



A CNN Model for Recognizing Facial Expressions in Programming Classes under Classroom Occlusions

Model CNN untuk Pengenalan Ekspresi Wajah pada Pembelajaran Pemrograman dengan Kondisi Oklusi di Kelas

Baharuddin^{1*}, Muh. Wahyu Suryandi Adam², Annahl Riadi³

^{1,2,3}Department of Informatics, Universitas Ichsan Sidenreng Rappang, Indonesia

E-Mail: ¹baharanthyqu@gmail.com, ²muh.wahyu.suryandi@gmail.com, ³annahlriadi@gmail.com

Received Aug 26th 2025; Revised Sep 24th 2025; Accepted Oct 25th 2025; Available Online Oct 31th 2025

Corresponding Author: Baharuddin

Copyright © 2025 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

Students' facial expressions are non-verbal indicators that can be leveraged by Learning Analytics (LA) to monitor engagement and confusion during a programming course (programming class). In this study, LA denotes a computational process that analyzes visual data (facial expressions) to provide actionable information for instructors and learning-support systems, either in near real time or post-class. We investigate facial-expression recognition under real classroom conditions with substantial occlusions (monitor screens, bags, hands, masks, peers), employing a CNN based on EfficientNet-B3 with transfer learning and fine-tuning to classify four categories: Saturated, Normal, Happy, and Confused. Evaluation uses accuracy, macro-precision, macro-recall, macro-F1, and the confusion matrix. On the test set, the model achieves 33.33% accuracy, 0.33 macro-precision, 0.33 macro-recall, and 0.32 macro-F1, underscoring the challenges posed by occlusions and limited data. Validation accuracy (26.67%) and training accuracy (45.31%) indicate underfitting and inter-class confusion, particularly among Normal, Happy, and Confused. Despite the modest metrics, the study provides a replicable baseline for occlusion-aware classroom FER in programming education. We outline actionable directions for improvement, data expansion, and balancing, occlusion-specific augmentation, face alignment, and lightweight attention/occlusion-handling modules toward more robust classroom LA.

Keyword: CNN, Expression, Face, Programming, Student

Abstrak

Ekspresi wajah mahasiswa merupakan indikator non-verbal yang dapat dimanfaatkan oleh *Learning Analytics* (LA) untuk memantau keterlibatan dan kebingungan selama mata kuliah pemrograman (*programming class*). Dalam konteks riset ini, LA merujuk pada proses komputasional yang menganalisis data visual (ekspresi wajah) guna menyediakan informasi bagi pengajar dan sistem pendukung pembelajaran, baik secara waktu nyata maupun pascakelas. Kami meneliti pengenalan ekspresi wajah pada kondisi kelas nyata yang sarat oklusi (layar monitor, tas, tangan, masker, rekan mahasiswa), menggunakan CNN EfficientNet-B3 dengan *transfer learning* dan *fine-tuning* untuk mengklasifikasi empat kategori: Jenuh, Normal, Senang, dan Bingung. Evaluasi menggunakan akurasi, presisi-makro, *recall*-makro, *F1*-makro, serta *confusion matrix*. Pada test set, model meraih 33,33% akurasi, 0,33 presisi-makro, 0,33 *recall*-makro, dan 0,32 *F1*-makro, menegaskan tantangan pengenalan di bawah oklusi dan keterbatasan data. Akurasi validasi (26,67%) dan akurasi latih (45,31%) menunjukkan model belum cukup belajar dan terjadi kebingungan antarkelas khususnya antara Normal, Senang, dan Bingung. Meski metrik masih moderat, studi ini menyediakan *baseline* yang dapat direplikasi untuk FER tanggap oklusi pada konteks pendidikan pemrograman. Arah peningkatan mencakup penambahan & penyeimbangan data, augmentasi spesifik oklusi, *face alignment*, serta modul atensi/penanganan oklusi ringan menuju LA yang lebih tangguh di kelas nyata.

