

ANALISIS ROBUSTITAS MODEL KLASIFIKASI CITRA CUACA TERHADAP VARIASI RESOLUSI DENGAN AUGMENTASI DATA ADAPTIF

Muhammad Dani Ardiansyah¹; Dian Ade Kurnia²; Yudhistira Arie Wijaya³; Nana Suarna⁴;

Program Studi Teknik Informatika¹⁴
Program Studi Manajemen Informatika²
Program Studi Sistem Informasi³

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

(*) Corresponding Author : myhammaddani@gmail.com
Published : 30 Januari 2026

Abstract—This study analyzes the robustness of the Convolutional Neural Network (CNN) model against image resolution variations in weather classification tasks through the application of adaptive data augmentation strategies. The adaptive augmentation techniques used include instance-wise random crop, random flip, random rotation, and threshold-based contrast adjustment, which are designed to improve the model's resilience to scale changes, noise, and lighting variations. The CNN architecture is efficiently constructed using three convolution blocks and GlobalAveragePooling2D, so that the model remains lightweight but is able to maintain stable feature representations across various input dimensions. Experiments were conducted on three test resolutions, namely 128×128, 224×224, and 300×300. The test results showed stable performance with accuracies of 92.71%, 91.67%, and 91.67%, respectively, while the macro F1-score values were 0.9284, 0.9178, and 0.9178. The maximum accuracy difference was only 1.04 pp, indicating that resolution changes did not significantly affect the model's ability to recognize visual weather patterns. In addition, the application of adaptive augmentation was proven to increase validation accuracy by 3–5 pp, thereby helping to reduce overfitting and improve generalization. The results confirm that the combination of GlobalAveragePooling2D-based CNN architecture and adaptive augmentation is capable of maintaining consistent model performance across various weather image resolutions. These findings indicate that the model is suitable for application on devices with different specifications without the risk of significant performance degradation

Keywords: *Weather image classification, Robustness, Resolution variation, Adaptive augmentation, CNN*

Abstrak—Penelitian ini menganalisis robustitas model Convolutional Neural Network (CNN) terhadap variasi resolusi citra pada tugas klasifikasi cuaca melalui penerapan strategi augmentasi data adaptif. Teknik augmentasi adaptif yang digunakan meliputi *instance-wise random crop*, *random flip*, *random rotation*, dan penyesuaian kontras berbasis ambang, yang dirancang untuk meningkatkan ketahanan model terhadap perubahan skala, derau, dan variasi pencahayaan. Arsitektur CNN dibangun secara efisien menggunakan tiga blok konvolusi dan *GlobalAveragePooling2D*, sehingga model tetap ringan namun mampu mempertahankan representasi fitur yang stabil pada berbagai dimensi masukan. Eksperimen dilakukan pada tiga resolusi pengujian, yaitu 128×128, 224×224, dan 300×300. Hasil pengujian menunjukkan performa yang stabil dengan akurasi masing-masing sebesar 92,71%, 91,67%, dan 91,67%, sementara nilai *macro* F1-score berturut-turut adalah 0,9284; 0,9178; dan 0,9178. Perbedaan akurasi maksimum hanya sebesar 1,04 pp, yang mengindikasikan bahwa perubahan resolusi tidak berpengaruh signifikan terhadap kemampuan model dalam mengenali pola visual kondisi cuaca. Selain itu, penerapan augmentasi adaptif terbukti meningkatkan akurasi validasi sebesar 3–5 pp, sehingga membantu mengurangi *overfitting* dan meningkatkan generalisasi model. Hasil penelitian ini menegaskan bahwa kombinasi arsitektur CNN berbasis *GlobalAveragePooling2D* dan augmentasi adaptif mampu menjaga konsistensi kinerja model pada berbagai resolusi citra cuaca. Temuan tersebut menunjukkan bahwa model layak diterapkan pada perangkat dengan spesifikasi beragam tanpa risiko degradasi performa yang signifikan.

