

## **APLIKASI PENGOLAHAN CITRA DALAM DIFERENSIASI BIJI KOPI NON-FERMENTASI DAN FERMENTASI**

**Yusnan Hasani Siregar\***, Seri Intan Kuala, Ari Rahayuningtyas, Lista Eka Yulianti  
*Pusat Riset Teknolgi Tepat Guna - BRIN*

*\*Penulis korespondensi: yusnanhasan@gmail.com*

### **ABSTRAK**

Fermentasi kopi merupakan teknik penting untuk meningkatkan nilai ekonomis biji kopi melalui modifikasi flavour. Namun, metode evaluasi kualitas kopi saat ini masih bersifat destruktif, mahal, dan memakan waktu. Penelitian ini mengembangkan pendekatan nondestruktif berbasis pengolahan citra digital dan pembelajaran mesin untuk mengklasifikasikan kopi non-fermentasi, fermentasi 1 (air dan ragi), dan fermentasi 2 (gula dan sari tauge) berdasarkan karakteristik visual. Citra biji kopi yang telah dipanggang dianalisis untuk fitur warna, tekstur, dan bentuk. Fitur warna diekstraksi menggunakan saluran warna pada ruang RGB, sedangkan fitur tekstur diukur menggunakan matriks Grey Level Co-occurrence Matrix (GLCM) untuk menghitung kontras, energi, dan homogenitas. Selain itu, fitur bentuk dianalisis melalui kontur untuk menghitung keliling dan eksentrisitas bentuk biji kopi. Fitur-fitur ini digunakan dalam model klasifikasi dengan algoritma Random Forest, KNN, SVM, dan Logistic Regression. Logistic Regression menunjukkan performa terbaik dengan akurasi 94,93%, diikuti Random Forest dan SVM dengan akurasi 93,24%, serta KNN dengan 91,30%. Metode ini memberikan solusi cepat, akurat, dan efisien untuk evaluasi kualitas kopi.

**Kata kunci:** fermentasi kopi, pengolahan citra, pembelajaran mesin, klasifikasi

### **1 PENDAHULUAN**

Kopi merupakan salah satu komoditas minuman non alkohol yang paling banyak dikonsumsi di seluruh dunia. Total konsumsi kopi secara umum terus meningkat hingga mencapai 178.5 million 60 kg bags di tahun 2022/2023 (Statista, 2024). Tingginya nilai konsumsi ini berbanding lurus dengan permintaan biji kopi yang memiliki kualitas baik. Kualitas kopi sangat dipengaruhi oleh berbagai faktor seperti lokasi dan teknik pengolahan (Freitas et al., 2024). Di beberapa daerah, flavour biji kopi yang dihasilkan masih belum dapat diterima kalangan umum sehingga menurunkan nilai ekonomisnya.

Fermentasi merupakan salah teknik pengolahan biji kopi untuk modifikasi flavour kopi yang diharapkan mampu meningkatkan harga jual. Selama fermentasi, terjadi proses metabolisme bakteri/ragi (Elhalis et al., 2023) baik secara aerobik/anaerobic pada jangka waktu tertentu. Perbedaan metode fermentasi menghasilkan flavour berbeda (Bastian et al., 2024; Nasution et al., 2024; Saito et al., 2024; Tolentino Vaz et al., 2024) yang terkait sifat kimia selama proses fermentasi.

Analisa flavour saat ini masih bersifat destruktif dengan sumber daya yang cukup mahal. Selain itu, analisa ini membutuhkan waktu yang cukup lama mengingat banyak tahapan yang harus dilewati. Terdapat metode nondestruktif yang berpotensi untuk dimanfaatkan sebagai solusi dari

permasalahan yang ada. Beberapa penelitian telah menggunakan image processing dalam menganalisa chemical properties (Walke et al., 2023; Wilkinson et al., 2022; Zeng et al., 2022) dan (Tomar et al., 2024). Sedangkan penelitian kopi pada beberapa tahun terakhir juga menunjukkan bahwa metode pengolahan citra digital efektif untuk mengklasifikasikan biji kopi berdasarkan tingkat pemanggangan (Santoso et al., 2024), ukuran (Pawłowski et al., 2024), dan tekstur (Septiarini et al., 2024). Namun, penelitian yang secara khusus memfokuskan pengaruh fermentasi terhadap sifat fisik biji kopi menggunakan metode pengolahan citra digital masih belum ada. Penelitian ini juga mengintegrasikan metode pembelajaran mesin untuk melakukan klasifikasi otomatis berdasarkan fitur-fitur yang diekstraksi dari citra biji kopi. Dengan demikian, hasil penelitian ini diharapkan dapat memberikan kontribusi pada peningkatan efisiensi dalam evaluasi kualitas dan karakteristik biji kopi dalam industri kopi.