Kata Kunci: CNN, Ekspresi, Mahasiswa, Pemrograman, Wajah

1. PENDAHULUAN

Pembelajaran pemrograman merupakan salah satu bidang yang secara umum menantang dan menuntut tingkat kognisi tinggi dari mahasiswa. Kesulitan dalam memahami konsep logika, debugging, dan sintaks dapat menimbulkan kebingungan, kejenuhan, bahkan frustrasi pada mahasiswa [1]. Pengenalan

ekspresi wajah mahasiswa yang belajar pemrograman merupakan solusi menarik untuk meningkatkan efektivitas pembelajaran. Wajah merupakan salah satu media komunikasi yang paling alami dan universal [2][3]. Ekspresi wajah merupakan salah satu bentuk komunikasi non-verbal yang paling alami dan kuat dalam menyampaikan emosi manusia [4][5]. Dalam konteks pembelajaran, ekspresi seperti bingung, konsentrasi/netral, Jenuh, atau senang dapat menjadi indikator penting terhadap tingkat pemahaman dan keterlibatan mahasiswa. Deteksi emosi berdasarkan ekspresi wajah dapat memberikan umpan balik instan kepada pendidik untuk menyesuaikan pendekatan pengajaran secara lebih personal. Kondisi emosional ini tidak selalu dapat terdeteksi secara eksplisit oleh dosen, terutama dalam kelas atau laboratorium komputer. Permasalahan penelitian ini adalah bagaimana mengenali ekspresi wajah mahasiswa di kelas/laboratorium pemrograman ketika wajah teroklusi oleh objek seperti monitor, masker, tas, tangan, atau rekan mahasiswa yang menutupi ciri visual kunci. Akibatnya, kondisi emosional mahasiswa tidak selalu dapat teramati secara eksplisit oleh dosen selama pembelajaran. Oleh karena itu, diperlukan pengembangan sistem pengenalan ekspresi wajah yang tangguh terhadap oklusi untuk mendukung proses pembelajaran yang lebih adaptif dan responsif terhadap kebutuhan individu.

Perkembangan teknologi *computer vision* dan *deep learning*, khususnya *Convolutional Neural Network* (CNN), telah membuka peluang besar dalam otomatisasi pengenalan ekspresi wajah. CNN dikenal sangat efektif dalam mengekstraksi fitur spasial dari citra wajah dan telah menunjukkan performa tinggi dalam berbagai tugas klasifikasi citra, termasuk pengenalan emosi. Metode tradisional umumnya mengandalkan fitur buatan tangan seperti *Local Binary Patterns* (LBP), *Gabor filter*, dan *Histogram of Oriented Gradients* (HOG) yang kemudian diklasifikasikan dengan *Support Vector Machine* (SVM)/ *k-Nearest Neighbors* (k-NN). Dibandingkan metode tradisional, CNN menawarkan kemampuan pembelajaran representasi fitur yang lebih kompleks, serta fleksibilitas dalam menangani variasi wajah, pencahayaan, dan sudut pandang.

Permasalahan yang terjadi yaitu pengenalan ekspresi wajah memiliki tingkat akurasi yang belum maksimal[6]. Selain itu, Model verifikasi wajah berbasis *deep learning* akurat di lingkungan terkendali (pencahayaan seragam, wajah frontal) tetapi memerlukan perbaikan di lingkungan tidak terkendali (*Closed-Circuit Television* (CCTV) kelas dengan oklusi, variasi pencahayaan, dan pose)[7]. Ekspresi wajah mahasiswa dalam kondisi oklusi dikelas dan saat menghadapi sintaks error, debugging, atau saat berhasil menjalankan program mengandung dinamika emosional yang khas dan belum banyak dieksplorasi dalam penelitian terdahulu.

