

Implementasi Model InceptionV3 untuk Klasifikasi Teroris dan *Non-Teroris* pada Dataset Citra

Bagus Al Qohar¹, Alamsyah²

^{1,2}Jurusan Ilmu Komputer, FMIPA, Universitas Negeri Semarang
Email: ¹bagusximipa6@students.unnes.ac.id, ²alamsyah@mail.unnes.ac.id

Abstrak

Klasifikasi citra teroris dan *non-teroris* merupakan hal yang penting dalam mendukung sistem keamanan berbasis teknologi. Penelitian ini bertujuan untuk mengimplementasikan model InceptionV3, sebuah model *deep learning* yang terbukti efektif dalam berbagai tugas klasifikasi gambar, untuk meningkatkan akurasi deteksi pada dataset gambar teroris dan *non-teroris*. Penelitian sebelumnya telah menggunakan berbagai model seperti VGG dan ResNet, namun masih terdapat tantangan dalam menangkap fitur yang kompleks. Penelitian ini menggunakan InceptionV3 karena arsitekturnya yang dalam dan kapasitasnya untuk mengelola variasi skala dan orientasi pada gambar. Kami menerapkan teknik yang terdiri dari prapemrosesan gambar, penambahan data, dan model InceptionV3. Dengan akurasi 0.8416, *F1-score* 0.8428, *recall* 0.8805, dan presisi 0.8613, hasilnya menunjukkan kinerja yang lebih baik. Penelitian ini menggunakan InceptionV3 untuk klasifikasi citra teroris dan *non-teroris*, yang terbukti lebih berhasil daripada model sebelumnya dalam menangkap fitur-fitur rumit untuk penelitian ini.

Kata Kunci: Klasifikasi gambar teroris, Pembelajaran mendalam, InceptionV3, Deteksi gambar, Prapemrosesan gambar

Abstract

Terrorist and non-terrorist image classification is important when supporting technology-based security systems. This research aims to implement the InceptionV3 model, a deep learning model proven effective in various image classification tasks, to improve the detection accuracy on terrorist and non-terrorist image datasets. Previous research has used various models such as VGG and ResNet, but there are still challenges in capturing complex features. This study employs InceptionV3 because of its deep architecture and its capacity to manage scale and orientation variations in images. We apply a technique comprising image preprocessing, data augmentation, and InceptionV3 model. With accuracy 0.8416, F1-score 0.8428, recall 0.8805, and precision 0.8613 the outcomes revealed better performance. This work employs InceptionV3 for both terrorist and non-terrorist image classification, which showed to be more successful than past models in capturing intricate features for this work.

Keyword: *Terrorist image classification, Deep learning, InceptionV3, Image detection, Image preprocessing*

1. PENDAHULUAN

Terorisme telah menjadi salah satu tantangan global yang paling mendesak, dengan dampak yang meluas di berbagai sektor, termasuk ekonomi, keamanan nasional, dan stabilitas politik. [1] menyatakan bahwa dinamika terorisme saat ini tidak hanya berdampak pada wilayah tertentu, tetapi juga mengundang risiko global yang membutuhkan tindakan kolektif. Seiring dengan meningkatnya ancaman ini,

kemampuan untuk mendeteksi dan mengidentifikasi perilaku teroris secara tepat waktu telah menjadi prioritas bagi banyak negara. Penerapan teknologi kecerdasan buatan dan pembelajaran mesin diharapkan dapat mengatasi masalah ini dengan menyediakan metode yang lebih efisien untuk mengklasifikasikan gambar atau data yang terkait dengan kegiatan teroris.

Seiring dengan meningkatnya penggunaan teknologi kecerdasan buatan, klasifikasi terorisme menggunakan data citra telah menjadi fokus penelitian baru. [2] menyoroti bahwa penerapan pembelajaran mesin untuk klasifikasi serangan teroris menggunakan karakteristik tekstual menunjukkan hasil yang menjanjikan. Namun, kita perlu memperluas pendekatan ini pada data gambar, karena gambar sering kali memberikan konteks visual yang lebih mendalam. Dengan menggunakan model InceptionV3, penelitian ini bertujuan untuk mengeksplorasi potensi klasifikasi gambar untuk mendeteksi potensi ancaman terorisme secara akurat dan efisien.