## 2 METODE

Penelitian ini bertujuan untuk membedakan kopi non-fermentasi, kopi yang difermentasi dengan formula 1 (air dan ragi), dan kopi yang difermentasi dengan formula 2 (gula dan sari taugé) berdasarkan karakteristik visualnya. Citra biji kopi diakuisisi setelah pemanggangan pada tingkat yang sama yaitu medium, untuk memastikan homogenitas dalam parameter roasting (Rahayuningtyas et al., 2024). Citra biji kopi diakuisisi sebanyak 1530 citra menggunakan kamera mikroskopik.

Untuk mengklasifikasikan kategori non-fermentasi dan fermentasi, penelitian ini mengusulkan pendekatan berbasis pengolahan citra digital dengan menggunakan fitur warna, tekstur, dan bentuk. Fitur-fitur tersebut diekstraksi menggunakan metode yang telah banyak diterapkan dalam berbagai aplikasi pengolahan citra pada produk agrikultur (Juan Pablo Guerra & Francisco Cuevas, 2024). Melalui pendekatan ini, diharapkan dapat diperoleh model klasifikasi yang mampu secara akurat membedakan biji kopi berdasarkan proses fermentasi yang diterapkan.

Fitur warna dianalisis dengan menghitung intensitas rata-rata setiap saluran warna dalam ruang RGB, untuk mendeteksi perubahan visual akibat fermentasi. Fitur tekstur diekstraksi menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM), melibatkan parameter seperti kontras, energi, dan homogenitas (Adhitya et al., 2020). Formula yang digunakan adalah persamaan 1 - 3.

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

$$\text{Energi} = \sum_{i,j} P(i, j)^2 \dots\dots\dots(2)$$

$$\text{Homogenitas} = \sum_{i,j} \frac{P(i,j)}{1+(i-j)^2} \dots\dots\dots(3)$$

Di mana  $P(i, j)$  adalah probabilitas pasangan piksel dalam matriks GLCM.

Fitur bentuk diekstraksi dari kontur biji kopi dengan menghitung keliling dan eksentrisitas, yang merepresentasikan perubahan fisik akibat fermentasi. Formula untuk keliling dapat dutiliskan seperti Persamaan 4.

$$\text{Keliling} = \sum_{k=1}^{N-1} \sqrt{(x_{k+1} - x_k)^2 + (y_{k+1} - y_k)^2} \dots\dots\dots(4)$$

Untuk fitur bentuk, dilakukan analisis kontur biji kopi untuk mengukur keliling dan eksentrisitas, yang dapat mencerminkan perubahan bentuk fisik akibat fermentasi. Ukuran keliling dan eksentrisitas dihitung dengan menggunakan metode kontur sesuai Persamaan 5 berikut:

$$\text{Eksentrisitas} = 1 - \frac{b^2}{a^2} \dots\dots\dots(5)$$

Di mana  $x_k$  dan  $y_k$  adalah koordinat  $x$  dan  $y$  dari setiap titik pada batas atau kontur objek,  $a$  dan  $b$  masing-masing adalah panjang sumbu mayor dan minor dari elips yang dipasang pada kontur objek.

Parameter ini penting karena fermentasi dapat memengaruhi struktur biji kopi secara fisik, yang bisa dianalisis dengan fitur geometris ini. Penelitian terdahulu menunjukkan bahwa bentuk, yang diukur melalui keliling dan eksentrisitas, efektif untuk membedakan objek agrikultural yang mengalami perubahan fisik dalam berbagai kondisi pengolahan.

Pemilihan fitur warna, tekstur, dan bentuk dalam metodologi ini didasarkan pada kemampuannya untuk merepresentasikan perubahan visual yang terjadi selama fermentasi. Studi terkini menyarankan bahwa fitur-fitur ini relevan untuk klasifikasi otomatis berbasis citra, terutama dalam sektor agrikultural dan makanan, di mana fitur-fitur ini memberikan informasi visual yang dapat membantu dalam memahami perubahan fisik dan kimia yang terjadi selama proses fermentasi (Sabahannur et al., 2018).


