

KLASIFIKASI PENGENALAN WAJAH SISWA PADA SISTEM KEHADIRAN DENGAN MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)

Tommy Sarawan ¹, Kusrini ²

1,2) Magister Teknik Informatika, Universitas AMIKOM Yogyakarta

Article Info	ABSTRACT
<p>Article history:</p> <p>Received: 22 Januari 2025 Revised: 28 Januari 2025 Accepted: 07 Februari 2025</p>	<p style="text-align: center;">Abstrak</p> <p>Proses pengendalian kehadiran konvensional seringkali membutuhkan waktu yang lama dan rentan terhadap kesalahan oleh pengguna. Dari masalah tersebut, diperlukan inovasi untuk lebih meningkatkan sistem pengelolaan kehadiran yang lebih akurat, cepat, dan efisien. Pengenalan wajah yang memanfaatkan <i>Artificial Intelligence</i> saat ini merupakan teknologi yang populer dalam berbagai aplikasi khususnya dalam lingkup pendidikan. Penelitian ini akan menguji beberapa skenario untuk membuat model klasifikasi khusus pengenalan wajah siswa pada sistem presensi dengan memanfaatkan metode <i>Convolutional Neural Network</i> (CNN). Metode yang digunakan dalam membangun model diawali dengan pengumpulan data, <i>preprocessing</i> data, pembagian data, <i>augmentasi</i> data, <i>training</i> data dan <i>testing</i> data. Penelitian ini melakukan beberapa skenario pengujian dengan dengan membandingkan dua arsitektur yaitu <i>MobileNetV2</i> dan <i>ResNetV2</i>. Penelitian ini menyimpulkan bahwa melakukan retrain pada 50 <i>layers</i> akhir dan 4 <i>layers custom</i> dapat meningkatkan <i>accuracy</i> untuk arsitektur <i>MobileNetV2</i> mencapai 25% sedangkan <i>ResNetV2</i> mencapai 26%. Selain itu, skenario dua yang menggunakan arsitektur <i>MobileNetV2</i> menghasilkan model terbaik dengan nilai <i>precision</i> 92%, <i>recall</i> 91% dan <i>accuracy</i> 91%. Sistem presensi berbasis pengenalan wajah memiliki potensi besar untuk meningkatkan efisiensi dan akurasi pencatatan kehadiran siswa ditunjukkan dari hasil pengujian yang cukup baik.</p> <p>Kata Kunci: Klasifikasi, Pengenalan Wajah, CNN, <i>Transfer Learning</i>.</p> <p style="text-align: center;">Abstract</p> <p><i>The conventional attendance control process often takes a long time and is prone to user errors. To address this issue, innovation is needed to enhance the attendance management system to be more accurate, faster, and more efficient. Face recognition utilizing Artificial Intelligence has become a popular technology in various applications, particularly in the field of education. This study examines several scenarios to develop a specialized classification model for student face recognition in an attendance system using the Convolutional Neural Network (CNN) method. The model development process begins with data collection, data preprocessing, data splitting, data augmentation, data training, and data testing. This study conducts multiple testing scenarios by comparing two architectures: MobileNetV2 and ResNetV2. The results indicate that retraining the last 50 layers and adding 4 custom layers can improve the accuracy of the MobileNetV2 architecture by 25%, while ResNetV2 achieves a 26% increase. Furthermore, the second scenario, which utilizes the MobileNetV2 architecture, produced the best model with a precision of 92%, recall of 91%, and accuracy of 91%. The face recognition-based attendance system has significant potential to improve the efficiency and accuracy of student attendance recording, as demonstrated by the promising test results.</i></p> <p>Keywords: Classification, Face Recognition, CNN, <i>Transfer Learning</i>.</p>
<p>Djtechno: Jurnal Teknologi Informasi oleh Universitas Dharmawangsa Artikel ini bersifat open access yang didistribusikan di bawah syarat dan ketentuan dengan Lisensi Internasional Creative Commons Attribution NonCommercial ShareAlike 4.0 (CC-BY-NC-SA).</p>	

Corresponding Author:

