

Model Pengenalan Wajah Menggunakan Algoritma k-Nearest Neighbors

Rifa Hayatul Nisa¹, Iqbal², Imam Muslem³
^{1,2,3} Universitas Almuslim

ARTICLE INFO

Article history:

Received : 27 April 2026

Revised : 05 Mei 2026

Accepted : 05 Mei 2026

Keywords:

Face recognition, K-Nearest Neighbors, HOG, biometric classification, image processing



This work is licensed under a [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/)

Kata kunci:

Pengenalan wajah, K-Nearest Neighbors, HOG, klasifikasi biometrik, pengolahan citra

Corresponding Author:

Rifa Hayatul Nisa

Universitas Almuslim

Email:

rifahayatunisa23@gmail.com

ABSTRACT

[Face Recognition Model using k-Nearest Neighbors Algorithm]

This study explores the development of a face recognition model using the K-Nearest Neighbors (KNN) algorithm as a classification method in biometric systems. The dataset consists of 1,000 grayscale facial images sized 128x128 pixels, collected from 10 individuals with 100 images each. Feature extraction was conducted using the Histogram of Oriented Gradients (HOG) technique to capture distinctive facial characteristics. The experimental results show that the optimal k value is 4, producing a validation accuracy of 75.37%. Further testing achieved an accuracy of 81.37% with an average F1-score of 0.81, demonstrating reliable recognition performance. Live recognition tests confirmed that the system can still identify faces under real-world conditions, such as varied orientations and partial occlusions. These results indicate that KNN is an effective and efficient algorithm for small to medium-scale face recognition tasks, offering fast training time and practical applicability for biometric identification systems.

ABSTRAK

Penelitian ini berfokus pada pengembangan model pengenalan wajah dengan memanfaatkan algoritma *K-Nearest Neighbors* (KNN) sebagai metode klasifikasi dalam sistem biometrik. Dataset yang digunakan terdiri atas 1.000 citra wajah grayscale berukuran 128x128 piksel dari 10 individu, masing-masing dengan 100 citra. Proses ekstraksi fitur dilakukan menggunakan metode *Histogram of Oriented Gradients* (HOG) untuk menangkap karakteristik wajah yang khas. Hasil eksperimen menunjukkan bahwa nilai k optimal adalah 4 dengan akurasi validasi sebesar 75,37%. Uji lebih lanjut menghasilkan akurasi 81,37% dengan nilai rata-rata F1-score sebesar 0,81, yang membuktikan kemampuan model dalam membedakan identitas wajah secara cukup andal. Pengujian *live recognition* memperlihatkan bahwa sistem mampu mengenali wajah meskipun pada kondisi nyata dengan variasi sudut pandang maupun sebagian wajah tertutup. Temuan ini menegaskan bahwa algoritma KNN masih relevan, efektif, serta efisien untuk tugas pengenalan wajah pada dataset berskala kecil hingga menengah, dengan keunggulan waktu pelatihan yang cepat dan penerapan praktis pada sistem identifikasi.

PENDAHULUAN

Pengenalan wajah (*face recognition*) merupakan salah satu teknologi biometrik berbasis kecerdasan buatan yang digunakan untuk mengidentifikasi atau memverifikasi identitas seseorang berdasarkan karakteristik wajahnya [1], [2], [3], [4]. Teknologi ini telah berkembang pesat dalam beberapa tahun terakhir dan banyak diterapkan dalam berbagai bidang, seperti

sistem keamanan, absensi, hingga autentikasi digital [5], [6], [7]. Wajah sebagai identitas unik setiap individu menjadikan metode ini semakin relevan untuk meningkatkan efisiensi dan akurasi dalam proses identifikasi dibandingkan metode konvensional [8]. Seiring dengan meningkatnya kebutuhan sistem keamanan yang cepat dan akurat, pengembangan metode pengenalan wajah yang efektif menjadi topik penelitian yang penting.