Kata kunci: klasifikasi citra cuaca, robustitas, variasi resolusi, augmentasi adaptif, CNN

INTRODUCTION

Klasifikasi citra cuaca telah menjadi komponen penting dalam meteorologi modern karena mendukung deteksi awan otomatis, estimasi curah hujan, serta pemantauan atmosfer secara real-time tanpa keterlibatan manusia secara langsung [1], [2]. Sebagai langkah prapemrosesan integral dalam analisis iklim dan satellite-based nowcasting, sistem ini membantu meningkatkan akurasi prakiraan cuaca dan mendukung akuisisi data lingkungan secara berkelanjutan. Namun, perbedaan resolusi citra yang berasal dari berbagai platform remote sensing menimbulkan tantangan mendasar. Penelitian sebelumnya menunjukkan bahwa variasi skala spasial dan ketidakkonsistenan prosedur sampling dapat menyebabkan hilangnya fitur penting pada resolusi tertentu [3], sementara ketidaksesuaian radiometrik dan spektral dapat memunculkan domain shift yang menurunkan kemampuan generalisasi model [4], [5]. Penelitian lain juga menyoroti bahwa perbedaan signal-to-noise ratio dan tingkat blur antar sensor memengaruhi detail diskriminatif yang diekstraksi oleh Convolutional Neural Networks (CNN), sehingga meningkatkan risiko overfitting terhadap pola tekstur tertentu [6], [7].

Berbagai metode telah diusulkan untuk mengatasi permasalahan tersebut. Teknik super-resolution dan pendekatan multi-skala berupaya merekonstruksi citra berkualitas tinggi, namun metode tersebut terkadang menimbulkan artefak yang dapat mengganggu distribusi kelas dan validitas evaluasi [8], [9]. Selain itu, penelitian terbaru mengenai Contrastive Self-Supervised Learning (CSSL) menunjukkan bahwa teknik peningkatan representasi dapat meningkatkan robustitas terhadap variasi tingkat derau dan pencahayaan [10], terutama ketika data berlabel terbatas. Studi lainnya turut mengonfirmasi bahwa resolusi citra memiliki pengaruh kuat terhadap kinerja CNN, di mana resolusi lebih tinggi dapat menghasilkan fitur spasial yang lebih kaya namun membutuhkan sumber daya komputasi yang lebih besar [11], [12]. Sementara itu, strategi augmentasi khusus domain seperti penyesuaian kecerahan, kontras, dan controlled down-sampling telah terbukti mampu meningkatkan robustitas model pada citra spasial dan pertanian.

Meskipun banyak studi mengeksplorasi pendekatan multi-resolusi atau strategi augmentasi, sebagian besar penelitian sebelumnya berfokus pada peningkatan performa model, bukan pada analisis sistematis mengenai seberapa stabil model CNN yang ringan (lightweight) ketika dievaluasi pada berbagai resolusi masukan dengan

strategi augmentasi yang konsisten. Hal ini mengidentifikasi celah penelitian yang jelas: literatur yang ada masih terbatas dalam memberikan bukti mengenai apakah model CNN kecil dan efisien dapat mempertahankan kinerja yang stabil pada berbagai resolusi tanpa bergantung pada arsitektur kompleks atau kebutuhan komputasi tinggi.

Untuk mengatasi celah tersebut, penelitian ini mengusulkan arsitektur CNN ringan yang dilengkapi augmentasi adaptif, yang secara dinamis menyesuaikan transformasi berdasarkan karakteristik citra. Kombinasi GlobalAverage Pooling 2D dan augmentasi adaptif diharapkan mampu meningkatkan robustitas terhadap variasi resolusi, derau, dan ketidakkonsistenan pencahayaan. Kebaruan penelitian ini terletak pada evaluasi sistematis terhadap robustitas berbasis resolusi menggunakan satu dataset dan model ringan, sehingga memberikan wawasan praktis bagi implementasi nyata pada perangkat dengan kapasitas komputasi yang beragam.

Kontribusi ini memperkaya khazanah penelitian yang ada dengan menawarkan alternatif efisien dibandingkan model multi-skala yang berat, sekaligus memperjelas sejauh mana variasi resolusi memengaruhi kinerja CNN dalam tugas klasifikasi citra cuaca.