Dalam konteks teknologi, penerapan model pembelajaran mesin memberikan peluang yang signifikan untuk meningkatkan akurasi klasifikasi gambar terkait terorisme. Beberapa penelitian [3-7] menunjukkan bahwa pendekatan komputasi lunak, termasuk penggunaan model pembelajaran mendalam seperti InceptionV3, dapat memberikan wawasan yang signifikan dalam analisis terorisme. Penelitian ini menggunakan InceptionV3, salah satu arsitektur *deep learning* yang terbukti efektif dalam tugas klasifikasi gambar, untuk membedakan gambar yang berhubungan dengan teroris dan yang tidak berhubungan dengan teroris. Pembelajaran transfer memungkinkan model untuk menggunakan pengetahuan yang diperoleh dari *domain* lain, sehingga mengurangi kebutuhan pelatihan dari awal dan meningkatkan efisiensi proses klasifikasi. Penerapan teknologi klasifikasi teroris melalui data citra dapat memperkuat pertahanan nasional dengan menyediakan alat yang lebih canggih untuk mendeteksi potensi ancaman sejak dini. Dengan menggabungkan hasil dari berbagai penelitian tersebut, penelitian ini diharapkan dapat memberikan kontribusi yang signifikan dalam klasifikasi gambar teroris dan pengembangan model *deep learning* yang lebih efektif untuk tujuan keamanan.

2. METODE

Dalam penelitian ini, total 597 gambar dikumpulkan, terdiri dari 263 gambar terkait orang dan 334 gambar terkait teror. Dataset ini terdiri dari dua kategori utama: "Orang" dan "Teror" dengan berbagai gambar di setiap kategori. Gambar-gambar tersebut telah diproses sebelumnya dan distandarisasi ke resolusi yang sesuai untuk analisis, dan jumlah total gambar dalam setiap kategori didistribusikan sesuai.

Untuk kategorisasi label gambar, kelas *LabelEncoder* dari modul *sklearn.preprocessing* digunakan. *LabelEncoder* mengubah label kategorikal menjadi nilai numerik, yang lebih cocok untuk algoritma pembelajaran mesin. Dalam hal ini, label yang sesuai dengan "Person" dan "Terror" dikodekan sebagai bilangan bulat. Proses ini mengubah label kategorikal menjadi *array* bilangan bulat, memungkinkan pemrosesan dan klasifikasi gambar yang efisien.

Untuk memastikan pelatihan, validasi, dan pengujian model yang tepat, dataset dibagi berdasarkan kategori-kategori ini. Tabel 1 dan Gambar 1 menggambarkan distribusi dan memberikan sampel representatif dari data gambar dari kedua kategori.

Tabel 1. Tabel distribusi gambar

Kategori	Gambar
<i>Terroris</i>	334
<i>Person</i>	263



Gambar 1. Sampel gambar pada dataset

2.1. Convolutional Neural Network (CNN)

Dalam beberapa tahun terakhir, pendekatan berbasis CNN [8-11] telah mencapai kesuksesan signifikan di berbagai *domain* klasifikasi gambar. Misalnya, dalam studi oleh [8], fitur-fitur yang telah dilatih sebelumnya pada CNN digunakan dalam kombinasi dengan *Extreme Learning Machine* (ELM) untuk mengklasifikasikan gambar luka kaki diabetes. Pendekatan *hybrid* ini menunjukkan efektivitas CNN dalam ekstraksi fitur, sementara ELM berfungsi sebagai pengklasifikasi yang efisien, menyoroti adaptabilitas arsitektur CNN ketika dipasangkan dengan model pembelajaran mesin lainnya. Studi ini juga menekankan pentingnya *transfer learning*, di mana CNN yang telah dilatih sebelumnya pada dataset besar dapat disesuaikan untuk menangani tugas klasifikasi spesifik. [9] mempersembahkan model fusi yang dapat diinterpretasikan yang mengintegrasikan CNN ringan dengan arsitektur *transformer* untuk mengidentifikasi penyakit daun padi.