Hasil ekstraksi fitur digunakan untuk membangun model klasifikasi menggunakan RandomForest, K-Nearest Neighbors (KNN), Support Vector Machine (SVM), dan Logistic Regression. Pemilihan algoritma ini berdasarkan kemampuan dalam menangani data visual dan menjaga efisiensi komputasi. Setiap model dilatih menggunakan data sebanyak 1380 dengan perbandingan 70% untuk data latih dan 30% data uji. Evaluasi model dilakukan untuk menentukan akurasi terbaik dalam mengklasifikasikan kategori fermentasi biji kopi. Model terbaik digunakan untuk memprediksi data baru sebanyak 150 citra.

### 3 HASIL DAN PEMBAHASAN

Citra yang ditunjukkan oleh Gambar 1 adalah citra hasil akuisisi dari tiga jenis sampel biji kopi yang telah melalui perlakuan fermentasi yang berbeda yaitu non-fermentasi, fermentasi 1, dan fermentasi 2. Citra ini memperlihatkan perbedaan visual yang signifikan, yang dapat diidentifikasi melalui perubahan warna, tekstur permukaan, dan karakteristik fisik biji kopi akibat proses fermentasi.

Sampel pertama (non-fermentasi) tampak memiliki warna yang lebih gelap dengan permukaan kasar, mencerminkan sifat alami biji kopi yang belum mengalami proses fermentasi. Proses fermentasi 1 menghasilkan perubahan warna menjadi lebih terang dengan tekstur yang terlihat lebih halus dibandingkan dengan biji non-fermentasi. Sementara itu, sampel fermentasi 2 menunjukkan perubahan warna yang lebih signifikan menuju kekuningan, yang disertai dengan tekstur permukaan yang lebih seragam.

Perbedaan ini diduga disebabkan oleh perubahan biokimia selama proses fermentasi, di mana enzim dan mikroorganisme memecah senyawa kompleks dalam biji kopi menjadi senyawa yang lebih sederhana (Evangelista et al., 2015). Proses ini tidak hanya memengaruhi komposisi kimia biji kopi tetapi juga sifat fisik dan visualnya. Analisis citra seperti ini dapat digunakan untuk mengidentifikasi dan mengklasifikasi perlakuan fermentasi secara non-destruktif, sekaligus mengevaluasi kualitas biji kopi berdasarkan parameter visual. Pendekatan ini relevan untuk penelitian lebih lanjut dalam bidang pengolahan kopi serta penerapan teknologi pengolahan berbasis citra.



**Gambar 1.** Akuisisi citra biji kopi

Tabel 1 menunjukkan hasil ekstraksi fitur dari sejumlah citra. Fitur yang dihasilkan mencakup berbagai parameter numerik yang mencerminkan karakteristik visual dan tekstural dari setiap citra, termasuk *Total Area*, nilai intensitas warna (*Blue*, *Green*, *Red*), serta fitur tekstur seperti *Contrast*, *Energy*, dan *Homogeneity*. Selain itu, parameter geometris seperti *Perimeter* dan *Eccentricity* juga diukur.

Fitur *Total Area* merepresentasikan luas area dari objek utama yang terdeteksi dalam citra, diukur dalam satuan piksel. Nilai intensitas warna (*Blue*, *Green*, *Red*) memberikan informasi tentang komposisi warna dominan dalam citra, yang dihitung sebagai rata-rata dari saluran warna blue, green, dan red. Fitur tekstural, seperti *Contrast*, *Energy*, dan *Homogeneity*, dihitung berdasarkan matriks ko-ocurrence (*Gray Level Co-occurrence Matrix*, GLCM). *Contrast* menunjukkan perbedaan lokal antara intensitas piksel, sementara *Energy* merepresentasikan tingkat keteraturan dalam pola intensitas. *Homogeneity* mengukur seberapa seragam distribusi intensitas dalam citra.

Fitur *Perimeter* menunjukkan panjang total kontur objek dalam citra, yang memberikan indikasi kompleksitas bentuk. Sementara itu, *Eccentricity* menggambarkan derajat elipsitas objek, dengan nilai mendekati 1 menunjukkan bentuk yang lebih lonjong.