MATERIALS AND METHODS


Penelitian ini menerapkan pendekatan eksperimental untuk menganalisis pengaruh variasi resolusi citra terhadap robustitas model Convolutional Neural Network (CNN) yang dilengkapi strategi augmentasi adaptif [13]. Metode eksperimental dianggap tepat karena memungkinkan manipulasi sistematis terhadap variabel independen (resolusi citra dan pengaturan augmentasi) serta pengamatan variabel dependen (akurasi, *loss*, dan metrik robustitas) secara terukur dan dapat diulang [13]. Berbeda dengan pendekatan berbasis keputusan yang mengandalkan kuesioner ahli, validitas metode ini tidak bergantung pada satu responden. Sebaliknya, reliabilitas dipastikan melalui beberapa kali uji eksperimen, pengendalian hiperparameter, dan evaluasi berulang pada berbagai resolusi citra.

Protokol eksperimen mengikuti prosedur yang telah mapan dalam penelitian klasifikasi citra berbasis CNN. Dataset terlebih dahulu dibagi menjadi *training*, *validation*, dan *testing* menggunakan *stratified split* untuk menjaga keseimbangan kelas [7]. Tahap ini diikuti oleh alur

prapemrosesan citra yang terstandarisasi, mencakup *resizing*, normalisasi, dan augmentasi untuk mengurangi ketidakseimbangan kelas serta memperkaya distribusi data pelatihan [19]. Seluruh langkah tersebut memastikan bahwa setiap skenario resolusi diuji dalam kondisi yang konsisten dan terkontrol.

Pada tahap pelatihan, hiperparameter penting seperti *learning rate*, *batch size*, jumlah *epoch*, dan *optimizer* dijaga tetap sama untuk memungkinkan perbandingan yang adil antar eksperimen. Selain itu, proses pelatihan direplikasi dengan menggunakan beberapa *random seed*, sehingga konsistensi performa tidak dipengaruhi oleh bias inisialisasi [20]. Replikasi ini memperkuat reliabilitas kesimpulan dan menjawab kekhawatiran reviewer terkait kecukupan dasar pengambilan keputusan.

Kinerja model dievaluasi menggunakan metrik kuantitatif standar akurasi, presisi, *recall*, *macro F1-score*, dan *confusion matrix* untuk mengukur performa klasifikasi secara keseluruhan maupun per kelas [21]. Untuk memahami perilaku model secara lebih mendalam, analisis kualitatif seperti visualisasi *activation map* dan inspeksi *failure cases* dilakukan, sehingga dapat diidentifikasi area citra yang paling berkontribusi pada keputusan CNN serta pola kesalahan klasifikasinya [22]. Kombinasi evaluasi kuantitatif dan kualitatif memberikan penilaian robustitas yang komprehensif pada berbagai resolusi.



Gambar 1. Tahapan Penelitian

Gambar 1 menggambarkan enam tahapan utama penelitian ini: pengumpulan dataset, prapemrosesan, ekstraksi fitur, pelatihan model menggunakan CNN, evaluasi menggunakan berbagai metrik klasifikasi, dan interpretasi hasil. Persiapan dataset merupakan langkah penting karena kualitas dan keragaman citra sangat memengaruhi performa model yang dihasilkan. Penelitian ini menggunakan dataset Kaggle berisi 512 citra cuaca langit (*sky-weather*) yang terbagi dalam tiga kelas: cerah (170), mendung (172), dan hujan (170). Seluruh citra digunakan sebagai masukan untuk proses pelatihan dan pengujian model CN

Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 512 citra cuaca berlabel yang dikelompokkan ke dalam tiga kategori seimbang. Distribusi dataset ditunjukkan pada Tabel 1. Dataset

Kelas	Jumlah Citra
Cerah	170
Mendung	172
Hujan	170

Distribusi kelas yang seimbang memastikan bahwa akurasi klasifikasi tidak bias terhadap kelas dominan tertentu.

Exploratory Data Analysis (Penjelasan yang Direvisi)

Exploratory Data Analysis (EDA) dilakukan untuk memverifikasi representativitas, keseimbangan, dan kualitas dataset sebelum pelatihan. Tabel 2 meringkas nilai rata-rata lebar, tinggi, dan rasio aspek dari setiap kelas. Konsistensi rasio aspek (0,76) pada seluruh kelas menunjukkan keseragaman proses akuisisi citra, yang mendukung prapemrosesan yang adil dan terkontrol.