Berbagai penelitian sebelumnya telah mengembangkan metode pengenalan wajah dengan pendekatan yang beragam, mulai dari teknik berbasis fitur hingga metode berbasis *deep learning* [9], [10], [11], [12]. Beberapa penelitian menggunakan algoritma seperti Principal Component Analysis (PCA) [13], Haar Cascade [14], hingga Convolutional Neural Network (CNN) [15], [16] untuk meningkatkan akurasi sistem pengenalan wajah. Meskipun metode berbasis *deep learning* mampu memberikan akurasi tinggi, pendekatan tersebut umumnya membutuhkan dataset yang besar serta sumber daya komputasi yang tinggi. Di sisi lain, algoritma K-Nearest Neighbors (KNN) menawarkan pendekatan yang lebih sederhana dan efisien, terutama pada dataset berukuran kecil hingga menengah [17]. Namun demikian, tantangan utama dalam pengenalan wajah masih berkaitan dengan variasi kondisi pencahayaan, sudut pandang, serta kemungkinan adanya *occlusion* (bagian wajah tertutup), yang dapat mempengaruhi performa sistem [18].

Berdasarkan tinjauan tersebut, dapat diidentifikasi bahwa masih terdapat kesenjangan penelitian dalam pengembangan metode pengenalan wajah yang ringan secara komputasi namun tetap mampu memberikan performa yang stabil pada kondisi nyata. Sebagian besar penelitian sebelumnya berfokus pada peningkatan akurasi menggunakan metode yang kompleks, sehingga kurang optimal untuk implementasi pada sistem dengan sumber daya terbatas atau skenario real-time. Oleh karena itu, diperlukan pendekatan alternatif yang lebih sederhana namun tetap mampu mempertahankan kinerja yang baik dalam kondisi variatif.

Penelitian ini memanfaatkan metode Histogram of Oriented Gradients (HOG) [19] sebagai teknik ekstraksi fitur untuk menangkap karakteristik wajah yang khas, serta algoritma K-Nearest Neighbors (KNN) sebagai metode klasifikasi. Pendekatan ini dipilih karena HOG mampu merepresentasikan fitur tekstur secara efektif, sedangkan KNN memiliki keunggulan dalam kemudahan implementasi serta waktu pelatihan yang cepat.

Tujuan penelitian ini adalah mengembangkan model pengenalan wajah berbasis kombinasi HOG dan KNN serta mengevaluasi performanya menggunakan metrik akurasi, precision, recall, dan F1-score. Adapun kontribusi utama dari penelitian ini adalah menunjukkan bahwa metode yang relatif sederhana tetap mampu memberikan performa yang cukup baik pada kondisi nyata, termasuk variasi sudut pandang dan *occlusion* wajah, sehingga dapat menjadi alternatif solusi yang efisien untuk sistem pengenalan wajah pada dataset berskala kecil hingga menengah.

METODE

Penelitian ini menggunakan pendekatan eksperimen berbasis pengolahan citra dan pembelajaran mesin untuk membangun sistem pengenalan wajah. Tahapan penelitian meliputi pengumpulan data, preprocessing, ekstraksi fitur, klasifikasi, serta evaluasi model. Dataset yang digunakan terdiri dari 1.000 citra wajah grayscale berukuran 128×128 piksel yang berasal dari 10 individu, masing-masing sebanyak 100 citra. Data kemudian dibagi menjadi data latih dan data uji dengan perbandingan 80:20 untuk memastikan model dapat diuji pada data yang belum pernah dilihat sebelumnya.

Pada tahap preprocessing, citra wajah dikonversi ke dalam bentuk grayscale dan dilakukan normalisasi untuk mengurangi pengaruh variasi pencahayaan. Selain itu, dilakukan proses deteksi wajah untuk memastikan bahwa area yang diproses merupakan bagian wajah yang relevan. Selanjutnya, proses ekstraksi fitur dilakukan menggunakan metode Histogram of Oriented Gradients (HOG). Metode ini bekerja dengan menghitung distribusi arah gradien pada setiap bagian citra sehingga mampu merepresentasikan karakteristik tekstur secara efektif. HOG

banyak digunakan dalam pengolahan citra karena kemampuannya dalam menangkap pola bentuk dan struktur objek secara lokal [8].

