

KARAKTERISASI KERUSAKAN BANGUNAN MENGGUNAKAN INTEGRASI EFFICIENTNET-B7 DAN PCA-CLUSTERING

Adila Muhtahidah, Yunifa Muhtachul Arif, Agung Teguh Wibowo Almais

Magister Informatika, UIN Maulana Malik Ibrahim Malang

Jalan Gajayana No. 50, Dinoyo, Kecamatan Lowokwaru, Kota Malang, Jawa Timur, Indonesia

240605210005@student.uin-malang.ac.id

ABSTRAK

Penilaian cepat dan akurat terhadap kerusakan bangunan pasca bencana sangat penting untuk merencanakan respons darurat dan upaya pemulihan. Namun, metode survei lapangan secara manual sering kali berisiko dan memakan waktu, sementara metode ekstraksi fitur tradisional seperti *Gray Level Co-occurrence Matrix* (GLCM) masih memerlukan penyesuaian parameter secara manual. Penelitian ini bertujuan untuk mengusulkan pendekatan otomatis menggunakan *deep learning* untuk mengelompokkan karakteristik tingkat kerusakan bangunan. Metode yang digunakan adalah integrasi *Convolutional Neural Network* (CNN) yaitu *EfficientNet-B7* untuk ekstraksi fitur gambar yang mendalam, dipadukan dengan teknik *PCA-Clustering*. Tingkat kerusakan kemudian dikelompokkan berdasarkan indikator nilai komponen utama pertama (PC1). Hasil eksperimen menunjukkan keefektifan metode ini; pengujian pada sebuah sampel gambar bangunan menghasilkan nilai PC1 sebesar 5.000. Berdasarkan standar pengelompokan yang ada, nilai $PC1 \geq 2$ secara akurat mengindikasikan bahwa bangunan tersebut masuk dalam kategori rusak berat. Integrasi ini menawarkan alat evaluasi yang *robust* dan otomatis untuk skenario nyata penanganan pasca bencana.

Kata kunci : Tingkat Kerusakan Bangunan, Deep Learning, EfficientNet-B7, Ekstraksi Fitur, PCA-Clustering, Penilaian Pasca Bencana.

1. PENDAHULUAN

Bencana alam seperti gempa bumi [1], [2], tanah longsor [3], dan banjir [4] sering kali menyebabkan kerusakan signifikan pada infrastruktur bangunan [5], yang berdampak besar pada kehidupan manusia dan ekonomi [6].

Penilaian cepat dan akurat terhadap kerusakan bangunan pasca bencana sangat penting untuk merencanakan respons darurat dan upaya pemulihan [7].

Metode tradisional yang mengandalkan survei manual di lapangan sering kali memakan waktu dan berisiko bagi surveyor [7], [8], [9].

Pada penelitiannya Almais et al., menerapkan salah satu teknik *Image Analysis* yaitu *Gray Level Co-Occurrence Matrix* (GLCM), hasilnya teknik GLCM menghasilkan nilai fitur yang dapat mengklusterkan tingkat kerusakan bangunan pasca bencana dengan teknik *PCA-Clustering* [10].

Dengan kemajuan teknologi penginderaan jauh dan pembelajaran mesin, analisis gambar berbasis *Artificial Intelligence* (AI) telah menjadi alat yang efektif untuk penilaian kerusakan bangunan [11], [12].

Salah satunya metode *EfficientNet* yaitu sebuah arsitektur *Convolutional Neural Network* (CNN) yang efisien dan telah menunjukkan kinerja unggul dalam ekstraksi fitur dari gambar resolusi tinggi [13].

Penggunaan *EfficientNet* memungkinkan ekstraksi fitur yang lebih akurat dan efisien dari gambar kerusakan bangunan pasca bencana. Terdapat banyak jenis *EfficientNet* yaitu *EfficientNet B0*, *B1*, *B2*, *B3*, *B4*, *B5*, *B6*, dan *B7* [13].

Yang ada pada penelitian ini menggunakan *EfficientNet-B7* karena berdasarkan Tan et al.,

EfficientNet-B7 memiliki hasil yang lebih bagus dalam penerapan untuk ekstraksi fitur gambar [13].

Hasil ekstraksi fitur dapat menjadi acuan untuk mengetahui karakteristik dari suatu bangunan berdasarkan tingkat kerusakannya.

Penelitian ini mengembangkan penelitiannya Almais et al., yang menerapkan teknik ekstraksi fitur tradisional yaitu GLCM [10] dan *Wavelet Transform* [14] dengan teknik ekstraksi fitur menggunakan *Artificial Intelligence* (AI). Menggunakan turunan dari AI yaitu *Deep Learning* dengan menerapkan metode CNN yang cocok untuk ekstraksi fitur yaitu *EfficientNet*. Sehingga kelemahan dari GLCM yang masih manual untuk tuning nilai jarak dan sudut dapat teratasi dengan menggunakan teknik *EfficientNet* dalam mengekstraksi fitur suatu gambar.