Dari hasil Tabel 1, terlihat bahwa beberapa citra memiliki nilai fitur yang cukup bervariasi. Citra AF0001.bmp memiliki *Total Area* yang besar (1,308,417 piksel) dan nilai *Contrast* yang cukup tinggi (27.56), yang menunjukkan objek dengan luas besar dan perbedaan intensitas yang signifikan. Sebaliknya, citra AF0100.bmp memiliki *Total Area* yang sangat kecil (33 piksel) dengan *Energy* yang rendah (0.072), yang menunjukkan objek dengan pola intensitas yang tidak terlalu teratur.

**Tabel 1.** Ekstrak fitur

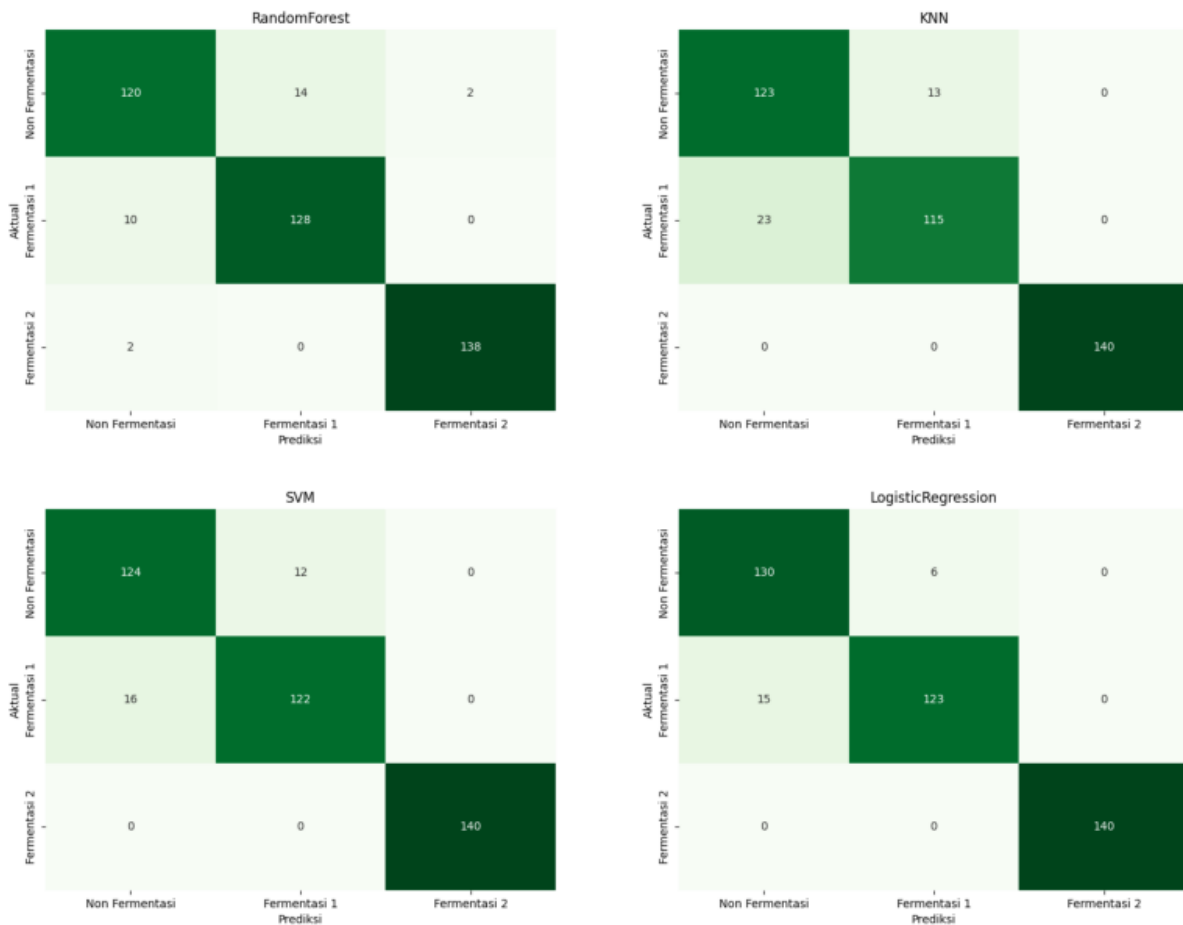
No	Citra	Total Area	B	G	R	Contrast	Energy	Homogeneity	Perimeter	Eccentricity
1	AF0001.bmp	1308417	174.7831	191.577	217.9589	27.56486	0.584407	0.689124	4604	1.25
2	AF0002.bmp	717720.5	164.6183	187.9053	211.8434	9.634176	0.449544	0.677657	4604	1.25
3	AF0003.bmp	1308417	169.8871	187.5922	212.6881	46.53536	0.555721	0.642139	4604	1.25
4	AF0004.bmp	1308088	173.3827	191.0481	214.4865	13.24675	0.545108	0.68495	4604	1.25
5	AF0005.bmp	1308258	167.409	188.4061	216.4328	35.20413	0.584714	0.69365	4604	1.25
6	AF0100.bmp	33	137.5221	163.3634	186.5	3.601698	0.072096	0.606791	4604	1.25
7	AF0101.bmp	1308371	167.2978	183.2435	205.6605	28.96294	0.65039	0.72772	4604	1.25
8	AF0102.bmp	1308408	170.5766	185.2264	205.8369	14.14458	0.649926	0.74055	4604	1.25
9	AF0103.bmp	232151	141.7604	166.5662	187.9091	22.62765	0.09023	0.559078	4604	1.25
10	AF0104.bmp	28267	135.9443	159.3425	179.0115	6.456824	0.065214	0.57631	4604	1.25
11	AF0200.bmp	158757.5	142.1994	168.5587	191.0937	25.19323	0.075718	0.553285	4604	1.25
12	AF0201.bmp	1087358	155.7529	183.7115	207.0715	9.380797	0.204145	0.638908	4604	1.25
13	AF0202.bmp	1308367	171.1019	189.7788	215.2728	22.27197	0.648247	0.747119	4604	1.25
14	AF0203.bmp	1307918	167.3794	188.9964	213.0738	8.733275	0.563622	0.737994	4604	1.25
15	AF0204.bmp	1308417	173.9792	190.3067	216.6156	41.2969	0.555439	0.635198	4604	1.25

