



Penerapan Arsitektur EfficientNet dalam Model CNN untuk Optimalisasi Klasifikasi Gambar Fashion pada Dataset Fashion MNIST

An EfficientNet-Based CNN for Optimizing Fashion Image Classification on the Fashion-MNIST Dataset

Shimon Abert Panggabean* & Susilawati

Program Studi Teknik Informatika, Universitas Medan Area, Indonesia

Diterima: 16 April 2025; Direview: 20 April 2025; Disetujui: 24 April 2025

*Corresponding Email: susilawati@staff.uma.ac.id

Abstrak

Penelitian ini mengevaluasi kinerja arsitektur EfficientNet untuk klasifikasi citra pada Fashion-MNIST (70.000 citra skala abu-abu, 10 kelas). Data pelatihan/pengujian mengikuti skema standar 60.000/10.000, dengan validasi internal dari subset pelatihan. Pra-pemrosesan meliputi penskalaan ulang citra agar kompatibel dengan masukan EfficientNet; pelatihan dilakukan menggunakan optimizer Adam (learning rate 0,001), batch size 32, dan 20 epoch, disertai augmentasi data serta pemantauan metrik. Evaluasi pada himpunan uji menggunakan akurasi, precision, recall, F1-skor, serta confusion matrix. Hasil menunjukkan akurasi 0,9429, precision 0,9426, recall 0,9429, dan F1-score 0,9425. Analisis per kelas menegaskan bahwa Trouser dan Bag merupakan kategori dengan performa terbaik, sedangkan T-shirt/top dan Shirt paling menantang akibat kemiripan visual, sebagaimana tercermin pada confusion matrix. Dibandingkan beberapa model pembanding CNN standar, CNN-3-128, VGG16, XG-ViT (Vision Transformer), dan DRQCNN EfficientNet meraih skor keseluruhan tertinggi, meskipun keunggulannya relatif marginal sehingga makna praktisnya perlu disesuaikan dengan tujuan aplikasi.

Kata Kunci: Efficientnet; Fashion-MNIST; CNN; Klasifikasi Gambar; Precision-Recall; F1-Score; Confusion Matrix.

Abstract

This study evaluates the performance of the EfficientNet architecture for image classification on Fashion-MNIST (70,000 grayscale images, 10 classes). The training/testing split follows the standard 60,000/10,000 scheme, with an internal validation subset drawn from the training data. Preprocessing resizes images to match EfficientNet's input requirements. The model is trained with the Adam optimizer (learning rate 0.001), batch size 32, for 20 epochs, with data augmentation and metric monitoring. Evaluation on the test set employs accuracy, precision, recall, F1-score, and the confusion matrix. The results show accuracy = 0.9429, precision = 0.9426, recall = 0.9429, and F1-score = 0.9425. Per-class analysis indicates that Trouser and Bag achieve the highest performance, while T-shirt/top and Shirt are most challenging due to visual similarity, as reflected in the confusion matrix. Compared with several baselines standard CNN, CNN-3-128, VGG16, XG-ViT (Vision Transformer), and DRQCNN EfficientNet attains the best overall score, although its advantage is relatively marginal; hence, practical significance depends on application goals.

Keywords: Efficientnet; Fashion-MNIST; Convolutional Neural Networks; Image Classification; Precision-Recall; F1-Score; Confusion Matrix.



PENDAHULUAN

Fashion MNIST adalah salah satu dataset penting dalam bidang Computer Vision. Pengenalan gambar sendiri merupakan masalah dasar yang memiliki penerapan luas di berbagai sektor, seperti pendidikan, keamanan, sistem pengenalan objek, hingga diagnosis di dunia medis. Identifikasi citra, termasuk pada dataset Fashion MNIST, menjadi tugas utama dalam pengenalan pola visual karena setiap kategori pakaian memiliki karakteristik berbeda yang dapat diekstraksi. Tantangan muncul karena adanya variasi bentuk, tekstur, dan gaya visual dari setiap objek, sehingga membuat proses pengenalan pola menjadi kompleks [1].