Proses klasifikasi dilakukan menggunakan algoritma K-Nearest Neighbors (KNN), yaitu metode klasifikasi berbasis jarak yang menentukan kelas suatu data berdasarkan kedekatannya dengan data lain dalam ruang fitur [7]. Pada penelitian ini digunakan beberapa variasi nilai k dari 1 hingga 10 untuk menentukan parameter terbaik. Pengukuran jarak antar data dilakukan menggunakan Euclidean distance. Evaluasi model dilakukan menggunakan metrik akurasi, precision, recall, dan F1-score untuk mengukur kinerja klasifikasi. Selain itu, digunakan confusion matrix untuk mengetahui distribusi kesalahan pada setiap kelas. Pengujian juga dilakukan secara real-time untuk melihat kemampuan model dalam mengenali wajah pada kondisi nyata, seperti variasi sudut pandang dan sebagian wajah yang tertutup.

HASIL DAN PEMBAHASAN

A. Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 1.000 citra wajah grayscale dengan ukuran 128×128 piksel yang terbagi ke dalam 10 kelas individu. Setiap kelas memiliki jumlah data yang relatif seimbang, yaitu sekitar 100 citra per individu. Distribusi data yang seimbang ini penting untuk menghindari bias pada model klasifikasi serta memastikan setiap kelas memiliki kontribusi yang setara dalam proses pelatihan.

Ekstraksi fitur dilakukan menggunakan metode Histogram of Oriented Gradients (HOG), yang mampu merepresentasikan karakteristik tekstur dan bentuk wajah secara lokal. Representasi fitur ini kemudian digunakan sebagai input pada algoritma K-Nearest Neighbors (KNN) dalam proses klasifikasi.

B. Nilai K terbaik

Penentuan nilai parameter k pada algoritma KNN dilakukan dengan menguji beberapa variasi nilai k dari 1 hingga 10. Hasil pengujian ditunjukkan pada Tabel 1.

Tabel 1. Hasil Pencarian k terbaik

Nilai K	Akurasi Validasi
1	73,40%
2	74,38%
3	73,40%
4	75,37%
5	73,40%
6	71,92%
7	72,91%
8	72,41%
9	71,43%
10	71,43%

Berdasarkan Tabel 1, nilai k=4 menghasilkan akurasi validasi tertinggi sebesar 75,37%. Hal ini menunjukkan bahwa pemilihan nilai k yang terlalu kecil cenderung membuat model sensitif terhadap noise, sedangkan nilai k yang terlalu besar menyebabkan model mempertimbangkan terlalu banyak tetangga yang tidak relevan. Oleh karena itu, nilai k=4 memberikan keseimbangan yang optimal antara bias dan variansi dalam proses klasifikasi [20], [21].

C. Evaluasi Model

Setelah diperoleh nilai k optimal, dilakukan pelatihan ulang menggunakan data latih dan evaluasi menggunakan data uji. Penggunaan data uji yang terpisah bertujuan untuk mengukur

kemampuan generalisasi model terhadap data yang belum pernah digunakan dalam proses pelatihan, sehingga hasil evaluasi lebih objektif.

D. Analisis Akurasi Model

Setelah proses pelatihan model dilakukan, tahap selanjutnya adalah evaluasi menggunakan data uji untuk mengukur kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya. Hasil evaluasi model ditunjukkan pada Gambar 1.

```
Evaluasi model dengan data test...

Hasil Evaluasi:
- Waktu Training: 0.00 detik
- Akurasi Test: 0.8137
```

Gambar 1. Hasil Evaluasi model

Berdasarkan Gambar 1, model memperoleh akurasi sebesar 0,8137 atau setara dengan 81,37%. Nilai ini menunjukkan bahwa model memiliki kemampuan yang cukup baik dalam mengenali wajah pada data uji. Selain itu, waktu pelatihan yang dihasilkan sangat singkat, yaitu sebesar 0,00 detik.

Waktu pelatihan yang sangat cepat ini disebabkan oleh karakteristik algoritma K-Nearest Neighbors (KNN) yang termasuk dalam kategori *lazy learning*, di mana proses pelatihan tidak melibatkan pembentukan model secara eksplisit, melainkan hanya menyimpan data latih untuk digunakan pada tahap klasifikasi [7].