Mengenali data wajah yang tidak sempurna dengan adanya oklusi bukanlah pekerjaan yang mudah[8]. Selain itu, tantangan dalam CNN tetap ada, khususnya dalam penanganan oklusi, optimasi model, mengatasi *overfitting*, dan pemilihan algoritma pelatihan yang tepat yang masih menjadi kendala untuk mencapai performa terbaik[9]. Penelitian tentang pengenalan ekspresi wajah telah banyak dilakukan oleh peneliti sebelumnya [10] [11][12][13][14].Pengenalan wajah dengan kendala oklusi juga menjadi tantangan dalam Pengenalan Wajah[15][16]. Beragam arsitektur CNN telah dieksplorasi dan menunjukkan kemampuan yang kuat dalam pengenalan wajah [17] dan mengklasifikasikan berbagai kondisi emosional dari citra wajah. Model *deep learning*, terutama pendekatan berbasis CNN, secara konsisten menunjukkan kinerja superior dibandingkan metode tradisional dalam tugas pengenalan ekspresi wajah [9][11]. Dalam penelitian Richard Steven Immanuel Sihombing dkk, tahun 2023[20] dalam Pengenalan Ekspresi Wajah Menggunakan CNN, hasilnya menunjukkan model mampu mengenali ekspresi wajah dengan akurasi 78% pada data uji. CNN dinyatakan berkinerja terbaik dalam mengkategorikan emosi[2].

Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi sistem pengenalan ekspresi wajah dengan kondisi oklusi dikelas berbasis CNN pada mahasiswa yang sedang mengikuti pembelajaran pemrograman. Urgensi penelitian ini diperkuat oleh kebutuhan akan sistem pembelajaran yang lebih responsif terhadap kondisi emosional mahasiswa, khususnya pada pembelajaran pemrograman yang menuntut konsentrasi dan ketekunan tinggi. Tanpa sistem pendeteksi otomatis, dosen cenderung kesulitan memberikan intervensi yang tepat waktu. Dengan demikian, penelitian ini memiliki kontribusi praktis dan akademik dalam mendorong implementasi *affective computing* di ruang kelas.

2. BAHAN DAN METODE

Metode yang digunakan dalam penelitian ini yaitu metode penelitian deskriptif. Adapun tahapan penelitian yang telah dan akan dilakukan adalah sebagai berikut:

2.1. Tahapan Awal

Tahapan diawal penelitian dapat dilihat dari Gambar 1.

Kegiatan yang telah dilakukan dalam penelitian ini yaitu *survey* lokasi untuk melakukan analisis situasi terkait permasalahan yang terjadi. Selanjutnya melakukan studi literatur berdasarkan permasalahan yang ditemukan dan mencari solusi hingga ditemukan sebuah model algoritma yang dianggap mampu mengatasi permasalahan tersebut sehingga mampu meningkatkan nilai akurasi pengenalan ekspresi wajah mahasiswa dalam pembelajaran pemrograman yang terdapat kendala oklusi diruang kelas.



Gambar 1. Tahap Awal Penelitian


2.2. Tahap Eksperimen

Kegiatan yang akan dilaksanakan dalam penelitian ini agar dapat memperoleh hasil yang diharapkan dapat dilihat pada Gambar 2.



Gambar 2. Tahapan Penelitian

1. Tahap pertama, melakukan pengumpulan data dengan cara mengambil gambar wajah mahasiswa dengan menggunakan CCTV yang terpasang di kelas dan laboratorium komputer, selanjutnya data tersebut akan dijadikan *dataset* melalui tahapan *preprocessing*.
2. Tahap kedua, melakukan eksperimen dimulai dari input *dataset* lalu kemudian *preprocessing* dengan cara *Resizing* gambar, *Grayscale conversion* (optional), Normalisasi piksel, Augmentasi data (rotasi, *flipping*, *zoom*, dsb.) untuk memperkuat generalisasi model. Selanjutnya, *Dataset* dibagi menjadi *training*, *validation*, dan *testing*. Desain Arsitektur CNN, melatih model CNN menggunakan algoritma optimasi seperti Adam. Evaluasi dan validasi penelitian, Pengujian, Evaluasi Performa hingga memperoleh nilai akurasi. Gambaran tahapan eksperimen dalam penelitian ini dapat dilihat pada Gambar 3.
3. Tahap ketiga yaitu menyelesaikan laporan dan publikasi penelitian.