Penelitian ini menggunakan arsitektur Convolutional Neural Network (CNN) untuk mengenali citra pakaian pada dataset Fashion MNIST [1]. CNN memiliki konsep yang mirip dengan Artificial Neural Network (ANN), karena terdiri dari neuron-neuron yang dapat mengoptimalkan bobotnya melalui proses pembelajaran. Dalam implementasinya, CNN memiliki empat lapisan utama. Lapisan konvolusi berfungsi untuk mengekstraksi fitur dari citra pakaian dengan cara menggeser matriks kecil (kernel atau filter) di seluruh area gambar dan menghasilkan feature maps [2]. Selanjutnya, lapisan pooling digunakan untuk mempertahankan informasi penting dengan mereduksi ukuran feature maps, sehingga dapat mengurangi jumlah parameter sekaligus meningkatkan efisiensi komputasi. Setelah itu, lapisan fully connected layer (lapisan terhubung penuh) berperan dalam menghubungkan setiap neuron dengan neuron pada lapisan sebelumnya untuk melakukan klasifikasi akhir [2]. Dengan susunan ini, CNN mampu mempelajari pola visual dari dataset Fashion MNIST secara lebih efektif. elanjutnya, lapisan output bertugas untuk melakukan prediksi terhadap kelas citra pada dataset Fashion MNIST [1]. Dengan arsitektur seperti ini, CNN membutuhkan jumlah parameter yang lebih sedikit untuk dipelajari serta mampu mengurangi jumlah data yang diperlukan dalam proses pelatihan model [3]. Selain itu, CNN memiliki kemampuan untuk mendeteksi fitur-fitur penting dari citra digital secara otomatis tanpa memerlukan intervensi manusia secara langsung. Hal ini menjadikan CNN lebih efektif dibandingkan metode pendahulunya. Selanjutnya, lapisan output bertugas untuk melakukan prediksi terhadap kelas citra pada dataset Fashion MNIST [1]. Dengan arsitektur seperti ini, CNN membutuhkan jumlah parameter yang lebih sedikit untuk dipelajari serta mampu mengurangi jumlah data

yang diperlukan dalam proses pelatihan model. Selain itu, CNN memiliki kemampuan untuk mendeteksi fitur-fitur penting dari citra digital secara otomatis tanpa memerlukan intervensi manusia secara langsung [2]. Hal ini menjadikan CNN lebih efektif dibandingkan metode pendahulunya. Terdapat berbagai variasi arsitektur yang dapat diterapkan pada CNN, salah satunya adalah EfficientNet. Arsitektur EfficientNet menggunakan pendekatan compound scaling yang secara sistematis menyeimbangkan kedalaman (depth), lebar (width), dan resolusi gambar (resolution) dalam jaringan. Dengan strategi ini, EfficientNet mampu mencapai akurasi yang tinggi dengan jumlah parameter yang relatif lebih sedikit dibandingkan arsitektur CNN konvensional. Selain itu, EfficientNet dikenal efisien dalam penggunaan sumber daya komputasi, sehingga lebih optimal ketika diterapkan pada dataset seperti Fashion MNIST [3].


METODE PENELITIAN

A. Dataset

Dataset Fashion MNIST merupakan salah satu dataset standar yang digunakan secara luas untuk menguji model pengenalan citra, khususnya dalam bidang image classification. Dataset ini berisi 60.000 gambar latih dan 10.000 gambar uji dengan resolusi 28×28 piksel dalam format grayscale [5]. Berbeda dengan MNIST klasik yang berisi Foto, Fashion MNIST terdiri dari 10 kelas kategori pakaian, yaitu T-shirt/Top, Trouser, Pullover, Dress, Coat, Sandal, Shirt, Sneaker, Bag, dan Ankle Boot [10]. Gambar latih digunakan untuk melatih model agar mampu mengenali pola dari setiap kelas, sedangkan gambar uji berfungsi untuk mengevaluasi kinerja model yang telah dilatih. Fashion MNIST banyak digunakan sebagai alternatif MNIST karena memiliki tingkat kompleksitas yang lebih tinggi, sehingga lebih menantang dan representatif dalam menguji kemampuan model visi computer [6]. Berikut adalah distribusi data pada dataset Fashion MNIST beserta beberapa contoh citra yang terdapat di dalamnya.

