ini memiliki dasar yang cukup representatif untuk menilai keandalan model. Berikut adalah Tabel 5 laporan klasifikasi yang merinci performa model untuk setiap kelas ('Busuk', 'Segar', 'Setengah-Segar')

Tabel 5 Hasil dan Evaluasi Model

Metrik	Nilai
Akurasi Model	88.43%
Jumlah Data Uji	363 gambar
Jumlah Total Fitur	24 fitur per gambar (mean & std dari 4 ruang warna)

Tabel 5 menyajikan ringkasan hasil evaluasi model klasifikasi berdasarkan metrik kinerja, jumlah data yang digunakan pada tahap pengujian, serta kompleksitas fitur yang dianalisis. Penyajian ini bertujuan memberikan gambaran umum mengenai kemampuan model dalam memproses dan mengenali pola citra berdasarkan fitur-fitur warna yang diekstraksi.

Penjelasan Metrik:

- Precision: Proporsi prediksi positif yang benar (misalnya, 94% dari gambar yang diprediksi 'Busuk' memang benar 'Busuk').
- Recall: Proporsi kasus positif aktual yang teridentifikasi dengan benar (misalnya, model berhasil mengidentifikasi 97% dari semua gambar 'Busuk' yang ada di data uji).
- F1-Score: Rata-rata harmonik dari Precision dan Recall.

Observasi Utama:

- Model menunjukkan performa terbaik dalam mengklasifikasikan daging 'Busuk' dengan F1-Score 0.96.
- Daging 'Segar' dan 'Setengah-Segar' memiliki F1-Score yang sedikit lebih rendah (0.87 dan 0.84).

CONCLUSION

Penelitian ini menyimpulkan bahwa perbedaan spektrum warna dari berbagai ruang warna dapat digunakan untuk membedakan tingkat kesegaran daging secara efektif. Fitur statistik sederhana berupa nilai rata-rata dan standar deviasi pada kanal RGB, HSV, Lab, dan YCrCb dapat menangkap perubahan warna daging yang terjadi akibat proses

oksidasi dan degradasi mikrobiologis. Hasil pemodelan dengan SVM menunjukkan akurasi 88,43%, dengan kemampuan klasifikasi yang paling stabil pada kelas daging busuk. Temuan ini membuktikan bahwa pendekatan multi-channel color-space fusion menghasilkan representasi visual yang lebih informatif dibandingkan penggunaan satu ruang warna secara tunggal.

Penelitian ini berkontribusi pada pengembangan metode deteksi kesegaran daging berbasis pengolahan citra dengan menyediakan bukti empiris bahwa fusi fitur warna mampu meningkatkan ketelitian proses klasifikasi. Pendekatan ini memberikan alternatif yang lebih murah, cepat, dan non-destruktif dibandingkan metode laboratorium kimia. Penelitian ini juga memperkaya kajian ilmiah mengenai pemanfaatan fitur statistik dalam domain imaging untuk mengidentifikasi kualitas pangan tanpa memerlukan model pembelajaran mendalam, sehingga relevan untuk diterapkan pada perangkat dengan sumber daya terbatas.

Penelitian ini memiliki batasan pada penggunaan satu jenis model klasifikasi, yaitu SVM, serta terbatas pada fitur mean dan standar deviasi. Struktur dataset yang tidak sepenuhnya seimbang juga berpengaruh pada variasi performa klasifikasi antar kelas, terutama pada kelas daging setengah segar yang memiliki distribusi warna lebih bervariasi. Meskipun demikian, hasil yang diperoleh tetap menunjukkan bahwa variasi spektrum multi-channel memiliki potensi besar untuk dioptimalkan pada penelitian lanjutan.

REFERENCE

- Alvarez-García, W. Y., Mendoza, L., Muñoz-Vílchez, Y., Nuñez-Melgar, D. C., & Quilcate, C. (2024). Implementing artificial intelligence to measure meat quality parameters in local market traceability processes. In *International Journal of Food Science and Technology* (Vol. 59, Issue 11, pp. 8058–8068). John Wiley and Sons Inc. <https://doi.org/10.1111/ijfs.17546>
- Alvarez-García, Y., W., Gómez-Calcano, A., García-Mora, & E. (2024). Implementing artificial intelligence to measure meat quality: Trends and challenges. *International Journal of Food Science & Technology*, 59(11), Artikel 8058. <https://doi.org/https://doi.org/10.1111/1750-3841.7933044>
- Boruckowska, H., Boruckowski, T., Bronkowska, M., Prajzner, M., & Rytel, E. (2025). Comparison of colour measurement