Selain itu, [10] mengusulkan model CNN-*Transformer* cabang ganda paralel untuk klasifikasi gambar fundus. Dalam arsitektur ini, CNN bertanggung jawab untuk mempelajari fitur-fitur tingkat rendah, sementara *transformer* menangani informasi kontekstual global. Model *hybrid* ini menunjukkan bagaimana CNN tetap integral dalam tugas klasifikasi citra medis, meskipun popularitas *transformer* semakin meningkat. Model CNN-*trans* mencapai kinerja tinggi dengan efektif menangkap baik fitur lokal maupun global, sehingga menunjukkan relevansi berkelanjutan CNN dalam arsitektur *hybrid* modern. Dalam konteks klasifikasi Lepidoptera, [11]

menggunakan EfficientNet-B0, sebuah varian dari CNN, untuk mengklasifikasikan spesies kupu-kupu dan ngengat. Arsitektur EfficientNet menunjukkan bahwa CNN dapat mencapai akurasi klasifikasi yang tinggi dengan lebih sedikit parameter, memperkuat pentingnya mengoptimalkan arsitektur CNN untuk tugas-tugas spesifik dan keterbatasan sumber daya.

2.2. InceptionV3


InceptionV3 adalah model pembelajaran mendalam yang banyak digunakan untuk tugas klasifikasi gambar karena kemampuannya untuk menangkap fitur gambar yang kompleks sambil menjaga efisiensi komputasi. Dikembangkan sebagai bagian dari keluarga Inception, arsitektur ini menggabungkan prinsip desain kunci seperti modul inception, yang memungkinkan jaringan untuk mengekstrak fitur multi-skala dengan menerapkan konvolusi dari berbagai ukuran (1x1, 3x3, dan 5x5) secara paralel. Inovasi arsitektur ini memungkinkan InceptionV3 untuk menangkap pola halus dan skala besar dari gambar masukan, menjadikannya sangat efektif untuk berbagai tugas klasifikasi gambar. Beberapa studi [12-15] menerapkan InceptionV3 dalam klasifikasi. [12] meneliti tentang klasifikasi kanker paru *non*-sel kecil (NSCLC) dari gambar slide utuh. Penelitian ini menyoroti kekuatan InceptionV3 dalam mengekstraksi fitur-fitur bermakna dari gambar medis besar beresolusi tinggi. Dengan memanfaatkan arsitektur mendalam model tersebut, mereka mencapai akurasi tinggi dalam mengklasifikasikan sub tipe kanker. [13] menggunakan InceptionV3 untuk klasifikasi gambar olahraga, menunjukkan ketahanan model dalam menangani gambar dengan konteks yang bervariasi, kondisi pencahayaan, dan blur gerakan yang khas dalam fotografi olahraga. Kemampuan ekstraksi fitur multi-skala dari InceptionV3 memungkinkan model untuk secara efektif membedakan antara aktivitas olahraga, bahkan dalam kondisi visual yang menantang.

[14] membandingkan kinerja InceptionV3 dengan arsitektur CNN populer lainnya, seperti ResNet50 dan VGG19, dalam klasifikasi kematangan tomat. Hasilnya menunjukkan bahwa InceptionV3 mengungguli baik ResNet50 maupun VGG19 dalam hal akurasi dan kecepatan. Ini dapat dikaitkan dengan modul inisiasi model, yang secara efisien mengelola biaya komputasi sambil mempertahankan arsitektur yang dalam yang memungkinkan ekstraksi fitur yang lebih efektif. Kemampuan InceptionV3 untuk menyeimbangkan kedalaman dan efisiensi membuatnya ideal untuk tugas dengan sumber daya komputasi terbatas.

Selain itu, [15] menerapkan InceptionV3 untuk diagnosis COVID-19 dari gambar rontgen dada, menyoroti kegunaannya di bidang medis. Studi tersebut menekankan bahwa pemrosesan multi-skala InceptionV3 memungkinkan model untuk membedakan perbedaan halus antara paru-paru yang terinfeksi COVID-19 dan yang sehat, bahkan ketika fitur gambar tidak jelas. Kemampuan ini untuk mengekstrak fitur lokal dan global meningkatkan presisi model dalam diagnosis medis, di mana variasi kecil dalam data gambar dapat memiliki implikasi signifikan terhadap akurasi klasifikasi.