Tabel 1. Distribusi Dataset MNIST

Kelas	T- Shirt/Top	Trouser	Pullover	Dress	Coat	Sandal	Shirt	Sneaker	Bag	Ankle Boot	Total
Data Latih	6000	6000	6000	6000	6000	6000	6000	6000	6000	6000	60000
Data Uji	1000	1000	1000	1000	1000	1000	1000	1000	1000	1000	10000




Gambar 1. Sampel Gambar Pada Dataset MNIST

B. Preprocessing Data

Tahap pra-pemrosesan data dimulai dengan mengubah resolusi citra dari ukuran asli 28x28 piksel menjadi 64x64 piksel, sambil mempertahankan format grayscale, agar arsitektur EfficientNet dapat digunakan dalam proses pelatihan [7].

C. Arsitektur Model

EfficientNet merupakan arsitektur CNN yang dirancang untuk efisiensi dan akurasi tinggi dengan jumlah parameter yang lebih sedikit. Model ini dibangun menggunakan blok utama MBConv (Mobile Inverted Bottleneck Convolution) yang dipadukan dengan mekanisme Squeeze-and-Excitation [8]. Keunggulan utama EfficientNet terletak pada strategi compound scaling, yaitu memperbesar model secara seimbang pada aspek depth (kedalaman jaringan), width (lebar saluran), dan resolution (resolusi gambar). Seri EfficientNet terdiri dari B0 hingga B7, dengan B0 sebagai model dasar hasil pencarian arsitektur otomatis (AutoML), sementara varian berikutnya diperoleh melalui skala yang seimbang [9]. Pendekatan ini membuat EfficientNet lebih efisien dibandingkan arsitektur CNN sebelumnya seperti ResNet atau Inception, baik dari sisi performa maupun kebutuhan komputasi.



Gambar 2. Arsitektur EfficientNET

Arsitektur EfficientNet yang digunakan pada penelitian ini diawali dengan sebuah lapisan konvolusi berukuran 3×3 yang berfungsi sebagai stem layer untuk mengekstraksi fitur awal dari citra dataset Fashion-MNIST. Dataset Fashion-MNIST sendiri terdiri dari gambar pakaian, sepatu, dan aksesoris dengan resolusi asli 28×28 piksel dalam format grayscale. Agar dapat diproses oleh arsitektur EfficientNet dengan lebih baik, citra terlebih dahulu diubah ukurannya menjadi 64×64 piksel namun tetap dipertahankan dalam format grayscale. Lapisan konvolusi awal ini bertugas menghasilkan representasi fitur dasar yang akan menjadi input bagi blok-blok berikutnya [9].

Setelah tahap awal, jaringan dilanjutkan dengan serangkaian blok MBConv (Mobile Inverted Bottleneck Convolution). Blok MBConv memiliki struktur khas, yaitu memperluas dimensi kanal melalui konvolusi 1×1 , kemudian melakukan konvolusi depthwise dengan kernel berukuran 3×3 atau 5×5 , diikuti mekanisme squeeze-and-excitation (SE) untuk menonjolkan kanal-kanal penting, serta akhirnya memproyeksikan kembali hasilnya dengan konvolusi 1×1 . Arsitektur ini memungkinkan jaringan untuk tetap efisien dalam jumlah parameter namun tetap mampu menangkap informasi yang relevan. Pada blok pertama, digunakan MBConv1 dengan kernel 3×3 , sementara pada blok-blok berikutnya digunakan MBConv6 dengan kernel 3×3 atau 5×5 dan jumlah pengulangan yang berbeda-beda sesuai tahapannya [9].

Proses ini dilakukan secara bertingkat dari Blok 1 hingga Blok 7. Setiap blok tidak hanya meningkatkan jumlah kanal fitur, tetapi juga secara bertahap mengecilkan ukuran spasial dari citra representasi, sehingga menghasilkan representasi yang lebih padat namun kaya akan informasi. Sebagai contoh, resolusi awal 64×64 piksel dapat diperkecil hingga menjadi 2×2 piksel pada blok akhir, dengan jumlah kanal yang semakin besar untuk memuat kompleksitas fitur. Hal ini penting untuk dataset Fashion-MNIST karena memungkinkan jaringan memahami pola tekstur, kontur pakaian, dan perbedaan bentuk antar kelas, misalnya membedakan antara kaos, celana, sandal, dan tas [1].