Gambar 2 menunjukkan evaluasi performa model untuk klasifikasi biji kopi berdasarkan tingkat perlakuan non-fermentasi, fermentasi 1, dan fermentasi 2 menunjukkan hasil yang beragam di antara empat model yang digunakan, yaitu Random Forest, KNN, SVM, dan Logistic Regression. Model Random Forest tampil sebagai model dengan performa paling konsisten. Pada kategori non-fermentasi, model ini berhasil mengklasifikasikan 120 sampel dengan benar, sementara 14 sampel salah diklasifikasikan sebagai Fermentasi 1, dan hanya 2 sampel salah diklasifikasikan sebagai Fermentasi 2. Untuk kategori Fermentasi 1, sebanyak 128 sampel berhasil diklasifikasikan dengan benar, dengan 10 sampel salah diklasifikasikan sebagai non-fermentasi dan tidak ada yang salah masuk ke Fermentasi 2. Sedangkan untuk Fermentasi 2, model ini hampir sempurna dengan 138 sampel diklasifikasikan dengan benar dan hanya 2 sampel salah masuk ke non-fermentasi.

Kinerja KNN menunjukkan bahwa model ini cukup baik, tetapi sedikit kurang akurat dibandingkan Random Forest. Pada kategori non-fermentasi, KNN mampu mengklasifikasikan 123 sampel dengan benar, namun terdapat 13 sampel yang salah diklasifikasikan sebagai Fermentasi 1. Kategori Fermentasi 1 menjadi tantangan bagi model ini, dengan 115 sampel diklasifikasikan dengan benar, tetapi 23 sampel salah masuk ke non-fermentasi. Untuk Fermentasi 2, model ini menunjukkan akurasi sempurna, dengan 140 sampel diklasifikasikan dengan benar tanpa kesalahan.

Sementara itu, model SVM memberikan performa yang cukup seimbang di semua kategori. Sebanyak 124 sampel pada kategori non-fermentasi berhasil diklasifikasikan dengan benar, sementara 12 sampel salah masuk ke Fermentasi 1. Pada kategori Fermentasi 1, sebanyak 122 sampel diklasifikasikan dengan benar, namun 16 sampel salah diklasifikasikan sebagai non-fermentasi. Sama seperti Random Forest dan KNN, SVM memiliki akurasi sempurna pada kategori Fermentasi 2 dengan 140 sampel diklasifikasikan dengan benar.