Meskipun demikian, keunggulan pada waktu pelatihan tersebut memiliki konsekuensi pada tahap prediksi, di mana proses klasifikasi dapat menjadi lebih lambat seiring dengan bertambahnya jumlah data latih. Oleh karena itu, penggunaan algoritma KNN lebih sesuai untuk dataset dengan ukuran kecil hingga menengah.

E. Analisis Kinerja Model KNN

Hasil pengujian kinerja model K-Nearest Neighbors (KNN) berdasarkan metrik precision, recall, dan F1-score ditampilkan pada Tabel 2.

Tabel 2. Hasil evaluasi Kinerja KNN

Label	Precision	Recall	F1-Score	Jumlah Data (Support)
Aceng	0,45	0,70	0,55	20
Fasya	1,00	1,00	1,00	20
Han	0,67	0,84	0,74	19
Putri	0,95	1,00	0,98	20
Rifa	0,45	0,23	0,30	22
Rifki	1,00	1,00	1,00	26
Syifa	1,00	1,00	1,00	20
Ubay	1,00	0,67	0,80	15
Yatno	0,84	0,88	0,86	24
Zif	0,88	0,78	0,82	18
Rata-rata (Macro Avg)	0,82	0,81	0,81	—
Rata-rata (Weighted Avg)	0,82	0,81	0,81	204

Berdasarkan Tabel 2, dapat dilihat bahwa performa model bervariasi pada setiap kelas. Beberapa kelas seperti Fasya, Syifa, dan Rifki menunjukkan nilai precision, recall, dan F1-score yang sangat tinggi, bahkan mencapai nilai 1,00. Hal ini menunjukkan bahwa model mampu mengenali karakteristik wajah pada kelas tersebut dengan sangat baik. Tingginya performa ini

kemungkinan disebabkan oleh perbedaan fitur wajah yang cukup jelas dibandingkan dengan kelas lainnya, sehingga memudahkan proses klasifikasi.

Di sisi lain, terdapat kelas yang memiliki performa lebih rendah, seperti kelas Rifa dengan nilai recall sebesar 0,23 dan F1-score sebesar 0,30. Nilai recall yang rendah menunjukkan bahwa sebagian besar data pada kelas tersebut tidak berhasil dikenali dengan benar oleh model. Hal ini dapat disebabkan oleh kemiripan fitur wajah dengan kelas lain atau adanya variasi kondisi pencahayaan dan posisi wajah yang mempengaruhi proses ekstraksi fitur.


Selain itu, kelas Aceng juga menunjukkan nilai precision yang relatif rendah, yaitu 0,45. Hal ini mengindikasikan bahwa model sering melakukan kesalahan dengan mengklasifikasikan wajah dari kelas lain sebagai kelas Aceng. Kondisi ini menunjukkan bahwa distribusi fitur antar kelas belum sepenuhnya terpisah dengan baik dalam ruang fitur.

Secara keseluruhan, nilai rata-rata F1-score sebesar 0,81 menunjukkan bahwa model memiliki performa yang cukup baik dalam melakukan klasifikasi multi-kelas. Nilai ini mencerminkan keseimbangan antara precision dan recall, sehingga dapat disimpulkan bahwa model mampu bekerja secara cukup efektif dalam mengenali wajah pada dataset yang digunakan.

Hasil ini juga menunjukkan bahwa performa algoritma KNN sangat bergantung pada kualitas fitur yang dihasilkan serta distribusi data latih. Ketika terdapat kemiripan fitur antar kelas, maka kemungkinan terjadinya kesalahan klasifikasi akan meningkat. Oleh karena itu, peningkatan kualitas dataset atau penggunaan metode ekstraksi fitur yang lebih kompleks dapat menjadi solusi untuk meningkatkan performa model pada penelitian selanjutnya.

F. Analisis Confusion Matrix

Confusion matrix digunakan untuk menganalisis distribusi kesalahan klasifikasi yang dihasilkan oleh model. Hasil confusion matrix ditampilkan pada Gambar 4.