Pada bagian akhir arsitektur, terdapat lapisan konvolusi 1×1 yang berfungsi memperbesar kanal fitur ke dimensi yang lebih tinggi, diikuti dengan global average pooling (GAP) yang mereduksi setiap kanal menjadi satu nilai representatif. Tahap akhir adalah lapisan fully connected atau dense layer dengan jumlah neuron sebanyak 10, sesuai dengan jumlah kelas pada dataset Fashion-MNIST. Hasil keluaran dari lapisan ini adalah probabilitas untuk masing-masing kelas, misalnya kemungkinan gambar termasuk ke dalam kategori kaos, celana, atau jenis pakaian lainnya [1].

Keunggulan arsitektur ini adalah sifatnya yang efisien karena mampu mencapai akurasi tinggi dengan jumlah parameter relatif kecil, berkat penggunaan MBConv dan mekanisme compound scaling. Selain itu, penggunaan squeeze-and-excitation memperkuat fokus model pada fitur penting, sehingga memudahkan proses klasifikasi terhadap pola tekstur dan bentuk objek pada Fashion-MNIST. Dengan demikian, arsitektur EfficientNet menjadi salah satu pilihan ideal untuk menyelesaikan permasalahan klasifikasi citra pada dataset Fashion-MNIST[12].

Dalam penelitian ini, arsitektur EfficientNet diterapkan untuk klasifikasi citra pada dataset Fashion-MNIST. Model dilatih dengan menggunakan optimizer seperti Adam, serta diuji dengan learning rate 0.001. Setiap eksperimen dievaluasi berdasarkan precision, recall, F1-score, serta akurasi. Dengan memanfaatkan efisiensi arsitektur EfficientNet yang mengombinasikan MBConv, Squeeze-and-Excitation, dan strategi compound scaling, penelitian ini bertujuan menghasilkan model yang lebih akurat sekaligus ringan dibandingkan CNN konvensional dalam mengenali berbagai jenis pakaian pada dataset Fashion-MNIST.

HASIL DAN PEMBAHASAN

A. Hasil


Pada penelitian ini digunakan dataset Fashion-MNIST yang terdiri atas 60.000 citra data latih dan 10.000 citra data uji. Setiap kelas memiliki jumlah sampel yang seimbang (10 kelas; pada data uji masing-masing 1.000 sampel). Evaluasi kinerja model dilakukan pada data uji dengan empat metrik utama akurasi, presisi, recall, dan F1-score untuk memastikan setiap kelas memperoleh bobot penilaian yang sama. Hasil pengujian menunjukkan akurasi sebesar 0.9429, presisi 0.9426, recall 0.9429, dan F1-score 0.9425. Penelitian ini mengindikasikan bahwa sekitar 9.429 dari 10.000 citra uji berhasil diklasifikasikan dengan benar, serta terdapat keseimbangan yang baik antara kemampuan model dalam menghindari kesalahan label (presisi) dan menangkap seluruh contoh positif pada tiap kelas (recall).

B. Pembahasan

Dataset yang telah diperoleh terlebih dahulu melewati tahap seleksi awal. Pada tahap ini, citra dengan kualitas rendah, tidak lengkap, atau mengandung *noise* akan


disaring dan dihapus. Proses ini bertujuan untuk mengurangi potensi gangguan yang dapat memengaruhi proses pelatihan model, sehingga diharapkan mampu meningkatkan kualitas data yang digunakan.