E-mail : tommy@students.amikom.ac.id

1. PENDAHULUAN

Presensi merupakan bagian esensial dari pengelolaan pendidikan yang berfungsi sebagai indikator kedisiplinan siswa dan dasar evaluasi proses pembelajaran. Keberhasilan suatu proses pendidikan sangat bergantung pada efisiensi dan efektivitas pengelolaan administrasi, termasuk pengelolaan kehadiran siswa. Proses pengendalian kehadiran konvensional seringkali membutuhkan waktu yang lama dan rentan terhadap kesalahan oleh pengguna [1]. Dari masalah tersebut, diperlukan inovasi untuk lebih meningkatkan sistem pengelolaan kehadiran yang lebih akurat, cepat, dan efisien.

Sebelumnya telah dikembangkan sistem untuk mengatasi pencatatan kehadiran siswa seperti presensi berbasis sidik jari dan menggunakan kartu namun sistem tersebut sulit diintegrasikan dengan sistem utama yang telah berjalan seperti sistem akademik. Selain itu, presensi menggunakan kartu sangat rentan terhadap pemalsuan karena kartu dapat dengan mudah dipindah tangankan [2]. Pengenalan wajah menjadi salah satu teknologi yang populer dalam berbagai aplikasi khususnya dalam bidang pendidikan. Teknologi ini menawarkan solusi yang efisien dan inovatif untuk mengatasi tantangan dalam sistem kehadiran siswa. Oleh karena itu, integrasi teknologi pengenalan wajah dalam sistem kehadiran dapat menjadi alternatif yang lebih akurat dan praktis.

Perkembangan teknologi *Artificial Intelligence* (AI) mengalami lonjakan signifikan dalam beberapa dekade terakhir. *Artificial Intelligence*, sebagai bagian dari ilmu komputer yang dimanfaatkan untuk membuat sistem yang dapat melakukan fungsi yang menyerupai kecerdasan seseorang, seperti pengenalan terhadap pola, pengambilan keputusan, dan pembelajaran data [3]. *Deep learning*, cabang AI yang paling terkenal, menggunakan jaringan saraf tiruan untuk mengolah data yang kompleks seperti teks, gambar, dan suara [4].

Deteksi wajah adalah teknik klasifikasi pola dengan input gambar dan label gambar. Sebelum dilakukan proses pengenalan wajah, pendeteksian wajah adalah tahap awal yang sangat penting. Pemrosesan wajah yang mencakup pengenalan wajah, autentikasi wajah, lokalisasi wajah, penjejukan wajah, dan pengenalan ekspresi [5].

Deep learning bekerja melalui jaringan saraf tiruan yang mampu memahami pola kompleks dari data. Model *deep learning* seperti *Convolutional Neural Network* (CNN) sangat andal dalam pengolahan citra. CNN sangat baik dalam tugas pengenalan wajah, terutama dalam mengekstrak fitur dan mengklasifikasikan gambar. CNN secara otomatis dapat menemukan pola kompleks dalam data yang diambil dari gambar, yang membuatnya ideal untuk digunakan pada sistem pengenalan wajah [6]. Dalam konteks pengenalan wajah, membangun model klasifikasi sangatlah penting untuk memastikan akurasi sistem dalam mengenali wajah siswa. Model klasifikasi ini bertugas untuk membedakan antara wajah siswa yang terdaftar dan yang tidak terdaftar.

Dari pembahasan sebelumnya, maka peneliti akan membuat model klasifikasi yang bertujuan menggunakan metode *Convolutional Neural Network* (CNN) untuk mengidentifikasi wajah siswa pada sistem kehadiran. Diharapkan model ini dapat diterapkan pada sistem pencatatan kehadiran siswa untuk meningkatkan akurasi dan efisiensi sekaligus mengurangi tanggung jawab administrasi guru.