Logistic Regression menunjukkan performa yang kuat, terutama pada kategori non-fermentasi dan Fermentasi 1. Sebanyak 130 sampel pada kategori non-fermentasi berhasil diklasifikasikan dengan benar, dengan hanya 6 sampel salah diklasifikasikan sebagai Fermentasi 1. Pada kategori Fermentasi 1, Logistic Regression mengklasifikasikan 123 sampel dengan benar, sementara 15 sampel salah diklasifikasikan sebagai non-fermentasi. Sama seperti dua model lainnya, Logistic Regression juga memiliki akurasi sempurna pada kategori Fermentasi 2 dengan 140 sampel diklasifikasikan dengan benar.



**Gambar 2.** Evaluasi model

Tabel 2 di atas menampilkan metrik evaluasi Akurasi, Presisi, Recall, dan F1-Score untuk empat model pembelajaran mesin: Random Forest, K-Nearest Neighbors (KNN), Support Vector Machine (SVM), dan Logistic Regression. Metrik ini digunakan untuk menilai efektivitas masing-masing model dalam mengklasifikasikan data dan membantu dalam memilih model terbaik untuk diimplementasikan. Berdasarkan hasil evaluasi, model Logistic Regression menunjukkan kinerja terbaik dengan nilai akurasi tertinggi, yaitu 0,9493, yang berarti sekitar 94,93% dari data diklasifikasikan dengan benar. Model ini juga unggul dalam metrik lainnya, dengan nilai Presisi sebesar 0,9505, Recall sebesar 0,9493, dan F1-Score sebesar 0,9492. Nilai yang tinggi dan seimbang pada setiap metrik menunjukkan bahwa Logistic Regression memiliki kemampuan yang

baik dalam mengenali sampel positif serta mengurangi kesalahan klasifikasi negatif palsu, sehingga sangat cocok untuk tugas klasifikasi ini.

Sementara itu, model Random Forest dan SVM memiliki performa yang serupa dengan akurasi masing-masing sebesar 0,9324. Kedua model ini menunjukkan keseimbangan yang baik antara Presisi, Recall, dan F1-Score, yang masing-masing berada pada kisaran nilai 0,932. Hal ini menandakan bahwa baik Random Forest maupun SVM dapat diandalkan dan mampu memberikan hasil yang stabil. Random Forest mungkin lebih bermanfaat apabila interpretabilitas model diperlukan, sedangkan SVM bisa menjadi pilihan baik apabila tugas klasifikasi ini melibatkan batas keputusan yang kompleks di ruang berdimensi tinggi.

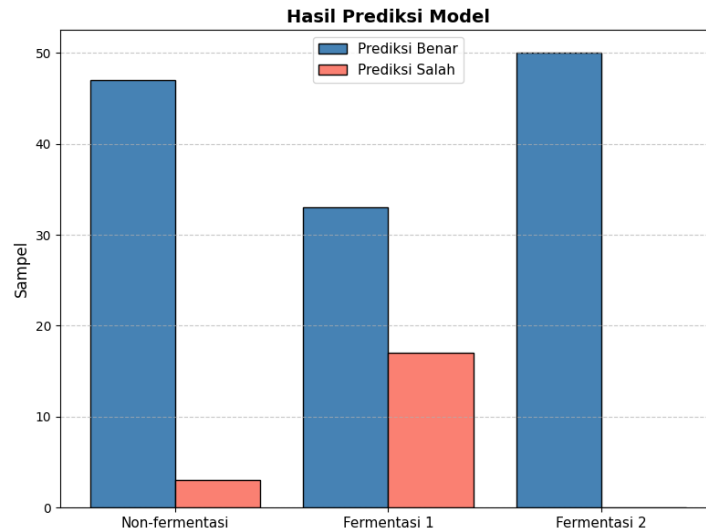
Di sisi lain, model KNN memiliki akurasi terendah, yaitu 0,9130, yang juga tercermin pada nilai Presisi, Recall, dan F1-Score yang sedikit lebih rendah dibandingkan model lainnya. Kinerja KNN yang lebih rendah ini mungkin disebabkan oleh sensitivitas model terhadap data yang mengandung noise atau ketidakseimbangan dalam kepadatan sampel. Meskipun demikian, KNN masih berguna untuk dataset non-linear dan mungkin dapat ditingkatkan lebih lanjut dengan melakukan tuning terhadap parameter jumlah tetangga (neighbors) yang optimal.