Gambar 3. Model Eksperimen

3. HASIL DAN PEMBAHASAN

3.1. Data Collection

Pengumpulan data dalam penelitian ini dilakukan dalam ruang kelas dan laboratorium Fakultas Ilmu Komputer Universitas Ichsan Sidenreng Rappang. Adapun mata kuliah yang diajarkan yaitu Pemrograman Web menggunakan Bahasa Pemrograman PHP dan Kecerdasan Buatan dengan menggunakan Bahasa Pemrograman Python. Data tersebut berupa gambar yang bersumber dari rekaman CCTV yang dipasang dalam ruang perkuliahan. Data video yang bersumber dari CCT diubah menjadi image agar memudahkan

tahap *preprocessing*. Gambar 4 merupakan tampilan lokasi pemasangan CCTV dalam kelas dan Lab Komputer.



Gambar 4. Posisi CCTV dalam kelas perkuliahan

3.2. *Preprocessing*

Berdasarkan pengumpulan data yang dilakukan, diperoleh *dataset* gambar wajah mahasiswa yang mengikuti pembelajaran pemrograman dengan kendala oklusi pada Gambar 5.



Gambar 5. Sampel Data Wajah

Adapun hasil dari pengumpulan data tersebut selanjutnya di simpan kedalam google drive yang dikelompokkan berdasarkan data latih (Train), data Uji (Test), data validasi (valid). Data tersebut berisi pengelompokan wajah berdasarkan ekspresi yang dikelompokkan berdasarkan kelas Bingung, Jenuh, Normal, dan Senang untuk kemudian dilanjutkan ketahapan *preprocessing* data.

3.3. *Training CNN Models*

Model yang digunakan dalam penelitian ini yaitu CNN dengan memanfaatkan EfficientNet-B3 sebagai *backbone*, seperti yang terlihat pada Tabel 1.


Tabel 1. Model yang digunakan

No	Layer	Type	Output Shape	Params
1	EfficientNet-B3	Functional	(None, 1536)	10,783,535
2	BatchNormalization_1	BatchNormalization	(None, 1536)	6,144
3	Dense_2	Dense	(None, 256)	393,472
4	Dropout	Dropout	(None, 256)	0
5	Dense_3	Dense	(None, 4)	1,028
Total params: 11,184,179 (42.66 MB)				
Trainable: 11,093,804 (42.32 MB)				
Non-trainable: 90,375 (353.03 KB)				

Tabel 1 ditemukan bahwa model memanfaatkan EfficientNet-B3 sebagai *backbone* (output fitur 1536-dim) yang diikuti *head* klasifikasi *BatchNormalization* (6.144 parameter) untuk stabilisasi aktivasi, *Dense* (256, ReLU) dengan regularisasi ringan (± 393.472 parameter), *Dropout* (0,45) untuk menekan *overfitting*, *Dense* (4, *Softmax*) sebagai lapisan keluaran (1.028 parameter).

Total parameter model mencapai 11.184.179 (42,66 MB), dengan 11.093.804 parameter *trainable* dan 90.375 *non-trainable*. Proporsi ini mengindikasikan bahwa sebagian besar lapisan EfficientNet-B3 dibuka (*unfrozen*) pada tahap *fine-tuning*, bukan hanya *head* sehingga *capacity* model besar untuk menyesuaikan diri dengan domain data.

Jika dilihat dari komposisi, >96% parameter berada pada *backbone*, sedangkan *head* menyumbang <4% parameter. Ini sesuai tujuan *transfer learning* yaitu memanfaatkan representasi fitur dalam EfficientNet-B3 lalu mengkhususkan pada empat kelas target (*Jenuh, Normal, Senang, Bingung*).