2. METODE PENELITIAN


Penelitian ini akan mengembangkan model klasifikasi menggunakan algoritma *Convolutional Neural Network* (CNN). Model klasifikasi ini bertugas untuk membedakan label pada gambar wajah siswa. Metode penelitian yang digunakan meliputi beberapa tahapan sebagai berikut:

Pengumpulan Data

Kekhawatiran tentang sistem pengenalan wajah mencakup privasi, keamanan data, dan efek psikologis dan etika. [7][8]. Untuk membangun model klasifikasi pengenalan wajah siswa akan menggunakan data publik sebagai dataset. Dataset yang digunakan merupakan gambar aktor *Hollywood* yang diperoleh dari <https://www.kaggle.com/datasets/vishesh1412/celebrity-face-image-dataset> yang menyediakan 16 aktor yang akan dianggap sebagai siswa dan masing-masing aktor memiliki 100 gambar.

Preprocessing Data

Setelah mendapatkan dataset, selanjutnya dilakukan proses *cropping* data untuk mendapatkan bagian wajah. Proses *cropping* dilakukan secara otomatis dengan menggunakan *Haar Cascade* yang merupakan metode untuk mengidentifikasi objek, terutama wajah yang diciptakan oleh *Paul Viola dan Michael Jones*[9]. Sebagai ilustrasi proses *cropping* diperlihatkan pada Gambar 1.



Gambar 1. Proses *Cropping*

Untuk mengatasi ketidakkonsistenan data atau data yang tidak valid, perlu dilakukan pembersihan data [10]. Pembersihan data dilakukan dengan menghapus gambar yang tidak sesuai, kualitas gambar yang rendah, serta gambar wajah yang terlalu muda. Berikut ilustrasi diperlihatkan pada Gambar 2.



Gambar 2. Pembersihan Data

Sebelumnya jumlah dataset sebanyak 1600 gambar yang terbagi kedalam 16 kelas dan masing-masing kelas sebanyak 100 gambar. Setelah melakukan pembersihan pada 336 gambar, jumlah data menjadi 1264 gambar dan masing-masing kelas memiliki jumlah yang bervariasi. Diketahui, kelas dengan jumlah data terbesar adalah 85 gambar dan data terkecil adalah 70 gambar sehingga untuk menyamakan jumlah data pada setiap kelas digunakan 70 gambar untuk proses selanjutnya.

Pembagian Data

Proses ini bertujuan untuk membagi dataset menjadi dua yaitu data latih dan data uji. dataset dibagi menjadi 50 data latih dan 20 data uji yang disimpan kedalam *google drive*. Berikut contoh pembagian data diperlihatkan pada Gambar 3



Gambar 3. Pembagian Data

Augmentasi Data

Tujuan dari augmentasi data adalah untuk memperluas variasi data dan memperluas generalisasi model *deep learning* [11]. Pada penelitian ini, augmentasi dilakukan secara otomatis menggunakan *tensorflow* yang merupakan *library python* yang dijalankan di *google colab*. Augmentasi yang dilakukan meliputi “*rotation_range=30*” untuk memutar gambar secara acak dalam rentang 30 derajat, “*width_shift_range=0.2*” untuk menggeser gambar secara horizontal hingga 20% dari lebar gambar, “*height_shift_range=0.2*” untuk menggeser gambar secara vertikal hingga 20% dari tinggi gambar, “*shear_range=0.2*” untuk menerapkan transformasi shear (geser sudut) hingga 20%, “*zoom_range=0.2*” untuk memperbesar atau memperkecil gambar hingga 20%, “*horizontal_flip=True*” untuk membalik gambar secara horizontal secara acak, dan yang terakhir “*fill_mode='nearest'*” untuk mengisi area kosong dengan *pixel* terdekat akibat augmentasi sebelumnya.