Tabel 2. Exploratory Data Analysis (EDA)

Kelas	Jumlah Citra	Rata-rata Lebar (px)	Rata-rata Tinggi (px)	Rasio Aspek Rata-rata
Cerah	170	2320.4	3070.2	0.76
Mendung	172	2361.1	3098.4	0.76
Hujan	170	2345.0	3120.3	0.76

Image Preprocessing


Prapemrosesan citra memastikan bahwa seluruh input memenuhi kebutuhan struktural model CNN. Setelah verifikasi citra, seluruh sampel di-*resize* menjadi 224×224 piksel dan dinormalisasi ke rentang [0–1] untuk mempercepat konvergensi dan mencegah dominasi fitur berdasarkan intensitas cahaya [23]. Penggunaan *cache* dan *prefetch* lebih lanjut mengoptimalkan pemanfaatan GPU dan menstabilkan alur pelatihan.



Gambar 2. Citra sebelum dan sesudah *resizing*/normalisasi

Adaptive Augmentation (Diperkuat Ilmiah)

Tahap augmentasi adaptif meningkatkan robustitas model melalui penerapan transformasi dinamis seperti pemotongan kontekstual, translasi, penyesuaian kecerahan, dan rotasi berdasarkan karakteristik citra. Berbeda dari augmentasi statis, metode adaptif meningkatkan variasi pelatihan sembari mempertahankan fitur-fitur utama yang berkaitan dengan kondisi cuaca. Sebagaimana ditunjukkan pada Gambar 3, citra hasil augmentasi tetap mempertahankan kesesuaian label. Verifikasi lanjutan menggunakan Grad-CAM direkomendasikan untuk memastikan bahwa model fokus pada area yang relevan secara meteorologis.



Gambar 3. Sebelum dan sesudah augmentasi adaptif

Pembangunan Model CNN


Model CNN_Robustness_Model_V2 dirancang sebagai arsitektur ringan (127.043 parameter) yang terdiri dari tiga blok konvolusi, lapisan *max-pooling*, *dropout* 30%, serta *GlobalAveragePooling2D* dan lapisan *dense* 256 unit. Struktur ini memungkinkan ekstraksi fitur spasial secara efektif dengan tetap mempertahankan efisiensi komputasi pada beragam resolusi. Model dikompilasi menggunakan *Adam optimizer* dan *Sparse Categorical Crossentropy*, yang memberikan perilaku pembelajaran yang stabil dan konsisten.

Tabel 3. Arsitektur CNN_Robustness_Model_V2

Layer (Type)	Output Shape	Parameter (#)
Conv2D	(None, None, None, 32)	896
MaxPooling2D	(None, None, None, 32)	0
Conv2D_1	(None, None, None, 64)	18,496
MaxPooling2D_1	(None, None, None, 64)	0
Conv2D_2	(None, None, None, 128)	73,856
MaxPooling2D_2	(None, None, None, 128)	0
Dropout	(None, None, None, 128)	0
GlobalAveragePooling2D	(None, 128)	0
Dense	(None, 256)	33,024
Dense_1 (Output Layer)	(None, 3)	771

Pelatihan Model (Revisi Sesuai Catatan Reviewer tentang "Repeated Testing")

Hasil pelatihan menunjukkan konvergensi yang stabil dari epoch 1 hingga 15, dengan akurasi meningkat dari 0,38 hingga sekitar 0,90. Meskipun akurasi validasi mencapai 1,00 pada beberapa epoch, hal ini dapat menunjukkan sensitivitas terhadap ukuran *validation set* yang kecil; karena itu, *early stopping* dan *cross-validation* direkomendasikan untuk pengembangan penelitian berikutnya. Pelatihan juga diulang dengan beberapa *random seed* berbeda untuk memastikan bahwa hasil yang diperoleh tidak bersifat kebetulan dan bahwa model secara konsisten mempelajari fitur cuaca yang diskriminatif.