Gambar 6. Grafik *Training* dan *Validation*

Berdasarkan Gambar 6, *loss* pada data latih dan validasi menurun konsisten sepanjang proses pelatihan tanpa indikasi *divergensi*, menandakan pembelajaran stabil. Ketiadaan pelebaran jarak yang berarti antara kurva latih–validasi menunjukkan model tidak mengalami *overfitting* maupun *underfitting*. Akurasi validasi mencapai puncak sekitar *epoch* 12 (*best epoch*) dan setelahnya hanya berfluktuasi ringan sementara *loss* terus menyusut tipis. Dengan demikian, pada *epoch* tersebut model berada pada kondisi optimal fit, dan kami jadikan sebagai model akhir melalui *early stopping*. Fenomena *loss* turun tetapi akurasi validasi menurun lazim terjadi saat:

1. Distribusi probabilitas makin “yakin” namun keputusan kelas belum bergeser ke label yang benar (mis. prediksi salah namun dengan kepercayaan lebih tinggi), atau
2. Ketidakseimbangan/ambiguitas kelas sehingga perbaikan kalibrasi tidak langsung terefleksi ke akurasi, atau
3. Data validasi kecil/*noisy*/teroklusi, membuat akurasi lebih berfluktuasi dari pada *loss*.

Generalization gap ($\text{train} > \text{val}$) yang persisten mengindikasikan *overfitting* ringan setelah *epoch* 12, terlihat dari akurasi validasi yang menurun ketika pelatihan diteruskan hingga *epoch* 20. Karena itu, *EarlyStopping* berbasis akurasi validasi sebaiknya memilih model pada *epoch* 12, bukan pada *epoch* dengan *loss* terendah.

Perbedaan *train acc* (0,45) vs *val acc* (0,27) menandakan *generalization gap*, namun karena *train acc* pun belum tinggi, masalah utama cenderung *underfitting* (model belum cukup menangkap pola kelas). Hal ini konsisten dengan *loss* yang masih besar pada semua *split*. Penyebab yang mungkin muncul yaitu Data terbatas dan oklusi, dimana variasi pose/pencahayaannya serta oklusi (tangan/masker/perangkat) menyamarkan ciri mikro (mata, alis, mulut), sehingga batas antarkelas (*Normal, Senang, Bingung*) kabur. Selain itu, *fine-tuning* yang kurang tepat, misalnya membuka terlalu banyak lapisan *backbone* terlalu awal atau menggunakan laju belajar yang tidak sesuai dapat menyebabkan pelatihan pada *dataset* kecil menjadi tidak stabil.

3.4. Model Evaluation

Evaluasi model berdasarkan percobaan diatas ditemukan Kelas Jenuh tampil terbaik (*F1*: 0,56; *recall*: 0,62), menunjukkan model relatif mudah mengenali ciri kejenuhan, Untuk Kelas Normal memiliki presisi menengah (0,40) tetapi *recall* rendah (0,25) menandakan banyak contoh *Normal* tidak terdeteksi. Kelas Senang dan Bingung adalah kelas tersulit (*F1*: 0,17 dan 0,24). Seperti yang terlihat pada Tabel 2.

Tabel 2. Evaluasi Model

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	<i>Support</i>
Jenuh	0,5	0,62	0,56	8
Normal	0,4	0,25	0,31	8
Senang	0,2	0,14	0,17	7
Bingung	0,2	0,29	0,24	7

4. PENUTUP

Dalam penelitian ini ditemukan bahwa model CNN sudah menangkap pola Jenuh dengan baik, tetapi masih membingungkan pada kelas Normal, Senang, Bingung. Oklusi karena tangan, masker, perangkat, atau rekan berpotensi menutup bagian wajah yang paling informatif. Tanpa strategi khusus, *backbone*, meski kuat akan kesulitan membedakan ekspresi yang mirip (Normal, Senang, Bingung). Hasil yang diperoleh yaitu test set model meraih 33,33% akurasi, 0,33 presisi-makro, 0,33 *recall*-makro, dan 0,32 *F1*-makro, yang mencerminkan tantangan pengenalan di bawah oklusi kelas dan keterbatasan jumlah data. Akurasi validasi (26,67%) dan akurasi latih (45,31%) menunjukkan underfitting serta kebingungan antarkelas, khususnya antara Normal, Senang, dan Bingung.