Penelitian ini memiliki beberapa kontribusi, diantaranya adalah mengembangkan teknik ekstraksi fitur gambar berbasis AI, yaitu *EfficientNet-B7*, untuk mengkluster tingkat kerusakan bangunan pasca bencana. Selain itu, penelitian ini juga membuat kluster tingkat kerusakan bangunan pasca bencana alam agar sesuai dengan jumlah kluster pada penelitian Almais et al., yang mengklasifikasikan tingkat kerusakan tersebut ke dalam 3 kluster, yaitu rusak ringan, rusak sedang, dan rusak berat [15].

Kontribusi lainnya dari penelitian ini adalah membuktikan bahwa ekstraksi fitur gambar menggunakan *EfficientNet-B7* menghasilkan informasi yang dapat terbaca dan diproses dengan baik menggunakan metode *PCA-Clustering*.

Isi artikel ini menjelaskan tentang: latar belakang menggunakan *EfficientNet-B7* dan *PCA-Clustering* untuk mengetahui informasi tingkat kerusakan

bangunan pasca bencana alam dan penggunaan *EfficientNet-B7* dan *PCA-Clustering* pada beberapa penelitian pada tinjauan pustaka. Kemudian pada persiapan data dan metode penelitian menjelaskan tentang langkah-langkah dari *EfficientNet-B7*, *PCA-Clustering*, dan akusisi data. Dalam hasil dan pembahasan, menjelaskan proses eksperimen *EfficientNet-B7* dan *PCA-Clustering* menggunakan bahasa pemrograman *Phyton* untuk mengekstraksi fitur gambar bangunan pasca bencana alam dan validasi hasil ekstrasi fitur menggunakan teknik PCA. Terakhir, kesimpulan dan saran, merangkum hasil eksperimen dan peluang untuk penelitian ke depan.

2. TINJAUAN PUSTAKA

Mengekstraksi fitur gambar dapat menggunakan banyak teknik antara lain adalah GLCM, pada penelitiannya Almais et al., mengintegrasikan GLCM dengan *PCA-Clustering* untuk menentukan tingkat kerusakan bangunan pasca bencana alam dengan menggunakan input berupa gambar bangunan [10].

Beberapa penelitian terdahulu telah menjadi landasan bagi studi ini, khususnya terkait ekstraksi fitur dan pengelompokan citra.

Penelitian oleh Christaki, M. (2022) [15] berfokus pada penggunaan teknik ekstraksi *Gray Level Co-occurrence Matrix* (GLCM) untuk membuat sistem pencarian gambar berbasis konten. Pendekatan ini memiliki kelebihan berupa akurasi pengambilan yang mencapai 88%, namun memiliki kekurangan karena penentuan sudut dan rentang jaraknya masih harus diatur secara manual. Penelitian ini berhasil mencapai akurasi hingga 60% dengan *silhouette score* di atas 0,550, akan tetapi penentuan rentang GLCM dan jumlah klusternya juga masih dilakukan secara manual.

Pada tahun yang sama, A. T. W. Almais et al. (2024) [10] memfokuskan penelitiannya untuk menentukan tingkat kerusakan bangunan pasca bencana menggunakan ekstraksi fitur GLCM dan *PCA-Clustering*. Penelitian tersebut sangat membantu proses evaluasi dengan menghasilkan tiga tingkat kluster kerusakan, tetapi masih memiliki keterbatasan karena ekstraksi fiturnya diatur secara manual dan belum memanfaatkan arsitektur *deep learning* (AI).

Dari kelemahan tersebut maka pada penelitian ini mengubah teknik ekstraksi fiturnya menggunakan metode *EfficientNet*. *EfficientNet* merupakan salah satu jenis metode AI yang dapat mengekstraksi fitur khusus gambar menjadi sebuah nilai fitur. *EfficientNet* adalah salah satu jenis metode CNN yang merupakan teknik AI yang biasanya untuk mengolah data berupa gambar [16], [17], [18], [19], [20].

Sedangkan *PCA-Clustering* merupakan pengembangan dari teknik reduksi data yaitu PCA, yang awalnya PCA hanya dapat untuk mereduksi data tetapi pada penelitiannya Almais et al, dapat menjadikan PCA untuk mengcluster suatu data yang

unsupervised sampai menjadi data tersebut dapat *supervised* (berlabel) [21].

Sehingga PCA selain dapat menjadi teknik *clustering* data modern, dapat juga sebagai teknik untuk labeling suatu kumpulan data [21].

Gabungan dua metode yaitu *EfficientNet-B7* untuk mengekstraksi fitur gambar, kemudian hasil ekstraksi fitur gambar menjadi input pada *PCA-Clustering* untuk mengetahui informasi yang ada pada gambar tersebut.