2.3. Metode

This research was conducted in stages as shown in Figure 2, starting with collecting data to testing and evaluating the model that has been built.



Gambar 2. InceptionV3 flowchart untuk klasifikasi teroris

2.4. Prapemrosesan Data

Prapemrosesan data gambar adalah tahap krusial dalam persiapan dataset untuk melatih model *deep learning* [16], [17], termasuk dalam klasifikasi gambar teroris dan *non-teroris*. Pada penelitian ini, gambar diambil dari direktori yang terstruktur berdasarkan label kelas (misalnya "teroris" dan "*non-teroris*"), dan setiap gambar diproses secara individual sebelum digunakan untuk pelatihan model. Salah satu langkah awal adalah membaca gambar menggunakan *OpenCV* yang berfungsi untuk memuat citra dari direktori yang ditentukan [18]. Setelah itu, setiap gambar dikonversi dari format BGR (*default OpenCV*) menjadi format RGB yang lebih umum digunakan dalam model *deep learning*.

Setelah gambar dimuat, langkah selanjutnya adalah *resizing* gambar menjadi ukuran yang seragam [19], dalam hal ini, 224x224 piksel. Ukuran ini dipilih karena kompatibel dengan arsitektur model InceptionV3 yang membutuhkan *input* gambar dalam dimensi tertentu. *Resizing* dilakukan menggunakan fungsi *cv2.resize*, yang memastikan bahwa setiap gambar memiliki dimensi yang konsisten sebelum dimasukkan ke dalam model. Selain itu, setiap gambar juga dikonversi menjadi *array NumPy* dan dinormalisasi dengan membagi nilai pikselnya dengan 255, yang mengubah rentang nilai piksel dari 0-255 menjadi 0-1. Normalisasi ini penting karena membantu dalam mempercepat proses pelatihan model dengan menghindari perhitungan besar dalam jaringan.

Pada akhir proses prapemrosesan, gambar-gambar yang telah diproses disimpan dalam sebuah *list*, bersama dengan label kelasnya (misalnya, teroris atau *non-teroris*). Kedua *list* ini kemudian dikonversi menjadi *array NumPy* untuk memastikan bahwa mereka dapat diolah lebih lanjut oleh model *deep learning* [20]. Bentuk dari *array* gambar dan label dicek untuk memastikan bahwa dataset siap digunakan dalam proses pelatihan model. Dengan demikian, langkah prapemrosesan ini memastikan bahwa gambar teroris dan *non-teroris* telah diubah ke dalam format yang optimal untuk diolah oleh model klasifikasi berbasis *deep learning*.

2.5. Pelatihan Model

Pada penelitian ini, model InceptionV3 diimplementasikan menggunakan arsitektur *Convolutional Neural Network* (CNN) yang terdiri dari beberapa lapisan konvolusi, *pooling*, dan lapisan *fully connected*. Dalam proses pelatihan model, setiap gambar dari dataset yang telah melalui tahap prapemrosesan digunakan sebagai *input* dengan ukuran tetap 224x224 piksel dan tiga saluran warna (RGB). Lapisan pertama dari model ini adalah lapisan *Conv2D* dengan 32 filter dan ukuran kernel 3x3, diikuti oleh lapisan *MaxPooling2D* untuk mengurangi dimensi spasial dari data dan menangkap fitur penting. Proses konvolusi dan *pooling* ini diulangi beberapa kali dengan jumlah filter yang semakin besar (64, 128, 256, dan 512) untuk menangkap fitur yang lebih kompleks dari gambar.

Setelah beberapa lapisan konvolusi dan *pooling*, gambar yang telah diproses dilewatkan ke lapisan *Flatten*, yang mengubah data multidimensi menjadi vektor satu dimensi. Vektor ini kemudian dimasukkan ke dalam lapisan *Dense* atau *fully connected* dengan 1024 unit dan fungsi aktivasi *ReLU*. Lapisan *fully connected* ini bertanggung jawab untuk melakukan klasifikasi berdasarkan fitur yang diekstraksi oleh lapisan konvolusi. Akhirnya, lapisan *output* dengan satu unit dan fungsi aktivasi *sigmoid* digunakan untuk menghasilkan prediksi biner, yaitu klasifikasi antara gambar teroris dan *non-teroris*.