Model algoritma EfficientNet pada penelitian ini akan dijalankan menggunakan Google Colab sebagai lingkungan komputasi. Platform ini dipilih karena menyediakan sumber daya GPU/TPU yang memadai serta mendukung integrasi pustaka deep learning. Semua proses pelatihan dan pengujian model dilakukan dengan menuliskan serta mengeksekusi potongan kode Python pada notebook Colab. Pada skenario pengujian, citra masukan berukuran 224×224 piksel dengan tiga kanal warna (RGB). Proses pelatihan dilakukan menggunakan ukuran batch 32, dengan optimizer Adam untuk memperbarui bobot jaringan. Pelatihan dijalankan selama 20 epoch dan learning rate 0.001 pada keseluruhan data sesuai pembagian yang telah ditetapkan. Rangkaian konfigurasi model pada skenario ini ditampilkan pada Gambar 3.



Gambar 3. Akurasi dan Loss EffecientNet

Gambar 3 adalah hasil dari pelatihan dengan menggunakan optimizer Adam dengan learning rate 0.001. Dapat dilihat pada grafik pertama kombinasi optimizer Adam dengan learning rate 0.001 mendapat akurasi yang naik tinggi dalam setiap epoch hingga seterusnya.



Gambar 4. Confusion Matrix EffecientNet

Gambar 4 Confusion matrix menunjukkan bahwa performa model sangat baik, ditandai oleh dominasi nilai tinggi pada diagonal utama (baris = label sebenarnya, kolom = prediksi model), yang berarti sebagian besar sampel diklasifikasikan dengan benar. Kelas Trouser, Sneaker, Bag, dan Ankle boot hampir seluruhnya berada pada diagonal, sehingga tingkat kesalahannya sangat kecil. Kesalahan yang tersisa terutama terjadi pada kelompok atasan: Shirt paling sering tertukar sebagai T-shirt/top atau Pullover, dan Coat sesekali diprediksi sebagai Pullover atau Dress.

Tabel 2. Classification Report

Nama	Precision	Recall	F1-Score	Support
T-shirt/Top	0.8959	0.9040	0.9000	1000
Trouser	0.9980	0.9900	0.9040	1000
Pullover	0.8864	0.9210	0.9034	1000
Dress	0.9508	0.9470	0.9489	1000
Coat	0.8970	0.9410	0.9185	1000
Sandal	0.9920	0.9940	0.9930	1000
Shirt	0.8549	0.7780	0.8147	1000
Sneaker	0.9733	0.9850	0.9791	1000
Bag	0.9930	0.9980	0.9955	1000
Ankle boot	0.9848	0.9710	0.9778	1000
Accuracy		0.9429		10000
Weighted avg	0.9426	0.9429	0.9425	10000

C. Perbandingan dari Penelitian Terdahulu

Referensi	Model	Dataset	Akurasi	Presisi	Recall	F1-Score
Ravil I. Mukhamediev	CNN-3-128	70.000 Dataset, 60.000 data training, 10.000 data testing	0.9344	0.9348	0.9029	0.9109
K. Ganesh, K. Haripriya, K. Indrasena Reddy T. Pavan Raj Prof. V. Sravanthi	CNN	70.000 Dataset, 60.000 data training, 10.000 data testing	0.8700	0.8400	0.8500	0.8450
Hadeer M. Abd Alaziz, Hela Elmannai, Hager Saleh; Myriam Hadjouni, Ahmed M. Anter, Abdelrahim Koura, dan Mohammed Kayed	VGG16	70.000 Dataset, 60.000 data training, 10.000 data testing	0.9325	0.9320	0.9325	0.9320
Sonia Bouzidi, Imen Jdey, dan Fadoua Drira	XG-ViT: Vision Transformer (ViT)	70.000 Dataset, 60.000 data training, 10.000 data testing	0.9283	0.9287	0.9265	0.9263
Meshal Alharbi dan Sultan Ahmad	DRQCNN (Deep Revamped Quantum Convolutional Neural	70.000 Dataset, 60.000 data training, 10.000	0.9408	0.9417	0.9403	0.9415

	Network)	data testing				
Peneliti Ini	EffecientNET	70.000	0.9429	0.9426	0.9429	0.9425
	Dataset,					
	60.000					
	data					
	training,					
	10.000					
	data					
	testing					