Skenario Pengujian

Ekperimen yang dilakukan oleh [12] dengan arsitektur *VGG16*, *VGG19*, *ResNet50*, *ResNet101* dan *MobileNetV2*, menyimpulkan bahwa arsitektur *MobileNetV2* menghasilkan akurasi terbaik untuk pengenalan wajah pengguna masker dengan akurasi mencapai 99,82%. Eksperimen yang dilakukan oleh [13] dengan arsitektur *AlexNet*, *VGG16*, *MobileNet V2*, *InceptionV2*, dan *ResNetV2* menyimpulkan bahwa arsitektur *ResNetV2* dan *MobileNetV2* menghasilkan akurasi yang cukup baik dalam melakukan deteksi wajah dengan akurasi *ResNetV2* 90,49% dan *MobileNetV2* 89,18%. Berdasarkan hasil penelitian terdahulu peneliti dalam upaya untuk mendapatkan model dengan akurasi terbaik, dilakukan beberapa skenario pengujian dengan membandingkan dua arsitektur yaitu *MobileNetV2* dan *ResNetV2*. *Fine-tuning* dilakukan pada masing-masing arsitektur untuk melakukan klasifikasi sesuai dengan jumlah siswa yang dilatih. Proses *training* dilakukan dengan dua skenario yang pertama hanya melakukan *training* pada *layer custom* hasil *fine-tuning* tanpa melakukan *retrain layer* arsitektur dan yang kedua melakukan *retrain* pada beberapa *layer* terakhir arsitektur beserta *layer custom* hasil *fine-tuning*. Skenario pengujian diperlihatkan pada tabel 1 berikut.

Tabel 1. Bobot kriteria

Skenario	Arsitektur	Retrain arsitektur	Epoch
S1	MobileNetV2	False	100
S2	MobileNetV2	-50	100
S3	ResNetV2	False	100
S4	ResNetV2	-50	100

Stelah melalui proses di atas, selanjutnya dilakukan proses *training* dan *testing* sesuai dengan skenario pengujian. Setiap skenario menggunakan 100 *epoch*, 50 data latih

Gambar 5. Confusion Matrix Skenario Satu

Classification Report:


	precision	recall	f1-score	support
Siswa_001	1.00	0.55	0.71	20
Siswa_002	0.79	0.55	0.65	20
Siswa_003	0.71	1.00	0.83	20
Siswa_004	0.65	0.65	0.65	20
Siswa_005	0.61	0.55	0.58	20
Siswa_006	0.93	0.65	0.76	20
Siswa_007	0.56	0.90	0.69	20
Siswa_008	0.52	0.55	0.54	20
Siswa_009	0.53	0.95	0.68	20
Siswa_010	0.71	0.50	0.59	20
Siswa_011	0.61	0.70	0.65	20
Siswa_012	0.82	0.45	0.58	20
Siswa_013	0.87	0.65	0.74	20
Siswa_014	0.55	0.55	0.55	20
Siswa_015	0.50	0.75	0.60	20
Siswa_016	1.00	0.65	0.79	20
accuracy			0.66	320
macro avg	0.71	0.66	0.66	320
weighted avg	0.71	0.66	0.66	320

Gambar 6. Classification Report Skenario Satu

Gambar 6 menunjukkan hasil testing untuk model skenario satu mendapat nilai *accuracy* 66%, *precision* 71% dan *recall* 66%.


Skenario Dua

Skenario dua menggunakan arsitektur *MobileNetV2* yang memiliki 154 *layers* ditambah dengan 4 *layers custom* hasil *fine-tuning*. Proses training dilakukan untuk 50 *layers* akhir dan 4 *layers custom* dengan menggunakan 100 epoch dan ukuran gambar 224 x 224 pixel. Hasil training diperlihatkan pada Gambar 7.



Gambar 7. Proses Training Skenario Dua

Gambar 7 menunjukkan *accuracy* trainig mencapai 99% dan *accuracy* validasi mencapai 91%. Selanjutnya hasil testing digambarkan dalam confusion matrix pada gambar 8 dan dijelaskan dengan classification report pada gambar 9.



Gambar 8. Confusion Matrix Skenario Dua

Classification Report:


	precision	recall	f1-score	support
Siswa_001	0.83	1.00	0.91	20
Siswa_002	0.82	0.90	0.86	20
Siswa_003	1.00	0.95	0.97	20
Siswa_004	1.00	0.90	0.95	20
Siswa_005	0.90	0.95	0.93	20
Siswa_006	0.82	0.90	0.86	20
Siswa_007	0.74	1.00	0.85	20
Siswa_008	1.00	0.65	0.79	20
Siswa_009	0.95	1.00	0.98	20
Siswa_010	0.94	0.80	0.86	20
Siswa_011	1.00	0.65	0.79	20
Siswa_012	0.95	0.90	0.92	20
Siswa_013	0.95	1.00	0.98	20
Siswa_014	0.90	0.95	0.93	20
Siswa_015	0.95	1.00	0.98	20
Siswa_016	0.95	1.00	0.98	20
accuracy			0.91	320
macro avg	0.92	0.91	0.91	320
weighted avg	0.92	0.91	0.91	320

Gambar 9. Classification Report Skenario Dua

Gambar 9 menunjukkan hasil testing untuk model skenario dua mendapat nilai accuracy 91%, precision 92% dan recall 91%.