2.6. Evaluasi Model

Evaluasi model dilakukan dengan menggunakan *metric* seperti *accuracy*, *precision*, *recall*, dan *f1-score* [21] seperti yang ditunjukkan pada rumus (1), (2), (3), (4)

$$Accuracy = \frac{TP+TN}{P+N} \times 100\% \#(1)$$

$$Precision = \frac{TP}{TP+FP} \#(2)$$

$$Recall = \frac{TP}{TP+FN} \#(3)$$

$$F1 - Score = 2 \times \frac{Recall \times Presisi}{Recall + Presisi} \#(4)$$

Keterangan:

True Positive (TP) : jumlah kasus positif yang diklasifikasikan positif
False Positive (FP) : jumlah kasus negatif yang diklasifikasikan positif
True Negative (TN) : jumlah kasus negatif yang diklasifikasikan negatif
False Negative (FN) : jumlah kasus positif yang diklasifikasikan negatif


3. HASIL DAN PEMBAHASAN

Pada hasil pelatihan model InceptionV3 untuk klasifikasi gambar teroris dan *non-teroris*, model menunjukkan peningkatan yang signifikan dalam akurasi seiring dengan bertambahnya *epoch*. Tabel 2 menunjukkan tabel hasil pelatihan.


Tabel 2. Tabel hasil pelatihan model InceptionV3

<i>Epoch</i>	<i>Accuracy</i>	<i>Loss</i>	<i>Val Accuracy</i>	<i>Val Loss</i>
1	0.5187	1.0075	0.5583	0.6624
2	0.5869	0.6049	0.7167	0.5346
3	0.7183	0.5193	0.7417	0.5331
4	0.8003	0.4530	0.7750	0.4370
5	0.7802	0.3953	0.7417	0.4873
6	0.8451	0.3410	0.7667	0.4197
7	0.8561	0.3547	0.7917	0.4798
8	0.8978	0.2625	0.8250	0.4231
9	0.8913	0.2413	0.7833	0.5779
10	0.9099	0.2153	0.8417	0.5061

Pada *epoch* 1, model memulai dengan *accuracy* sebesar 0.5187 pada data pelatihan dan *val accuracy* sebesar 0.5583 pada data validasi, serta *loss* yang cukup tinggi yaitu 1.0075 untuk pelatihan dan 0.6624 untuk validasi. Hal ini menunjukkan bahwa model masih dalam tahap awal pembelajaran dan belum mampu mengenali pola secara optimal dari dataset. Namun, pada *epoch* berikutnya, model mulai menunjukkan perbaikan signifikan. Seiring dengan berjalannya pelatihan, *accuracy* dan *val accuracy* terus meningkat. Pada *epoch* 4, *accuracy* pada data pelatihan meningkat menjadi 0.8003 dengan *val accuracy* mencapai 0.7750, yang menunjukkan bahwa model mulai mampu menangkap fitur-fitur penting dari gambar secara lebih baik. Pada saat ini, *loss* pada validasi juga menurun secara signifikan menjadi 0.4370, menandakan bahwa kesalahan prediksi model berkurang. Model terus mengalami penyempurnaan hingga *epoch* 10, di mana *accuracy* pelatihan mencapai 0.9099 dan *val accuracy* mencapai 0.8417, dengan *val loss* 0.5061. Angka ini mengindikasikan bahwa model telah mampu menggeneralisasi data dengan baik pada dataset validasi. Gambar 3 dan 4 menunjukkan grafik model *accuracy* dan *loss*




Gambar 3. Grafik InceptionV3 Model *Accuracy*



Gambar 4. Grafik InceptionV3 Model *Loss*

Berdasarkan *confusion matrix* yang ditunjukkan pada Gambar 5, model InceptionV3 menunjukkan performa yang baik dalam klasifikasi gambar dengan metrik sebagai berikut:



Gambar 5. *Confusion matrix*

- **True Positive (TP):** Sebanyak 59 gambar diklasifikasikan dengan benar sebagai gambar teroris (kelas 1).
- **True Negative (TN):** Sebanyak 42 gambar diklasifikasikan dengan benar sebagai gambar *non*-teroris (kelas 0).
- **False Positive (FP):** Terdapat 11 gambar yang salah diklasifikasikan sebagai teroris padahal sebenarnya adalah *non*-teroris.
- **False Negative (FN):** Terdapat 8 gambar yang salah diklasifikasikan sebagai *non*-teroris padahal sebenarnya adalah teroris.