Gambar 4. Confusion Matrix

Berdasarkan Gambar 4, terlihat bahwa sebagian besar prediksi berada pada diagonal utama, yang menunjukkan bahwa model mampu mengklasifikasikan sebagian besar data dengan benar. Hal ini mengindikasikan bahwa model K-Nearest Neighbors (KNN) memiliki kemampuan yang cukup baik dalam membedakan karakteristik wajah pada dataset yang digunakan.

Namun demikian, masih terdapat beberapa kesalahan klasifikasi pada kelas tertentu. Sebagai contoh, pada kelas Fasya, sebagian besar data berhasil dikenali dengan benar, dengan hanya satu kesalahan klasifikasi ke kelas Putri. Hal ini menunjukkan bahwa fitur wajah pada kelas Fasya cukup mudah dikenali oleh model.

Sebaliknya, pada kelas Putri, tingkat kesalahan klasifikasi relatif lebih tinggi, di mana hanya sebagian data yang dikenali dengan benar, sementara sisanya salah diklasifikasikan ke kelas lain seperti Fasya dan Rifa. Hal ini mengindikasikan adanya kemiripan fitur visual antar kelas, yang menyebabkan model kesulitan dalam membedakan identitas secara akurat.

Selain itu, kelas Rifki menunjukkan performa yang sangat baik dengan sebagian besar data diklasifikasikan secara tepat. Hal serupa juga terlihat pada kelas Tania yang memiliki tingkat akurasi sangat tinggi. Kondisi ini menunjukkan bahwa distribusi fitur pada kelas tersebut cukup berbeda dibandingkan kelas lain, sehingga lebih mudah dipelajari oleh model.



Secara umum, kesalahan klasifikasi yang terjadi cenderung muncul pada kelas yang memiliki kemiripan fitur wajah atau pada kondisi citra yang kurang optimal, seperti pencahayaan yang tidak merata atau variasi posisi wajah. Hal ini menunjukkan bahwa performa algoritma KNN sangat bergantung pada kualitas fitur yang dihasilkan serta distribusi data dalam ruang fitur.

Dengan demikian, dapat disimpulkan bahwa model KNN mampu mengenali sebagian besar wajah dengan baik, namun masih memiliki keterbatasan dalam membedakan kelas dengan karakteristik yang mirip. Oleh karena itu, peningkatan kualitas dataset atau penggunaan metode ekstraksi fitur yang lebih kompleks dapat menjadi solusi untuk meningkatkan akurasi klasifikasi pada penelitian selanjutnya.

G. Pengujian Secara Live Recognition

Pengujian secara *live recognition* dilakukan untuk mengevaluasi kemampuan model dalam kondisi nyata, di mana wajah diuji secara langsung menggunakan kamera dengan berbagai variasi posisi dan kondisi. Hasil pengujian ditampilkan pada Tabel 3.

Tabel 3. Hasil Uji Live Recognition

Gambar Pengujian	Deskripsi
	Model Dapat Membaca wajah dan mendeteksi wajah dengan posisi objek terlihat jelas
	Model Dapat membaca wajah dan mendeteksi wajah dengan posisi objek menunduk



Berdasarkan hasil pengujian pada Tabel 3, model mampu mengenali wajah dengan baik pada beberapa kondisi, seperti posisi wajah normal, menunduk, menghadap ke atas, serta sebagian wajah tertutup. Hal ini menunjukkan bahwa model memiliki kemampuan yang cukup baik dalam menangani variasi orientasi wajah dan kondisi occlusion.

Kemampuan tersebut dipengaruhi oleh metode Histogram of Oriented Gradients (HOG) yang digunakan dalam ekstraksi fitur. HOG mampu menangkap karakteristik lokal dari citra wajah, sehingga tetap dapat mengenali pola penting meskipun terjadi perubahan posisi atau sebagian wajah tertutup [8].

Namun demikian, performa model dalam pengujian real-time masih memiliki keterbatasan. Pada kondisi tertentu, seperti pencahayaan yang tidak merata atau sudut wajah yang ekstrem, akurasi pengenalan dapat menurun. Selain itu, kemiripan fitur wajah antar individu juga dapat menyebabkan kesalahan klasifikasi.