Langkah perbaikan yang relevan dengan arsitektur di gambar dan pengembangan penelitian selanjutnya yaitu dengan menambahkan augmentasi oklusi terarah (random *erasing/cutout*, *gridmask*) pada area yang sering tertutup, selanjutnya pertimbangkan *face alignment* sebelum *resize 224×224* agar variansi pose berkurang dan fitur 1536-dim lebih fokus, serta sisipkan *attention* ringan (misalnya *Squeeze-and-Excitation (SE)*/ *Convolutional Block Attention Module (CBAM)* pada *head*) untuk menyorot fitur penting walau sebagian area terhalang.

UCAPAN TERIMA KASIH

Para penulis menyampaikan terima kasih atas dukungan pendanaan dari Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi Republik Indonesia (Kemendikbudristek) melalui Hibah Penelitian Dosen Pemula (PDP) melalui portal BIMA 2025. Kami juga berterima kasih kepada para Pimpinan Universitas Ichsan Gorontalo dan pengelola program atas bimbingan selama pelaksanaan program hibah penelitian ini.

REFERENSI

- [1] J. H. Berssanette and A. C. De Francisco, 'Cognitive Load Theory in the Context of Teaching and Learning Computer Programming: A Systematic Literature Review', *IEEE Trans. Educ.*, vol. 65, no. 3, pp. 440–449, Aug. 2022, doi: 10.1109/TE.2021.3127215.
- [2] G. Ekambaram, T. Rakkiannan, N. P, and J. E, 'Transfer Learning Based Deep Learning Model for the Identification of Facial Expression', in *2025 3rd International Conference on Intelligent Data Communication Technologies and Internet of Things (IDCIoT)*, Bengaluru, India: IEEE, Feb. 2025, pp. 2030–2037. doi: 10.1109/IDCIOT64235.2025.10915054.
- [3] U. Anwar *et al.*, 'Privacy-Preserving Facial Emotion Classification With Visual Micro-Doppler Signatures for Hearing Aid Applications', *IEEE Trans. Instrum. Meas.*, vol. 74, pp. 1–10, 2025, doi: 10.1109/TIM.2025.3548782.
- [4] S. Saxena, S. Tripathi, and T. S. B. Sudarshan, 'An intelligent facial expression recognition system with emotion intensity classification', *Cognitive Systems Research*, vol. 74, pp. 39–52, Aug. 2022, doi: 10.1016/j.cogsys.2022.04.001.
- [5] M. A. Khan, D. Chattaraj, S. Tadal, T. H. Sardar, A. Chourasia, and P. Malik, 'A Context for Human Behavior Recognition Using Facial Expression', in *2025 International Conference on Computational, Communication and Information Technology (ICCCIT)*, Indore, India: IEEE, Feb. 2025, pp. 275–280. doi: 10.1109/ICCCIT62592.2025.10928104.
- [6] Ayu Lestari Perdana, Suharni, and A. Riadi, 'Pengenalan Ekspresi Wajah Pengunjung Deal Coffee Menggunakan Metode Convolutional Neural Network (CNN)', *j. of Embedded Systems, secur. and intell. Systems*, pp. 132–139, Nov. 2023, doi: 10.59562/jessi.v4i2.1024.
- [7] N. Li *et al.*, 'Chinese Face Dataset for Face Recognition in an Uncontrolled Classroom Environment', *IEEE Access*, vol. 11, pp. 86963–86976, 2023, doi: 10.1109/ACCESS.2023.3302919.
- [8] S. I. Yudita, T. Mantoro, and M. A. Ayu, 'Deep Face Recognition for Imperfect Human Face Images on Social Media using the CNN Method', in *2021 4th International Conference of Computer and Informatics Engineering (IC2IE)*, Depok, Indonesia: IEEE, Sep. 2021, pp. 412–417. doi: 10.1109/IC2IE53219.2021.9649317.
- [9] V. S. Bhati, N. Tiwari, and M. Chawla, 'A Generalized Zero-Shot Deep Learning Classifier for Emotion Recognition Using Facial Expression Images', *IEEE Access*, vol. 13, pp. 18687–18700, 2025, doi: 10.1109/ACCESS.2025.3533580.