Penelitian ini membandingkan enam arsitektur pada dataset Fashion-MNIST yang berjumlah 70.000 sampel, dengan pembagian 60.000 data pelatihan dan 10.000 data pengujian; rincian pembagian tersebut tercantum secara konsisten pada tabel Perbandingan. Hasil evaluasi terhadap 10.000 data uji menunjukkan bahwa EfficientNet memberikan kinerja terbaik dengan akurasi 0,9429, presisi 0,9426, recall 0,9429, dan F1-Score 0,9425. Model DRQCNN menempati peringkat kedua (akurasi 0,9408; presisi 0,9417; recall 0,9403; F1-Score 0,9415), diikuti VGG16 (0,9325; 0,9320; 0,9325; 0,9320), XG-ViT/Vision Transformer (0,9283; 0,9287; 0,9265; 0,9263), CNN-3-128 (0,9344; 0,9348; 0,9029; 0,9109), serta CNN standar (0,8700; 0,8400; 0,8500; 0,8450). Dari sisi akurasi, EfficientNet melampaui DRQCNN sebesar 0,21 poin persentase (pp), VGG16 sebesar 1,04 pp, XG-ViT sebesar 1,46 pp, CNN-3-128 sebesar 0,85 pp, dan CNN standar sebesar 7,29 pp. Meskipun demikian, selisih yang relatif kecil ($\approx 0,2-1,5$ pp) di antara tiga model teratas menandakan bahwa makna praktis dari peningkatan kinerja perlu dievaluasi kembali sesuai tujuan aplikasi, misalnya dengan memprioritaskan penurunan false negative atau false positive.

KESIMPULAN

Penelitian menunjukkan bahwa EfficientNet sangat efektif untuk klasifikasi dataset Fashion-MNIST. Pada dataset 70.000 citra dengan 10 kelas seimbang, model ini mencapai akurasi sekitar 94–95% dengan precision, recall, dan F1 yang sejalan, menandakan kinerja stabil di semua kelas. Kelas seperti Trouser, Bag, Sneaker, dan Ankle boot paling mudah dikenali, sementara kesalahan utama terjadi pada kelas atasan yang mirip secara visual terutama T-shirt/top, Shirt, dan Pullover sebagaimana tercermin pada confusion matrix. Dibandingkan model pembanding (CNN standar, CNN-3-128, VGG16, Vision Transformer/XG-ViT, dan DRQCNN), EfficientNet memberikan skor

terbaik, meski selisihnya tipis sehingga makna praktisnya tetap bergantung pada kebutuhan aplikasi. Implikasinya, EfficientNet layak dipilih untuk sistem klasifikasi fashion yang membutuhkan model relatif ringan namun akurat. Untuk peningkatan lebih lanjut, disarankan melakukan fine-tuning pada blok akhir EfficientNet serta memperkaya skema augmentasi data guna mengurangi misklasifikasi pada kelas yang mirip. Jika diperlukan, strategi seperti penyeimbangan kelas, penyesuaian ambang keputusan, atau evaluasi metrik per kelas juga dapat membantu memaksimalkan performa di skenario produksi.