Secara keseluruhan, hasil pengujian menunjukkan bahwa model berbasis KNN yang dikombinasikan dengan HOG cukup efektif untuk implementasi pengenalan wajah secara real-time pada dataset berskala kecil hingga menengah. Hal ini menunjukkan bahwa metode yang digunakan memiliki potensi untuk diterapkan pada sistem sederhana dengan kebutuhan komputasi yang rendah.

KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa model pengenalan wajah berbasis kombinasi Histogram of Oriented Gradients (HOG) dan K-Nearest Neighbors (KNN) mampu memberikan performa yang cukup baik dengan akurasi sebesar 81,37% pada data uji. Hasil ini menunjukkan bahwa algoritma KNN masih efektif digunakan dalam permasalahan klasifikasi wajah, khususnya pada dataset berskala kecil hingga menengah.

Pemilihan nilai parameter k terbukti berpengaruh terhadap kinerja model, di mana nilai k optimal diperoleh pada k=4 melalui proses pengujian terhadap beberapa variasi nilai k. Selain itu, karakteristik KNN sebagai metode *lazy learning* memberikan keunggulan pada waktu pelatihan yang sangat cepat, meskipun memiliki kelemahan pada tahap prediksi yang cenderung lebih lambat ketika jumlah data meningkat.

Hasil pengujian juga menunjukkan bahwa model mampu mengenali wajah dalam kondisi nyata dengan variasi posisi dan sebagian wajah tertutup, yang menunjukkan bahwa metode yang digunakan cukup robust terhadap perubahan orientasi dan kondisi citra. Hal ini

memperkuat bahwa kombinasi HOG dan KNN dapat menjadi solusi yang efisien untuk implementasi sistem pengenalan wajah sederhana.

Meskipun demikian, penelitian ini masih memiliki keterbatasan, terutama pada jumlah dataset yang relatif terbatas serta kemungkinan kemiripan fitur antar wajah yang dapat mempengaruhi akurasi klasifikasi. Oleh karena itu, penelitian selanjutnya dapat mengembangkan model dengan menggunakan dataset yang lebih besar atau mengkombinasikan metode yang lebih kompleks untuk meningkatkan performa dan ketahanan sistem.