Skenario Tiga

Skenario tiga menggunakan arsitektur ResNetV2 yang memiliki 780 layers ditambah dengan 4 layers custom hasil fine-tuning. Proses training hanya dilakukan untuk 4 layers custom dengan menggunakan 100 epoch dan ukuran gambar 160 x 160 pixel. Hasil training diperlihatkan pada Gambar 10.



Gambar 10. Proses Training Skenario Tiga

Gambar 10 menunjukkan accuracy trainig mencapai 57% dan accuracy validasi mencapai 63%. Selanjutnya hasil testing digambarkan dalam confusion matrix pada gambar 11 dan dijelaskan dengan classification report pada gambar 12.



Gambar 11. Confusion Matrix Skenario Tiga

Classification Report:


	precision	recall	f1-score	support
Siswa_001	0.50	0.65	0.57	20
Siswa_002	0.50	0.80	0.62	20
Siswa_003	0.75	0.75	0.75	20
Siswa_004	0.75	0.75	0.75	20
Siswa_005	0.54	0.65	0.59	20
Siswa_006	0.93	0.70	0.80	20
Siswa_007	0.52	0.65	0.58	20
Siswa_008	0.82	0.70	0.76	20
Siswa_009	0.53	0.80	0.64	20
Siswa_010	0.71	0.50	0.59	20
Siswa_011	0.53	0.40	0.46	20
Siswa_012	0.67	0.60	0.63	20
Siswa_013	0.53	0.45	0.49	20
Siswa_014	0.50	0.25	0.33	20
Siswa_015	0.67	0.80	0.73	20
Siswa_016	1.00	0.65	0.79	20
accuracy			0.63	320
macro avg	0.65	0.63	0.63	320
weighted avg	0.65	0.63	0.63	320

Gambar 12. Classification Report Skenario Tiga

Gambar 12 menunjukkan hasil testing untuk model skenario tiga mendapat nilai accuracy 63%, precision 65% dan recall 63%.


Skenario Empat

Skenario empat menggunakan arsitektur ResNetV2 yang memiliki 780 layers ditambah dengan 4 layers custom hasil fine-tuning. Proses training dilakukan untuk 50 layers akhir dan 4 layers custom dengan menggunakan 100 epoch dan ukuran gambar 160 x 160 pixel. Hasil training diperlihatkan pada Gambar13.



Gambar 13. Proses Training Skenario Empat

Gambar 13 menunjukkan accuracy trainig mencapai 98% dan accuracy validasi mencapai 89%. Selanjutnya hasil testing digambarkan dalam confusion matrix pada gambar 14 dan dijelaskan dengan classification report pada gambar 15.



Gambar 14. Confusion Matrix Skenario Empat

Classification Report:				
	precision	recall	f1-score	support
Siswa_001	0.81	0.85	0.83	20
Siswa_002	0.95	0.90	0.92	20
Siswa_003	0.95	0.95	0.95	20
Siswa_004	0.91	1.00	0.95	20
Siswa_005	1.00	0.85	0.92	20
Siswa_006	0.89	0.80	0.84	20
Siswa_007	0.76	0.80	0.78	20
Siswa_008	1.00	0.95	0.97	20
Siswa_009	0.95	0.95	0.95	20
Siswa_010	0.75	0.90	0.82	20
Siswa_011	0.94	0.85	0.89	20
Siswa_012	0.86	0.90	0.88	20
Siswa_013	0.89	0.85	0.87	20
Siswa_014	0.76	0.80	0.78	20
Siswa_015	0.95	0.95	0.95	20
Siswa_016	1.00	1.00	1.00	20
accuracy			0.89	320
macro avg	0.90	0.89	0.89	320
weighted avg	0.90	0.89	0.89	320