- methods in the food industry. *Processes*, 13(5), 1268.
<https://doi.org/10.3390/pr13051268>
- Bu, Y., Hu, J., Chen, C., Bai, S., Chen, Z., Hu, T., Zhang, G., Liu, N., Cai, C., Li, Y., Xuan, Q., Wang, Y., Su, Z., & Xiang, Y. (2023). ResNet incorporating the fusion data of RGB & hyperspectral images improves classification accuracy of vegetable soybean freshness. *Scientific Reports*, 14, 51668.
<https://doi.org/10.1038/s41598-024-51668-6>
- Büyükarıkan, B. (n.d.). ConvColor DL: Concatenated convolutional and handcrafted colour feature extraction for beef quality classification. *Food Research International*, 172, 112814.
<https://doi.org/10.1016/j.foodres.2023.112814>
- Büyükarıkan, B., Tuncer, S. A., Özyurt, F., & Koçak, H. (2024). ConvColorDL: Concatenated convolutional and handcrafted colour-space features for beef quality classification. *Food Research International*, 179, 114456.
<https://doi.org/10.1016/j.foodres.2024.114456>
- Chomicki, A. (2025). Assessing the impact of dataset quality on the performance of machine learning classification tasks. *Procedia Computer Science*, 223, 187–195.
<https://doi.org/10.1016/j.procs.2025.03.031>
- Dalakleidi, K. V., Vlachos, K. A., & Tzovaras, D. (2022). Applying image-based food-recognition systems on mobile devices: A review. *Smart Health*, 24, 100293.
<https://doi.org/10.1016/j.smhl.2022.100293>
- Elangovan, P., Balasubramanian, V., & Vijayalakshmi, S. (2024). A novel approach for meat quality assessment using an ensemble framework of shallow convolutional neural networks. *Applied Sciences*, 14(14), 5979.
<https://doi.org/10.3390/app14145979>
- Feng, Y., Zhang, Y., Shi, H., & Wang, Y. (2024). Machine learning supported ground beef freshness detection via data fusion of near-infrared spectroscopy and paper chromogenic array. *Food and Bioprocess Technology*.
<https://doi.org/10.1002/fft.2438>
- Gong, Y., Huang, Z., & Liu, F. (2023). A survey on dataset quality in machine learning. *Information and Software Technology*, 150, 107236.
<https://doi.org/10.1016/j.infsof.2023.107236>
- Han, W., Hu, C., & Zhang, Y. (n.d.). SVM classification method of meat freshness based on QPSO. *Computers and Electronics in Agriculture*, 216, 108390.
<https://doi.org/10.1016/j.compag.2023.108390>
- Han, W., Hu, C., & Zhang, Y. (2024). SVM classification method of meat freshness based on QPSO. *Computers and Electronics in Agriculture*, 216, 108390.
<https://doi.org/10.1016/j.compag.2023.108390>
- Hoang, P.-H., Tran, N.-H., & Luu, T.-D. (2025). Enhanced Fish Freshness Classification with Incremental Handcrafted Feature Fusion. *Artificial Intelligence in Agriculture*, 5, 1–11.
<https://doi.org/10.1016/j.aiia.2025.10.003>
- Huang, X. (2024). Research progress on machine learning and computer vision in food quality assessment. *Food Science*, 45(4), 239–251.
<https://doi.org/10.7506/spkx1002-6630-20240131-284>
- Jeong, K., Jo, G., Lee, J. H., Kim, B., Choi, J., Oh, H., & Lee, E. (2025). Artificial intelligence in meat processing: A comprehensive review of data driven applications and future directions. *Meat and Muscle Biology*, 9(1), 20157.
<https://doi.org/10.22175/mmb.20157>
- King, D. A. (2023). American Meat Science Association guidelines for meat colour evaluation. *Meat and Muscle Biology*.
<https://doi.org/10.3168/mmb.2023-12473>
- Kurade, C. (2023). An automated image processing module for quality assessment of rice grains using machine learning. *Foods*, 12(6).
<https://doi.org/10.3390/foods12061273>
- Lhermitte, E., Bertaux, N., & Dupont, S. (2022). Deep learning and entropy-based texture features for image classification: Mean and standard-deviation normalization. *Entropy*, 24(11).
<https://doi.org/10.3390/e24111577>
- Liakos, K. G., Balafoutis, A., Bochtis, D., & Papageorgiou, E. (2025). Machine learning for quality control in the food industry. *Foods*, 14(19), 3424.
<https://doi.org/10.3390/foods14193424>
- Luo, D., Zhang, M., & Zhu, J. (2024). Quality detection and grading of peach fruit based on color, size and texture features. *Frontiers in Plant Science*, 15, 141509.
<https://doi.org/10.3389/fpls.2024.141509>
- Ma, W., Zhang, B., Xu, T., & Fan, C. (2023). Multiple Kernel-Based SVM Classification of Hyperspectral Images by Combining Spectral, Spatial, and Semantic Information.