Secara keseluruhan, model Logistic Regression menjadi pilihan terbaik klasifikasi ini karena memiliki kinerja yang unggul pada semua metrik evaluasi. Random Forest dan SVM juga merupakan alternatif yang baik jika diperlukan karakteristik model tertentu, seperti interpretabilitas atau kemampuan menangani batas keputusan non-linear. Sementara itu, model KNN mungkin memerlukan penyesuaian lebih lanjut untuk mencapai kinerja yang lebih optimal. Temuan ini memberikan panduan yang berguna dalam pemilihan model untuk aplikasi praktis, dan konsistensi evaluasi pada metrik Akurasi, Presisi, Recall, dan F1-Score memastikan bahwa pemilihan model sejalan dengan tujuan klasifikasi yang diinginkan.

**Tabel 2.** Metrik agregat

No	Model	Accuracy	Precision	Recall	F1-Score
1	RandomForest	0.932367	0.932441	0.932367	0.932277
2	KNN	0.913043	0.914395	0.913043	0.912951
3	SVM	0.932367	0.932606	0.932367	0.932360
4	LogisticRegression	0.949275	0.950513	0.949275	0.949233

Grafik 3 menunjukkan performa model Logistic Regression dalam memprediksi kategori fermentasi kopi pada data baru. Model menunjukkan akurasi tinggi pada kategori non-fermentasi dan fermentasi 2, dengan mayoritas sampel diprediksi benar dan hanya sedikit atau tidak ada kesalahan prediksi. Sebaliknya, pada kategori fermentasi 1, terdapat jumlah kesalahan prediksi yang lebih tinggi dibandingkan prediksi benar, menunjukkan kesulitan model dalam membedakan kategori ini. Hal ini mengindikasikan bahwa kategori fermentasi 1 memiliki fitur yang lebih tumpang tindih dengan kategori lainnya, atau data pelatihan untuk kategori ini kurang representatif. Evaluasi lebih lanjut diperlukan untuk mengatasi kesalahan tersebut, seperti dengan menyeimbangkan data atau meningkatkan pemilihan fitur.



**Gambar 3.** Hasil prediksi

#### 4 KESIMPULAN

Klasifikasi kopi non-fermentasi dan fermentasi telah berhasil diterapkan. Model Logistic Regression menunjukkan performa terbaik dengan akurasi 94,93%, diikuti Random Forest dan SVM dengan akurasi 93,24%, serta KNN dengan 91,30%. Metode ini memberikan solusi cepat, akurat, dan efisien untuk evaluasi kualitas kopi.

#### DAFTAR PUSTAKA

- Adhitya, Y., Prakosa, S. W., Köppen, M., & Leu, J.-S. (2020). Feature Extraction for Cocoa Bean Digital Image Classification Prediction for Smart Farming Application. *Agronomy*, 10(11), 1642. <https://doi.org/10.3390/agronomy10111642>
- Bastian, F., Sinaga, H. L. R., Syarifuddin, A., & Hambali, A. (2024). Peningkatan cita rasa kopi robusta terdekafeinasi melalui fermentasi ulang menggunakan mucilage tiruan. *Agrointek: Jurnal Teknologi Industri Pertanian*, 18(3), 593–604. <https://doi.org/10.21107/agrointek.v18i3.18556>
- Elhalis, H., Cox, J., & Zhao, J. (2023). Coffee fermentation: Expedition from traditional to controlled process and perspectives for industrialization. *Applied Food Research*, 3(1), 100253. <https://doi.org/10.1016/j.afres.2022.100253>
- Evangelista, S. R., Miguel, M. G. D. C. P., Silva, C. F., Pinheiro, A. C. M., & Schwan, R. F. (2015). Microbiological diversity associated with the spontaneous wet method of coffee fermentation. *International Journal of Food Microbiology*, 210, 102–112. <https://doi.org/10.1016/j.ijfoodmicro.2015.06.008>
- Freitas, V. V., Borges, L. L. R., Vidigal, M. C. T. R., Dos Santos, M. H., & Stringheta, P. C. (2024). Coffee: A comprehensive overview of origin, market, and the quality process. *Trends in Food Science & Technology*, 146, 104411. <https://doi.org/10.1016/j.tifs.2024.104411>
- Juan Pablo Guerra & Francisco Cuevas. (2024). Application of Digital Image Processing Techniques for Agriculture: A Review. In Francisco Cuevas, Pier Luigi Mazzeo, & Alessandro Bruno (Eds.), *Digital Image Processing* (p. Ch. 2). IntechOpen. <https://doi.org/10.5772/intechopen.1004767>