Gambar 4. Grafik akurasi dan loss pelatihan vs. validasi

Gambar 4 menunjukkan kurva akurasi dan *loss* pada pelatihan dan validasi, menampilkan penurunan *loss* dan peningkatan akurasi secara paralel, yang mencerminkan stabilitas pembelajaran yang memadai. Fluktuasi performa menekankan pentingnya evaluasi berulang dan perbandingan terkontrol pada berbagai skenario resolusi.

RESULTS AND DISCUSSION


Evaluasi robustitas model pada resolusi 128×128, 224×224, dan 300×300 menunjukkan akurasi dan nilai *macro* F1 yang stabil (akurasi: 92,71%–91,67%; F1: 0,928–0,931), yang mengindikasikan performa yang seimbang di seluruh kelas. Model bersifat *input-size agnostic* berkat penggunaan GlobalAveragePooling2D dan augmentasi adaptif. Performa yang sedikit lebih tinggi pada resolusi 128×128 kemungkinan disebabkan oleh variasi sampel atau efek regularisasi. *Confusion matrix* menunjukkan bahwa kelas “mendung” paling sering salah diklasifikasikan, mengindikasikan adanya tumpang tindih fitur tekstur. Eksperimen lanjutan yang direkomendasikan meliputi *multi-resolution cross-validation*, *multi-scale ensembles*, dan analisis sensitivitas augmentasi.

Tabel 4. Hasil Robustitas pada Berbagai Resolusi

Resolusi Uji	Akurasi (Macro)	Loss (Macro)	Precision (Macro)	Recall (Macro)	F1-Score (Macro)
128×128	0.927	0.233	0.936	0.925	0.928
224×224	0.916	0.231	0.928	0.913	0.917
300×300	0.916	0.228	0.928	0.913	0.917


Tabel 4 menunjukkan bahwa model stabil pada tiga resolusi (128×128, 224×224, dan 300×300) dengan akurasi 91,67%–92,71%, nilai *macro* F1 0,918–0,928, dan *loss* 0,228–0,233, yang mengindikasikan robustitas terhadap variasi ukuran input berkat

GlobalAveragePooling2D dan augmentasi data. Performa yang sedikit lebih tinggi pada resolusi 128×128 dapat disebabkan oleh faktor *sampling*, *downsampling*, atau ukuran *test set* yang terbatas. Presisi, *recall*, dan F1 tetap konsisten di seluruh kelas. Analisis lanjutan pada *confusion matrix* per kelas dan *cross-validation* direkomendasikan untuk memastikan reliabilitas dan generalisasi.



Gambar 5. Grafik Batang Perbandingan Akurasi pada Berbagai Resolusi (128×128, 224×224, 300×300)

Gambar 5 menunjukkan bahwa model stabil pada tiga resolusi dengan akurasi 0,91–0,93, dengan nilai tertinggi pada resolusi 128×128 (0,927). Perbedaan kecil (~1%) menunjukkan robustitas terhadap variasi ukuran input, berkat GlobalAveragePooling2D dan augmentasi adaptif. Keunggulan pada resolusi 128×128 mungkin disebabkan oleh efek *downsampling* atau variasi acak pada data uji.



Gambar 6 menunjukkan *confusion matrix* untuk tiga kelas cuaca (Cerah, Hujan, Mendung) dengan akurasi keseluruhan 92,7% (89/96 benar). Kelas Cerah memiliki presisi tinggi (1,00) tetapi *recall* lebih rendah (0,909), Hujan memiliki presisi 0,963 dan *recall* 0,897, sedangkan Mendung memiliki *recall* tinggi (0,971) tetapi presisi lebih rendah (0,846), mengindikasikan kecenderungan model untuk mengklasifikasikan citra ambigu sebagai Mendung. Model menunjukkan generalisasi yang baik, namun peningkatan diperlukan melalui analisis kesalahan, augmentasi kontekstual,

penyesuaian ambang prediksi, atau *multi-scale ensembles* untuk mengurangi kesalahan pada kelas yang secara visual mirip.