DAFTAR PUSTAKA

- [1] Zhang, H., Luo, T., Goh, R. S. M., & Wong, W.-F. (2023). Desire backpropagation: A lightweight training algorithm for multi-layer neural networks. *Neurocomputing*. (MNIST & Fashion-MNIST).
- [2] Raza, S. H., Islam, M. M., Haque, A., Farin, S., Ahmad, M., & Hossain, M. S. (2023). Lung cancer classification using EfficientNet from CT-scan images. *Engineering Applications of Artificial Intelligence*, 126, 106902. <https://doi.org/10.1016/j.engappai.2023.106902>
- [3] Ge, S., Phan, K., Chen, S., Shen, T., Siriapisith, T., & Chen, M. (2023). Multi-class classification of brain tumor types from MR images using EfficientNets. *Biomedical Signal Processing and Control*, 84, 104777. <https://doi.org/10.1016/j.bspc.2023.104777>
- [4] Waskita, A., Nurhadiyatna, A., & co-authors. (2023). EfficientNetV2-based for MRI brain tumor image classification. In *2023 International Conference on Computer, Control, Informatics and its Applications (IC3INA)*. <https://doi.org/10.1109/IC3INA60834.2023.10285782>
- [5] Chamnong, N., Werapun, J., & Hanskunatai, A. (2023). Hierarchical convolutional neural networks using CCP-3 block architecture for apparel image classification. *International Journal of Advanced Computer Science and Applications*, 14(6). <https://doi.org/10.14569/IJACSA.2023.0140624>
- [6] Riyanto, S., Sitanggang, I. S., Djatna, T., & Atikah, T. D. (2023). Comparative analysis using various performance metrics in imbalanced data for multi-class text classification. *International Journal of Advanced Computer Science and Applications*, 14(6). <https://doi.org/10.14569/IJACSA.2023.01406116>
- [7] Gerlinghoff, D., Luo, T., Goh, R. S. M., & Wong, W.-F. (2023). Desire backpropagation: A lightweight training algorithm for multi-layer spiking neural networks based on spike-timing-dependent plasticity. *Neurocomputing*, 560, 126773. <https://doi.org/10.1016/j.neucom.2023.126773>
- [8] Rani, R. U., Kakarla, J., & Sundar, B. (2023). Weather image classification using EfficientNet and dual attention block. In *2023 2nd International Conference on Smart Technologies and Systems for Next Generation Computing (ICSTSN)*. <https://doi.org/10.1109/ICSTSN57873.2023.10151564>
- [9] Pillai, R., Sharma, N., & Gupta, R. (2023). Fine-Tuned EfficientNetB4 transfer learning model for weather classification. In *2023 3rd Asian Conference on Innovation in Technology (ASIANCON)*. <https://doi.org/10.1109/ASIANCON58793.2023.10270698>
- [10] Nagib, A. E., Mohamed, H., & Ashraf, A. (2023). Comparative analysis of pre-trained CNN architectures for multi-class weather classification: A study on deep learning techniques. In *2023 Intelligent Methods, Systems, and Applications (IMSA)*. <https://doi.org/10.1109/IMSA58542.2023.10217616>
- [11] Gupta, A., & Goel, S. (2023). Deep learning empowered weather image classification for accurate analysis. In *2023 IEEE 2nd International Conference on Industrial Electronics: Developments & Applications (ICIDEA)*. <https://doi.org/10.1109/ICIDEA59866.2023.10295216>
- [12] Samo, M., Mafeni Mase, J. M., & Figueredo, G. (2023). Deep learning with attention mechanisms for road weather detection. *Sensors*, 23(2), 798. <https://doi.org/10.3390/s23020798>
- [13] Afxentiou, V., & Vladimirova, T. (2023). Multi-label weather image classification for embedded computing platforms. In *2023 IEEE Smart World Congress (SWC)*. <https://doi.org/10.1109/SWC57546.2023.10449086>
- [14] Nguyen, T., & co-authors. (2023). MLcps: Machine Learning Cumulative Performance Score for classification problems. *GigaScience*, 12, giad108. <https://doi.org/10.1093/gigascience/giad108>



- [15] Obi, J., & co-authors. (2023). A comparative study of several classification metrics and their performances on data. *World Journal of Advanced Engineering Technology and Sciences*, 8(1), 308–314. <https://doi.org/10.30574/wjaets.2023.8.1.0054>
- [16] Swain, D., Sahoo, M., & Pradhan, S. (2023). An intelligent fashion object classification using CNN. *EAI Endorsed Transactions on Industrial Networks and Intelligent Systems*. <https://doi.org/10.4108/eetinis.v10i4.4315>
- [17] Muhathir, N., Ryandra, M. F. D., Syah, R. B. Y., Khairina, N., & Muliono, R. (2023). Convolutional Neural Network (CNN) of Resnet-50 with Inceptionv3 Architecture in Classification on X-Ray Image. In *Lecture notes in networks and systems* (pp. 208–221). https://doi.org/10.1007/978-3-031-35314-7_20
- [18] Syah, R. B. Y., Muliono, R., Siregar, M. A., & Elveny, M. (2024). An efficiency metaheuristic model to predicting customers churn in the business market with machine learning-based. *IAES International Journal of Artificial Intelligence*, 13(2), 1547. <https://doi.org/10.11591/ijai.v13.i2.pp1547-1556>