- Remote Sensing*, 15(1), 120.
<https://doi.org/10.3390/rs15010120>
- Medeiros, E. C., Oliveira, L. S., Britto, A. S., & Koerich, A. L. (2021). Computer vision and machine learning for tuna and beef quality classification. *Information Processing in Agriculture*, 8(4), 70–81.
<https://doi.org/10.3390/ipa8040070>
- Meenu, M. (2021). A concise review on food quality assessment using digital image processing. *Trends in Food Science & Technology*, 112, 412–422.
<https://doi.org/10.1016/j.tifs.2021.04.021>
- Mehdizadeh, S. A., Ghaffari, H., & Dehghan, S. (2025). AI-driven non-destructive detection of meat freshness using sensor arrays and machine learning algorithms. *Food Bioscience*, 59, 103665.
<https://doi.org/10.1016/j.fbio.2024.103665>
- Modzelewska-Kapituła, M., & Jun, S. (n.d.). The application of computer vision systems in meat science and industry – A review. *Meat Science*, 192, 108904.
<https://doi.org/10.1016/j.meatsci.2022.108904>
- Modzelewska-Kapituła, M., & Jun, S. (2022). The application of computer vision systems in meat science and industry – A review. *Meat Science*, 192, 108904.
<https://doi.org/10.1016/j.meatsci.2022.108904>
- Niu, W., Zhang, B., Chen, Q., Sun, T., & Wang, Y. (2024). Review of the deep learning for food image processing. *International Journal of Agricultural and Biological Engineering*, 17(5), 15–30.
<https://doi.org/10.25165/j.ijabe.20241705.8975>
- Olakanmi, S. J., Olaniyi, O. W., & Ojo, A. (2023). Applications of imaging systems for the assessment of quality attributes in foods. *Comprehensive Reviews in Food Science and Food Safety*, 22(4), 1570–1589.
<https://doi.org/10.1111/1541-4337.13131>
- risssss. (n.d.). TY - JOUR%0AAU - Boruckowska, H.%0AAU - Boruckowski, T.%0AAU - Bronkowska, M.%0AAU - Prajzner, M.%0AAU - Rytel, E.%0APY - 2025%0ATI - Comparison of colour measurement methods in the food industry%0AJO - Processes%0AVL - 13%0AIS - 5%0ASP - 1268%0ADO - 10
- Ruedt, C. (2023). Meat colour and iridescence: Origin, analysis, and approaches. *Comprehensive Reviews in Food Science and Food Safety*. <https://doi.org/10.1111/1541-4337.13191>
- Sánchez, C. N., Orvañanos Guerrero, M. T., Domínguez Soberanes, J., & Álvarez Cisneros, Y. M. (2023a). Analysis of beef quality according to colour changes using computer vision and white box machine learning techniques. *Heliyon*, 9(7).
<https://doi.org/10.1016/j.heliyon.2023.e17976>
- Sánchez, C. N., Orvañanos Guerrero, M. T., Domínguez Soberanes, J., & Álvarez Cisneros, Y. M. (2023b). Analysis of beef quality according to colour changes using computer vision and white box machine learning techniques. *Heliyon*, 9(7), 17976.
<https://doi.org/10.1016/j.heliyon.2023.e17976>
- Shteplyuk, I., Domènech Gil, G., Almqvist, V., Kautto, A. H., Vågsholm, I., Boqvist, S., & Puglisi, D. (2025). Electronic nose and machine learning for modern meat inspection. *Journal of Big Data*, 12, 96.
<https://doi.org/10.1186/s40537>
- Simović, P., Ristić, S., & Petrović, M. (2024). The effects of data quality on deep learning performance in biological image recognition. *Water*, 17(1), 21.
<https://doi.org/10.3390/w17010021>
- Tahir, G. A. (2024). A comprehensive survey of image based food recognition and volume estimation. *Foods*, 10(9), 2125.
<https://doi.org/10.3390/foods10092125>
- Tan, K., Li, S., Wang, S., & Li, C. (2022). Classification of Hyperspectral Images by SVM Using a Composite Kernel by Employing Spectral, Spatial and Hierarchical Structure Information. *Remote Sensing*, 14(8).
<https://doi.org/10.3390/rs14081832>
- Tomasevic, I., Zdolec, N., Krocko, M., Skunca, D., & Aleksic, N. (2021). Recent advances in meat color research: Integrating traditional and high-throughput approaches. *Meat Science*, 181, 108695.
<https://doi.org/10.1016/j.meatsci.2021.108695>
- Wang, C., Zhang, X., Lv, Y., & Liu, Z. (2024). Deep Learning-Based Visual Quality Assessment of Agricultural Products: A Comprehensive Review. *Computers and Electronics in Agriculture*, 216, 108420.
<https://doi.org/10.1016/j.compag.2023.108420>
- Wu, X., Liang, X., Wang, Y., Wu, B., & Sun, J. (n.d.). Non-destructive techniques for the analysis and inspection of meat quality: A review. *Foods*, 11(22), 3713.
<https://doi.org/10.3390/foods11223713>