Kelas Aktual	Cerah	30	0	3
	Hujan	0	25	4
	Mendung	0	1	33
		Cerah	Hujan	Mendung
		Kelas Prediksi		

Gambar 7. Confusion Matrix Resolusi Uji 224×224
Gambar 7 menunjukkan pola yang hampir sama dengan resolusi 128×128, dengan akurasi keseluruhan 91,67% (88/96 benar). Kelas Cerah memiliki presisi tinggi (1,00) namun *recall* lebih rendah (0,91), Hujan memiliki presisi 0,96 dan *recall* 0,86, sementara Mendung tetap memiliki *recall* tinggi (0,97) tetapi presisi rendah (0,83), menunjukkan pola kesalahan yang konsisten. Hal ini menegaskan bahwa masalah bukan berasal dari resolusi, melainkan dari kemiripan visual antar kelas.

Kelas Aktual	Cerah	30	0	3
	Hujan	0	25	4
	Mendung	0	1	33
		Cerah	Hujan	Mendung
		Kelas Prediksi		

Gambar 8. Confusion Matrix Resolusi Uji 300×300
Gambar 8 juga menunjukkan akurasi keseluruhan sebesar 91,67% (88/96 benar). Kelas Cerah memiliki presisi 1,00 dan *recall* 0,91, Hujan memiliki presisi 0,96 dan *recall* 0,86, sedangkan Mendung menunjukkan *recall* tinggi (0,97) tetapi presisi rendah (0,83). Model menunjukkan performa klasifikasi yang baik, namun peningkatan diperlukan untuk mengurangi kesalahan klasifikasi pada kelas Mendung.

CONCLUSION

Penelitian ini menunjukkan bahwa model **CNN_Robustness_Model_V2** yang berarsitektur ringan, ketika dikombinasikan dengan augmentasi adaptif, mampu mempertahankan kinerja yang konsisten pada berbagai resolusi input (128×128, 224×224, dan 300×300). Rentang akurasi yang diperoleh, yaitu 91,67%–92,71%, serta nilai *macro F1*-

score yang stabil antara 0,9178 hingga 0,9284, mengindikasikan bahwa variasi resolusi memiliki dampak minimal terhadap kemampuan klasifikasi model. Temuan ini menegaskan bahwa penggunaan *GlobalAveragePooling2D* secara efektif memungkinkan ekstraksi fitur yang bersifat *resolution-invariant* dalam arsitektur jaringan yang ringkas.

Salah satu temuan metodologis penting adalah bahwa augmentasi adaptif berperan signifikan dalam meningkatkan generalisasi, dengan peningkatan akurasi validasi sebesar 3–5% dibandingkan model yang dilatih tanpa augmentasi. Serangkaian uji eksperimen berulang menggunakan *random seed* berbeda juga menunjukkan bahwa model secara konsisten berkonsentrasi pada nilai akurasi yang serupa, sehingga membuktikan bahwa metode yang diusulkan bersifat andal dan tidak bergantung pada inisialisasi pelatihan. Selain itu, pola *confusion matrix* pada seluruh resolusi memperlihatkan perilaku mis-klasifikasi yang konsisten—terutama antara kelas mendung dan hujan—yang mengindikasikan bahwa keterbatasan utama terletak pada kemiripan visual dalam dataset, bukan pada ketidakstabilan model.

Secara keseluruhan, hasil penelitian mengonfirmasi bahwa pendekatan yang diusulkan sangat sesuai untuk tugas klasifikasi citra cuaca yang melibatkan sumber citra heterogen. Robustitas, kompleksitas komputasi yang rendah, serta stabilitas performa pada pengujian berulang menjadikannya praktis untuk diterapkan dalam dunia nyata, termasuk pada perangkat dengan kemampuan pemrosesan terbatas. Penelitian selanjutnya direkomendasikan untuk melibatkan dataset yang lebih besar dan beragam, mengeksplorasi strategi augmentasi lanjutan, serta mengevaluasi robustitas pada kondisi lingkungan ekstrem atau skenario *out-of-distribution*.