- Nasution, L. R., Permata, Y. M., Keliat, J. M., Pelawi, M. A. T., Ciunardy, V. K., & Seruni, T. R. (2024). Fermentation Effects on Caffeine Content and Chemical Parameters of Kombucha Coffee Cascara. *International Journal of Applied Pharmaceutics*, 11–16. <https://doi.org/10.22159/ijap.2024v16s4.52252>
- Pawłowski, J., Kołodziej, M., & Majkowski, A. (2024). Implementing YOLO Convolutional Neural Network for Seed Size Detection. *Applied Sciences*, 14(14), 6294. <https://doi.org/10.3390/app14146294>
- Rahayuningtyas, A., Yulianti, L. E., Hidayat, D. D., Karim, M. A., Azizah, I. F., Desnilasari, D., Putri, D. P., Mayasti, N. K. I., Sagita, D., Yudhi, T., Witman, S., Warandi, R. R. A., Setyawan, A. B., Gandara, D., Furqon, M., Dharmawan, A., & Yusianto, Y. (2024). *Serbuk Kopi Robusta Rendah Kafein dengan Cita Rasa Buah dari Hasil Fermentasi dan Media Pembuatannya* (Patent P00202404935).
- Sabahannur, S., Syam, N., & Alimuddin, S. (2018). *Teknologi Fermentasi Biji Kakao* (1st ed.). IPB Press Printing.
- Saito, M. S., Dos Santos, W. A., & Mamede, M. E. D. O. (2024). Coffee-Flavoured Kombucha: Development, Physicochemical Characterisation, and Sensory Analysis. *Fermentation*, 10(7), 334. <https://doi.org/10.3390/fermentation10070334>
- Santoso, I., Yuanita, E., & Karomah, R. (2024). Application of digital image processing method for roasted coffee bean quality identification: A systematic literature review. *African Journal of Food, Agriculture, Nutrition and Development*, 24(1), 25264–25287. <https://doi.org/10.18697/ajfand.126.23410>
- Septiarini, A., Hamdani, H., Ery Burhandeny, A., Nurcahyono, D., & Eka Priyatna, S. (2024). Image analysis for classifying coffee bean quality using a multi feature and machine learning approach. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 13(4), 4241. <https://doi.org/10.11591/ijai.v13.i4.pp4241-4248>
- Statista. (2024). *Global coffee consumption 2021/21*. Statista. <https://www.statista.com/statistics/292595/global-coffee-consumption/>
- Tolentino Vaz, C. J., Douglas De Oliveira, M., Zotarelli, M. F., Guidini, C. Z., & Sentanin, M. A. (2024). Sensory profile of beverages produced from fermented coffee under different time and temperature conditions. *International Journal of Gastronomy and Food Science*, 38, 101016. <https://doi.org/10.1016/j.ijgfs.2024.101016>
- Tomar, N., Pradyumna, S., & Jain, J. (2024). Analysis of microscopic images using image processing to measure homogeneity of metal powder mixture samples. *Powder Technology*, 444, 119980. <https://doi.org/10.1016/j.powtec.2024.119980>
- Walke, S., Mandake, M., Tapre, R. W., Naniwadekar, M., Thakar, C., & Jadhav, S. D. (2023). Image Processing in Industrial Chemical Engineering Trends and Applications: In B. K. Pandey, D. Pandey, R. Anand, D. S. Mane, & V. K. Nassa (Eds.), *Advances in Computational Intelligence and Robotics* (pp. 348–363). IGI Global. <https://doi.org/10.4018/978-1-6684-8618-4.ch021>
- Wilkinson, M. R., Martinez-Hernandez, U., Wilson, C. C., & Castro-Dominguez, B. (2022). Images of chemical structures as molecular representations for deep learning. *Journal of Materials Research*, 37(14), 2293–2303. <https://doi.org/10.1557/s43578-022-00628-9>
- Zeng, X., Xiang, H., Yu, L., Wang, J., Li, K., Nussinov, R., & Cheng, F. (2022). Accurate prediction of molecular properties and drug targets using a self-supervised image representation learning framework. *Nature Machine Intelligence*, 4(11), 1004–1016. <https://doi.org/10.1038/s42256-022-00557-6>