REFERENCES

- [1] A. Pathak and S. Bhardwaj, "A systematic literature review on the fusion of face recognition and neuro-marketing," *SN Business & Economics*, vol. 6, no. 5, p. 129, 2026.
- [2] P. Dharnasi, "ATM access using card scanner and face recognition with AIML," *International Journal of Research Publications in Engineering, Technology and Management (IJRPETM)*, vol. 9, no. 1, pp. 113-118, 2026.
- [3] R. Saputra, I. Muslem, and R. Fajri, "Klasifikasi Spesies Ikan Koi Berdasarkan Citra Menggunakan Metode YOLOv3-Tiny Dan OpenCV," *Jurnal Ilmu Komputer Aceh*, vol. 3, no. 1, pp. 182-188, Feb. 2026.
- [4] V. Shakila, I. Muslem, and S. Sriwinar, "Prototipe Kamera Pengawasan Berbasis YOLOv5 untuk Deteksi Benda Tajam Secara Real-Time dengan Notifikasi Telegram," *Jurnal Ilmu Komputer Aceh*, vol. 3, no. 1, pp. 90-95, Feb. 2026.
- [5] J. S. Jeyanathan, C. T. A. Wise, O. A. Tom, C. Yogeswar, G. Sankeerth, and Y. D. Kumar, "Real-Time Intrusion Detection and Cloud-based Facial Recognition for Smart Home Security Systems," in *Emerging Perspectives and Applications of Computational Intelligence and Smart Systems*, CRC Press, 2026, pp. 174-178.
- [6] S. Ben Chaabane, R. Harrabi, and H. Seddik, "Home security system with hybrid face recognition approach using convolutional neural Networks, fuzzy Logic, and SVM classifier," *Multimed. Tools Appl.*, vol. 85, no. 2, p. 125, 2026.
- [7] S. Jothimani, K. Lavanya Devi, M. Madhumithra, R. Mahalakshmi, and N. Surya, "Advanced Secure Platform for Identity Recognition," *Proceedings Copyright*, vol. 782, p. 788.
- [8] J. Liu, X. Wang, and J. Liu, "The origin of cognitive modules for face processing: A computational evolutionary perspective," *Cognition*, vol. 266, p. 106341, 2026.
- [9] A. Agustiyar, R. R. Isnanto, and C. E. Widodo, "Face Recognition for Attendance Systems: A Bibliometric Review of Research Trends and Opportunities," *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, vol. 15, no. 01, pp. 8-13, 2026.
- [10] R. Kute, V. Vyas, and A. Anuse, "Transfer learning for face recognition using fingerprint biometrics," *Journal of King Saud University-Engineering Sciences*, vol. 38, no. 2, p. 16, 2026.
- [11] J. W. Hwang and A. B. J. Teoh, "Face Conditioning Periocular Recognition based on Asymmetrical Progressive Masked AutoEncoder," *Expert Syst. Appl.*, p. 131196, 2026.
- [12] J. Vijaya, S. Chandrakar, and P. Shrivastava, "A Comprehensive Review Concerning the Involvement of Artificial Intelligence Techniques in Face Recognition System," *Practical Applications of Smart Human-Computer Interaction*, pp. 69-110, 2026.
- [13] L. V. Nguyen, "PCA-Based Face Recognition Using Eigenfaces For Cheating Detection," *Data Science and Applications: Proceedings of ICDSA 2025, Volume 2*, vol. 2, p. 282, 2026.
- [14] M. Jaumitbaeva, S. Beknazarova, L. Mukhtarzhanovna, Q. Axmedov, and A. Abdukhalilov, "Algorithm for recognizing geometric objects in video images using the Haar Cascade method," in *Fifth International Conference on Optics, Computer Applications, and Materials Science (CMSD-V 2025)*, SPIE, 2026, pp. 166-172.
- [15] I. R. Muslem and T. M. Johan, "KLIK: Kajian Ilmiah Informatika dan Komputer Klasifikasi Citra Ikan Menggunakan Algoritma Convolutional Neural Network dengan Arsitektur VGG-16," *Media Online*, vol. 4, no. 2, pp. 978-985, 2023, doi: 10.30865/klik.v4i2.1209.
- [16] L. Luthfi, R. Imam Muslem, D. Armiady, S. Sriwinar, R. Fajri, and I. Iqbal, "Analysis of CNN Method for Image Classification of Coconut Ripeness Levels," in *2023 Eighth International Conference on Informatics and Computing (ICIC)*, IEEE, Dec. 2023, pp. 1-6. doi: 10.1109/ICIC60109.2023.10381964.

- [17] J. R. Velázquez-González and ..., "Unsupervised Outlier detection algorithm based on k-NN and fuzzy logic," ... *Autumn Meeting on* ..., 2019, [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/9057029/>
- [18] K. L. Davies, H. Ugail, and D. G. Stork, "Reassessing Anne Boleyn and other Boleyn women in Holbein drawings using facial recognition," *npj Heritage Science*, vol. 14, no. 1, p. 175, 2026.
- [19] F. Ahmed, "Hog-cnn: Integrating histogram of oriented gradients with convolutional neural networks for retinal image classification," *Journal of Imaging Informatics in Medicine*, pp. 1–16, 2026.
- [20] R. Melani, S. Sriwinar, D. Azmi, I. Muslem, and M. Amin, "Klasifikasi Kematangan Cabai Berdasarkan Citra Digital Menggunakan Algoritma K-Nearest Neighbor," *NOVAKOMPUTA: Jurnal Ilmu Komputer dan Informatika*, vol. 1, no. 1, pp. 30–42, 2026.
- [21] D. Fahmi, D. Azmi, I. Muslem, and P. B. N. Simangunsong, "Sistem Pendeteksi Dan Klasifikasi Jenis Hewan Ternak Menggunakan Metode You Only Look Once (YOLO)," *NOVAKOMPUTA: Jurnal Ilmu Komputer dan Informatika*, vol. 1, no. 1, pp. 43–51, 2026.