Gambar 15. Classification Report Skenario Empat

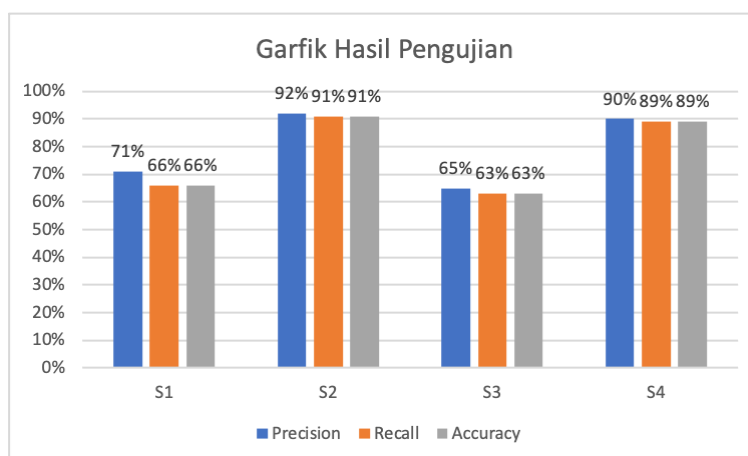
Gambar 15 menunjukkan hasil testing untuk model skenario empat mendapat nilai *accuracy* 89%, *precision* 90% dan *recall* 89%.

Hasil Evaluasi

Untuk mendapatkan model dengan akurasi terbaik nilai *precision*, *recall* dan *accuracy* hasil pengujian semua skenario akan dibandingkan. Hasil pengujian untuk semua skenario diperlihatkan pada tabel 2 dan gambar 16.

Tabel 2. Hasil Pengujian Penerapan Algoritma CNN

Skenario	Precision	Recall	Accuracy
S1	71%	66%	66%
S2	92%	91%	91%
S3	65%	63%	63%
S4	90%	89%	89%



Gambar 16. Grafik Hasil Pengujian Algoritma CNN

Model klasifikasi wajah siswa yang dibangun dengan empat skenario, diketahui skenario dua mendapatkan hasil *precision*, *recall* dan *accuracy* yang lebih unggul yaitu

precision 92%, *recall* 91% dan *accuracy* 91%. Skenario terendah adalah skenario tiga dengan nilai *precision* 65%, *recall* 63% dan *accuracy* 63%.

4. SIMPULAN

Pada penelitian ini kami telah melakukan klasifikasi 320 gambar wajah yang terbagi dalam 16 kelas menggunakan model CNN yang dibangun menggunakan metode transfer learning dan *fine-tuning*. Berdasarkan skenario pengujian dapat disimpulkan bahwa melakukan retrain pada 50 *layers* akhir dan 4 *layers custom* dapat meningkatkan *accuracy* untuk arsitektur *MobileNetV2* mencapai 25% sedangkan ResNetV2 mencapai 26%. Selain itu, skenario dua yang menggunakan arsitektur *MobileNetV2* menghasilkan model terbaik dengan nilai *precision* 92%, *recall* 91% dan *accuracy* 91%.

Penerapan model *deep learning* dalam sistem presensi berbasis pengenalan wajah memiliki potensi besar untuk meningkatkan efisiensi dan akurasi pencatatan kehadiran siswa ditunjukkan dari hasil pengujian yang cukup baik. Namun, beberapa keterbatasan penelitian ini harus dipertimbangkan seperti ukuran dataset yang relatif kecil yang dapat mempengaruhi generalisasi model terhadap variasi wajah yang lebih luas seperti perubahan pencahayaan, ekspresi wajah, atau aksesoris yang digunakan oleh siswa. Oleh karena itu, studi lanjutan merekomendasikan penggunaan dataset yang lebih besar dan beragam, serta mengeksplorasi teknik regularisasi guna meningkatkan kemampuan generalisasi model. Selain itu, evaluasi performa model dalam kondisi nyata perlu dilakukan untuk memastikan keandalan sistem presensi dalam berbagai skenario penggunaan.