- Xiao, Z., Wang, J., Han, L., Guo, S., & Cui, Q. (2022). Application of machine vision system in food detection. *Frontiers in Nutrition*, 9, 888245. <https://doi.org/10.3389/fnut.2022.888245>
- Xiao, Z., Wang, J., Han, L., Guo, S., & Cui, Q. (2024). Application of machine vision system in food detection. *Frontiers in Nutrition*, 9, 888245. <https://doi.org/10.3389/fnut.2022.888245>
- Xu, W. (2024). Non-destructive detection of beef freshness based on optimized colour components. *Journal of Food Engineering*, 321, 110963. <https://doi.org/10.1016/j.jfoodeng.2022.110963>
- Xu, Z., Chen, S., Zhao, D., Yao, H., Hao, J., & Bai, Y. (n.d.). Non-destructive detection of chilled meat quality based on hyperspectral technology combined with different data processing methods. *Frontiers in Nutrition*, 12, 1623671. <https://doi.org/10.3389/fnut.2025.1623671>
- Xu, Z., Han, Y., Chen, S., Zhao, D., Yao, H., Hao, J., Li, J., Li, K., Li, S., & Bai, Y. (2024). Research on non destructive detection of chilled meat quality based on hyperspectral technology combined with different data processing methods. *Frontiers in Nutrition*, 12, 1623671. <https://doi.org/10.3389/fnut.2025.1623671>
- Xu, Z., Han, Y., Zhao, D., Li, K., Li, J., Dong, J., Shi, W., Zhao, H., & Bai, Y. (2024a). Research progress on quality detection of livestock and poultry meat based on machine vision, hyperspectral and multi-source information fusion technologies. *Foods*, 13(3), 469. <https://doi.org/10.3390/foods13030469>
- Xu, Z., Han, Y., Zhao, D., Li, K., Li, J., Dong, J., Shi, W., Zhao, H., & Bai, Y. (2024b). Research progress on quality detection of livestock and poultry meat based on machine vision, hyperspectral and multi source information fusion technologies. *Foods*, 13(3), 469. <https://doi.org/10.3390/foods13030469>
- Zhang, J., Zhang, S., Liu, C., & Li, Q. (n.d.). Hyperspectral Image Classification Based on Adaptive Weighting Multiple Kernel Support Vector Machine. *IEEE Transactions on Geoscience and Remote Sensing*, 59(6), 5035–5048. <https://doi.org/10.1109/TGRS.2020.3015525>
- Zhang, J., Zhang, S., Liu, C., & Li, Q. (2021). Hyperspectral Image Classification Based on Adaptive Weighting Multiple Kernel Support Vector Machine. *IEEE Transactions on Geoscience and Remote Sensing*, 59(6), 5035–5048. <https://doi.org/10.1109/TGRS.2020.3015525>
- Zhang, J., Zhang, S., Liu, C., & Li, Q. (2022). Hyperspectral Image Classification Based on Adaptive Weighting Multiple Kernel Support Vector Machine. *IEEE Transactions on Geoscience and Remote Sensing*, 59(6), 5035–5048. <https://doi.org/10.1109/TGRS.2020.3015525>
- Zou, X. G., Xin, C. R., Wang, C. Y., Li, Y. H., Wang, S. C., & Zhang, W. T. (2024). Non-destructive detection of chicken freshness based on multiple-feature image fusion and support vector machine. *International Journal of Agricultural and Biological Engineering*, 17(6), 264–272. <https://doi.org/10.25165/j.ijabe.20241706.8783>