4. SIMPULAN

Penelitian ini berhasil menunjukkan bahwa model InceptionV3 dapat memberikan kinerja yang lebih baik dalam klasifikasi citra teroris dan *non*-teroris. Dengan arsitektur yang lebih dalam dan kemampuan untuk menangani variasi skala serta orientasi gambar, InceptionV3 mampu menangkap fitur-fitur kompleks yang sulit diidentifikasi oleh model lain. Melalui penerapan prapemrosesan gambar, teknik augmentasi data, dan penggunaan model InceptionV3, penelitian ini menghasilkan akurasi 0.8167, *F1-score* 0.8533, *recall* 0.9552, dan presisi 0.7711, yang menunjukkan peningkatan kinerja secara keseluruhan. Secara keseluruhan, implementasi InceptionV3 terbukti efektif dalam klasifikasi gambar teroris dan *non*-teroris, menjadikannya pilihan yang tepat untuk mendukung sistem keamanan berbasis teknologi. Model ini dapat menangkap fitur yang rumit secara lebih akurat, meningkatkan potensi deteksi ancaman secara signifikan.

5. REFERENSI

- [1] H. S. M. Abbas and X. Xu, "Topical dynamics of terrorism from a global perspective and a call for action on global risk," *Int. J. Disaster Risk Reduct.*, vol. 110, p. 104659, Aug. 2024, doi: 10.1016/j.ijdr.2024.104659.
- [2] M. Abdalsalam, C. Li, A. Dahou, and N. Kryvinska, "Terrorism Attack Classification Using Machine Learning: The Effectiveness of Using Textual Features Extracted from GTD Dataset," *Comput. Model. Eng. Sci.*, vol. 138, no. 2, pp. 1427–1467, 2024, doi: 10.32604/cmescs.2023.029911.
- [3] S. R. Srivastava, Y. K. Meena, and G. Singh, "The landscape of soft computing applications for terrorism analysis: A review," *Appl. Soft Comput.*, vol. 113, p. 107977, Dec. 2021, doi: 10.1016/j.asoc.2021.107977.
- [4] C. Meng and N. Ghafoori, "The economic impact of terrorism in South Asia," *Socioecon. Plann. Sci.*, vol. 96, p. 102084, Dec. 2024, doi: 10.1016/j.seps.2024.102084.
- [5] B. Ghufuran and W. Breuer, "Terrorism, national security, and takeover performance," *Int. Rev. Financ. Anal.*, p. 103634, Sep. 2024, doi: 10.1016/j.irfa.2024.103634.
- [6] G. Meena, K. K. Mohbey, S. Kumar, R. K. Chawda, and S. V. Gaikwad, "Image-Based Sentiment Analysis Using InceptionV3 Transfer Learning Approach," *SN Comput. Sci.*, vol. 4, no. 3, p. 242, Mar. 2023, doi: 10.1007/s42979-023-01695-3.