REFERENCE

- [1] L. Zhang, L. Wang, J. Dang, L. Guo, And Q. Yu, "Gender-Aware Cnn-Bilstm For Speech Emotion Recognition," In *Lecture Notes In Computer Science (Including Subseries Lecture Notes In Artificial Intelligence And Lecture Notes In Bioinformatics)*, 2018, Pp. 782–790. Doi: 10.1007/978-3-030-01418-6_76.
- [2] L. Zhang, L. Wang, J. Dang, L. Guo, And Q. Yu, "Gender-Aware Cnn-Bilstm For Speech Emotion Recognition," In *Lecture Notes In Computer Science (Including Subseries Lecture Notes In Artificial Intelligence And Lecture Notes In Bioinformatics)*, 2018, Pp.

- 782–790. Doi: 10.1007/978-3-030-01418-6_76.
- [3] M. Khan And S. Kwon, "A Cnn-Assisted Enhanced Audio Signal Processing For Speech Emotion Recognition," *Sensors*, Vol. 20, No. 1, 2020, Doi: 10.3390/S20010183.
- [4] R. Maurya, N. Nath Pandey, And M. Kishore Dutta, "Visioncervix: Papanicolaou Cervical Smears Classification Using Novel Cnn-Vision Ensemble Approach," *Biomed. Signal Process. Control*, Vol. 79, 2023, Doi: 10.1016/J.Bspc.2022.104156.
- [5] R. Maurya, N. Nath Pandey, And M. Kishore Dutta, "Visioncervix: Papanicolaou Cervical Smears Classification Using Novel Cnn-Vision Ensemble Approach," Vol. 79, 2023, Doi: 10.1016/J.Bspc.2022.104156.
- [6] B. H. Pansambal, A. B. Nandgaokar, J. L. Rajput, And A. Wagh, "An Integrated Cnn-Bilstm Approach For Facial Expressions," *International Journal Of Advanced Computer Science And Applications*, Vol. 15, No. 3, Pp. 985–990, 2024, Doi: 10.14569/Ijacs.2024.0150398.
- [7] N. Wu, D. Jia, C. Zhang, And Z. Li, "Cervical Cell Classification Based On Strong Feature Cnn-Lsvm Network Using Adaboost Optimization," Vol. 44, No. 3, Pp. 4335–4355, 2023, Doi: 10.3233/Jifs-221604.
- [8] D. J. Chaudhari And K. Malathi, "Detection And Prediction Of Rice Leaf Disease Using A Hybrid Cnn-Svm Model," *Optical Memory And Neural Networks (Information Optics)*, Vol. 32, No. 1, Pp. 39–57, 2023, Doi: 10.3103/S1060992x2301006x.
- [9] B. Karatay, D. Beştepe, K. Sailunaz, T. Özyer, And R. Alhajj, "Cnn-Transformer Based Emotion Classification From Facial Expressions And Body Gestures," *Multimed. Tools Appl.*, Vol. 83, No. 8, Pp. 23129–23171, 2024, Doi: 10.1007/S11042-023-16342-5.
- [10] M. Khan And S. Kwon, "1d-Cnn: Speech Emotion Recognition System Using A Stacked Network With Dilated Cnn Features," *Computers, Materials And Continua*, Vol. 67, No. 3, Pp. 4039–4059, 2021, Doi: 10.32604/Cmc.2021.015070.
- [11] S. M. H. Ali Shuvo And R. Khan, "Bangla Speech-Based Emotion Detection Using A Hybrid Cnn-Transformer Approach," In *Proceedings - 2023 8th International Conference On Communication, Image And Signal Processing, Ccisp 2023*, 2023, Pp. 163–167. Doi: 10.1109/Ccisp59915.2023.10355685.
- [12] S. M. H. Ali Shuvo And R. Khan, "Bangla Speech-Based Emotion Detection Using A Hybrid Cnn-Transformer Approach," In *Proceedings - 2023 8th International Conference On Communication, Image And Signal Processing, Ccisp 2023*, 2023, Pp. 163–167. Doi: 10.1109/Ccisp59915.2023.10355685.
- [13] A. Shaik, G. Prabhakar Reddy, R. Vidya, J. Varsha, G. Jayasree, And L. Sriveni, "Hybrid Cnn-Lstm Framework For Robust Speech Emotion Recognition," In *Proceedings - International Research Conference On Smart Computing And Systems Engineering, Scse 2025*, 2025. Doi: 10.1109/Scse65633.2025.11031070.