- [10] A. Gangwar, V. González-Castro, E. Alegre, and E. Fidalgo, 'Triple-BigGAN: Semi-supervised generative adversarial networks for image synthesis and classification on sexual facial expression recognition', *Neurocomputing*, vol. 528, pp. 200–216, Apr. 2023, doi: 10.1016/j.neucom.2023.01.027.
- [11] S. F. Kak, F. M. Mustafa, and A. Varol, 'Design and Enhancement of a CNN Model to Augment the Face Recognition Accuracy', in *2022 3rd International Informatics and Software Engineering Conference (IISEC)*, Ankara, Turkey: IEEE, Dec. 2022, pp. 1–5. doi: 10.1109/IISEC56263.2022.9998236.
- [12] S. S. Rajput and K. V. Arya, 'CNN Classifier based Low-resolution Face Recognition Algorithm', in *2020 International Conference on Emerging Frontiers in Electrical and Electronic Technologies (ICEFEET)*, Patna, India: IEEE, Jul. 2020, pp. 1–4. doi: 10.1109/ICEFEET49149.2020.9187001.
- [13] G. C. Lee, Y.-C. Lee, and C.-C. Chiang, 'Low-Resolution Face Recognition in Multi-person Indoor Environments Using Convolutional Neural Networks', in *2021 International Conference on Computational Science and Computational Intelligence (CSCI)*, Las Vegas, NV, USA: IEEE, Dec. 2021, pp. 1629–1633. doi: 10.1109/CSCI54926.2021.00313.
- [14] R. G. Sharma, H. Garg, and L. K. Singh, 'A Framework for Face Mask Detection and Face Recognition of Masked Images Using ResNet50 CNN with Multi-Task Learning and Cross- Attention Mechanism', in *2025 7th International Conference on Signal Processing, Computing and Control (ISPCC)*, SOLAN, India: IEEE, Mar. 2025, pp. 237–242. doi: 10.1109/ISPCC66872.2025.11039321.
- [15] P. C. Pedro Neto, J. R. Pinto, F. Boutros, N. Damer, A. F. Sequeira, and J. S. Cardoso, 'Beyond Masks: On the Generalization of Masked Face Recognition Models to Occluded Face Recognition', *IEEE Access*, vol. 10, pp. 86222–86233, 2022, doi: 10.1109/ACCESS.2022.3199014.
- [16] S. Malakar, W. Chiracharit, and K. Chamnongthai, 'Masked Face Recognition With Generated Occluded Part Using Image Augmentation and CNN Maintaining Face Identity', *IEEE Access*, vol. 12, pp. 126356–126375, 2024, doi: 10.1109/ACCESS.2024.3446652.
- [17] H. B. Fredj, S. Sghaier, and C. Souani, 'An Efficient Face Recognition Method Using CNN', in *2021 International Conference of Women in Data Science at Taif University (WiDSTaif)*, Taif, Saudi Arabia: IEEE, Mar. 2021, pp. 1–5. doi: 10.1109/WiDSTaif52235.2021.9430209.
- [18] A. A. Albraikan *et al.*, 'Intelligent facial expression recognition and classification using optimal deep transfer learning model', *Image and Vision Computing*, vol. 128, p. 104583, Dec. 2022, doi: 10.1016/j.imavis.2022.104583.
- [19] S. Karamizadeh, S. S. Chaeikar, and M. K. Najafabadi, 'Enhancing Facial Recognition and Expression Analysis With Unified Zero-Shot and Deep Learning Techniques', *IEEE Access*, vol. 13, pp. 43508–43519, 2025, doi: 10.1109/ACCESS.2025.3546061.
- [20] Richard Steven Immanuel Sihombing, Rafif Nauval Tuah Siregar, Vijay Sitorus, and Timotius Selar Sitompul, 'Pengenalan Ekspresi Wajah Menggunakan Convolutional Neural Network (CNN)', *jcsr-politama*, vol. 1, no. 6, pp. 89–97, Dec. 2023, doi: 10.55606/jcsrpolitama.v1i6.3046.