- [7] W. Tyassari, Y. Jusman, S. Riyadi, and S. N. Sulaiman, "Classification of Cervical Precancerous Cell of ThinPrep Images Based on Deep Learning Model AlexNet and InceptionV3," in *2022 IEEE 11th International Conference on Communication Systems and Network Technologies (CSNT)*, IEEE, Apr. 2022, pp. 276–281. doi: 10.1109/CSNT54456.2022.9787658.
- [8] F. Arnia, K. Saddami, R. Roslidar, R. Muharar, and K. Munadi, "Towards accurate Diabetic Foot Ulcer image classification: Leveraging CNN pre-trained features and extreme learning machine," *Smart Heal.*, vol. 33, p. 100502, Sep. 2024, doi: 10.1016/j.smhl.2024.100502.
- [9] A. Chakrabarty, S. T. Ahmed, M. F. U. Islam, S. M. Aziz, and S. S. Maidin, "An interpretable fusion model integrating lightweight CNN and transformer architectures for rice leaf disease identification," *Ecol. Inform.*, vol. 82, p. 102718, Sep. 2024, doi: 10.1016/j.ecoinf.2024.102718.
- [10] S. Liu, W. Wang, L. Deng, and H. Xu, "Cnn-trans model: A parallel dual-branch network for fundus image classification," *Biomed. Signal Process. Control*, vol. 96, p. 106621, Oct. 2024, doi: 10.1016/j.bspc.2024.106621.
- [11] H. Syamsudin, S. Khalidah, and J. Unjung, "Lepidoptera Classification Using Convolutional Neural Network EfficientNet-B0," *Indones. J. Artif. Intell. Data Min.*, vol. 7, no. 1, p. 47, Nov. 2023, doi: 10.24014/ijaidm.v7i1.24586.
- [12] K. Dwivedi, A. Gupta, A. Rajpal, and N. Kumar, "Deep Learning-based NSCLC Classification from Whole-Slide Images: Leveraging Expectation-Maximization and InceptionV3," *Procedia Comput. Sci.*, vol. 235, pp. 2422–2433, 2024, doi: 10.1016/j.procs.2024.04.229.
- [13] K. Joshi, V. Tripathi, C. Bose, and C. Bhardwaj, "Robust Sports Image Classification Using InceptionV3 and Neural Networks," *Procedia Comput. Sci.*, vol. 167, pp. 2374–2381, 2020, doi: 10.1016/j.procs.2020.03.290.
- [14] J. R. Pangilinan, J. Legaspi, and N. Linsangan, "InceptionV3, ResNet50, and VGG19 Performance Comparison on Tomato Ripeness Classification," in *2022 5th International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, IEEE, Dec. 2022, pp. 619–624. doi: 10.1109/ISRITI56927.2022.10052920.
- [15] N. S. Shadin, S. Sanjana, and N. J. Lisa, "COVID-19 Diagnosis from Chest X-ray Images Using Convolutional Neural Network(CNN) and InceptionV3," in *2021 International Conference on Information Technology (ICIT)*, IEEE, Jul. 2021, pp. 799–804. doi: 10.1109/ICIT52682.2021.9491752.
- [16] M. E. Sahin, "Image processing and machine learning-based bone fracture detection and classification using X-ray images," *Int. J. Imaging Syst. Technol.*, vol. 33, no. 3, pp. 853–865, May 2023, doi: 10.1002/ima.22849.
- [17] A. Oyeranmi, B. Ronke, R. Mohammed, and A. Edwin, "Detection of Fracture Bones in X-ray Images Categorization," *J. Adv. Math. Comput. Sci.*, pp. 1–11, Jun. 2020, doi: 10.9734/jamcs/2020/v35i430265.
- [18] H. Wu, L. Xu, and N. Xiao, "Efficient and accurate segmentation of adhesive lamellae in tri-modal microstructure of titanium alloy based on OpenCV," *Mater. Charact.*, vol. 208, p. 113606, Feb. 2024, doi: 10.1016/j.matchar.2023.113606.
- [19] N. R. Billa, B. P. Das, M. Biswal, and M. Okade, "CNN based image resizing forensics for double compressed JPEG images," *J. Inf. Secur. Appl.*, vol. 81, p. 103693, Mar. 2024, doi: 10.1016/j.jisa.2023.103693.
- [20] R. V. Gilmiyarov, L. I. Galimzyanova, S. Porshnev, and O. Chernova,

- “Comparative Quality Analysis of Random Number Generators in MATLAB and NumPy packages,” in *2023 IEEE Ural-Siberian Conference on Biomedical Engineering, Radioelectronics and Information Technology (USBEREIT)*, IEEE, May 2023, pp. 293–297. doi: 10.1109/USBEREIT58508.2023.10158838.
- [21] M. Heydarian, T. E. Doyle, and R. Samavi, “MLCM: Multi-Label Confusion Matrix,” *IEEE Access*, vol. 10, pp. 19083–19095, 2022, doi: 10.1109/ACCESS.2022.3151048.