REFERENCES

- [1] R. V. Talumepa, D. A. Putra, and H. Soetanto, "Sistem Presensi Pendeteksi Wajah menggunakan Metode Modified Region Convolutional Neural Network dan PCA," *Edumatic J. Pendidik. Inform.*, vol. 8, no. 1, pp. 46–55, 2024, doi: 10.29408/edumatic.v8i1.25207.
- [2] Miftakhurrokhmat, R. A. Rajagede, and R. Rahmadi, "Presensi Kelas Berbasis Pola Wajah, Senyum dan Wi-Fi Terdekat dengan Deep Learning," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 1, no. 10, pp. 31–38, 2021.
- [3] L. P. A. S. Tjahyanti, P. S. Saputra, and M. S. Gitakarma, "Peran Artificial Intelligence (Ai) Untuk Mendukung Pembelajaran di Masa Pandemi Covid-19," *J. Komput. dan Teknol. Sains*, vol. 1, no. 1, pp. 15–21, 2022.
- [4] S. F. Ahmed *et al.*, *Deep learning modelling techniques : current progress , applications , advantages , and challenges*, vol. 56, no. 11. Springer Netherlands, 2023.
- [5] E. Tarigan, R. S. Naibaho, and A. Satria, "Pengenalan Wajah Menggunakan Metode Viola Jones Dengan Menggunakan Aplikasi Matlab 2015," *Djtechno J. Teknol. Inf.*, vol. 4, no. 1, pp. 82–89, 2023, doi: 10.46576/djtechno.
- [6] I. N. G. A. Astawa, M. L. Radhitya, I. W. R. Ardana, and F. A. Dwiyanto, "Face Images Classification using VGG-CNN," *Knowl. Eng. Data Sci.*, vol. 4, no. 1, pp. 49–54, 2021.
- [7] D. Razaqa, M. R. Al Maghribi, N. D. Gunasti, and T. Wati, "Analisis Etika dan Dampak Penggunaan Sistem Pengenalan Wajah untuk Manajemen Kehadiran di Lingkungan Sekolah," *J. Inform.*, vol. 20, no. 2, pp. 50–57, 2024.
- [8] R. Rambe and L. Abdurrahman, "Implikasi Etika dan Hukum Dalam Penggunaan Teknologi Pengenalan Wajah: Perlindungan Privasi Versus Keamanan Publik," *J. Huk. Caraka Justitia*, vol. 4,

- no. 2, pp. 90–104, 2024, doi: <https://doi.org/10.30588/jhcj.v4i2.1828>.
- [9] G. A. Anarki, K. Auliasari, and M. Orisa, "Penerapan Metode Haar Cascade pada Aplikasi Deteksi Masker," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 5, no. 1, pp. 179–186, 2021.
- [10] V. Varkarakis and P. Corcoran, "Dataset Cleaning - A Cross Validation Methodology for Large Facial Datasets using Face Recognition," *IEEE Access*, pp. 0–5, 2020.
- [11] I. A. DLY, Jasril, S. Sanjaya, L. Handayani, and F. Yanto, "Klasifikasi Citra Daging Sapi dan Babi Menggunakan CNN Alexnet dan Augmentasi Data," *J. Inf. Syst. Res.*, vol. 4, no. 4, pp. 1176–1185, 2023, doi: 10.47065/josh.v4i4.3702.
- [12] R. K. Shukla and A. K. Tiwari, "Masked Face Recognition Using MobileNet V2 with Transfer Learning," *Comput. Syst. Sci. Eng.*, vol. 45, no. 1, pp. 293–309, 2023, doi: 10.32604/csse.2023.027986.
- [13] M. A. S. Ai *et al.*, "Real-Time Facemask Detection for Preventing COVID-19 Spread Using Transfer Learning Based Deep Neural Network," *Electronics*, vol. 11, no. 14, pp. 1–21, 2022, doi: 10.3390/electronics11142250.
- [14] A. Rahim and K. Kusriani, "Convolutional Neural Network untuk Kalasifikasi Penggunaan Masker," *Inspir. J. Teknol. Inf. dan Komun.*, vol. 10, no. 2, pp. 109–115, 2021, doi: 10.35585/inspir.v10i2.2569.