3. PERSIAPAN DATA DAN METODE PENELITIAN

Pada bab ini menjelaskan dua sub-bab, yaitu persiapan data dan metode yang diusulkan. Sub-bab pertama, persiapan data, menjelaskan cara mendapatkan data dan batasan data untuk penelitian ini. Sub-bab kedua, menjelaskan langkah-langkah dari metode *EfficientNet-B7* dan *PCA-Clustering*.

3.1. Persiapan Data


Penelitian ini menggunakan dataset citra bangunan pasca bencana alam yang bersumber dari repositori publik seperti Kaggle dan pencarian web (Google). Dataset terdiri dari sekitar 100 gambar yang menggambarkan berbagai keadaan kerusakan struktural dari bencana alam yang berbeda (misalnya, gempa bumi, banjir, tanah longsor). Citra-citra tersebut bervariasi dalam resolusi dan kondisi pencahayaan untuk merepresentasikan skenario dunia nyata. Untuk penelitian ini berfokus pada subset yang representatif untuk memvalidasi alur kerja yang sudah ada, dengan rencana validasi skala besar pada riset masa depan.

3.2. Metode Penelitian

Pada sub bab metode penelitian menjelaskan tentang alur dari metode *EfficientNet-B7* dan *PCA-Clustering* dalam mengekstraksi fitur gambar bangunan pasca bencana alam, sehingga dapat menghasilkan informasi *cluster* tingkat kerusakan bangunan pasca bencana alam. Pada Gambar 1 merupakan alur dari metode *EfficientNet-B7* dan *PCA-Clustering*.

Pada Gambar 1 merupakan alur kerja dari penelitian ini yang terdiri dari tiga tahap utama: Input dan Pra-pemrosesan Citra, Ekstraksi Fitur Dalam, serta *Clustering* dan Pelabelan Berbasis PCA. Berikut merupakan penjelasan dari setiap alur:

Input: *Initialization and Image input*, mengetahui inialisasi suatu model merupakan langkah awal dalam membaca data input yang menjadi suatu jalur validasi suatu kebenaran suatu data [22], [23]. Pada penelitian ini mengetahui inialisasi dari model *EfficientNet-B7*, karena *EfficientNet-B7* memiliki hasil ekstraksi fitur yang terbaik jika dibandingkan dengan jenis *EfficientNet* lainnya [13]. Kemudian, menginputkan jalur (path) ke gambar bangunan untuk memvalidasi keberadaan suatu data.



Gambar 1. Alur metode *Efficientnet-B7* dan PCA untuk menentukan tingkat kerusakan bangunan pasca bencana alam

Process: *Image Feature Extraction, Adaptive PCA Analysis, and Determination of Level of Damage*. Setelah mendapatkan jalur gambar yang sudah tervalidasi keberadaannya maka proses selanjutnya adalah proses analisis. Proses analisis meliputi beberapa langkah antara lain ekstraksi fitur menggunakan *EfficientNet-B7*. Ekstraksi fitur merupakan proses mengubah gambar menjadi fitur baru yaitu berupa nilai numerik yang merupakan hasil perubahan dari gambar menjadi sebuah nilai numerik [24], [25].


Kemudian hasil ekstraksi fitur menginterpretasikan ke dalam lima ukuran tekstur

statistik yaitu *fiture entropy, nomalized stdd, contrast, homogeneity*, dan *skewness*. Setelah itu nilai masing-masing tekstur masuk proses analisis PCA yang adaptif berdasarkan karakteristik tekstur yang memiliki nilai dari hasil PC1 dan PC2. Untuk menentukan tingkat kerusakan bangunan pasca bencana alam menggunakan nilai yang ada pada PC1 [21].

Output: *Result Visualization and Reporting*, hasil analisis berupa visualisasi dari hasil karakteristik hasil ekstraksi fitur yang sudah tervisualisasi dengan sumbu x (PC1) dan y (PC2). Visualisasi merupakan hasil akhir yang dapat berupa hasil 2 dimensi ataupun 3 dimensi yang dapat menampilkan informasi [26]. Pada penelitian ini visualisasi hasil akhir memberi informasi tentang tingkat kerusakan bangunan pasca bencana alam. Hasil akhirnya mengubah *clustering* yang *unsupervised* menjadi output yang *supervised* dengan label semantik yang jelas.

4. HASIL DAN PEMBAHASAN

Pada bab hasil menjelaskan tentang proses dalam menentukan tingkat kerusakan bangunan menggunakan *EfficientNet-B7* dan *PCA-Clustering*. Proses input gambar sampai bentuk visualisasi hasil terlihat pada Gambar 2 yang merupakan bentuk hasil akhir dari proses penerapan *EfficientNet-B7* dan *PCA-Clustering* dalam menentukan tingkat kerusakan bangunan pasca bencana alam.



Gambar 2. Visualisasi hasil penerapan *EfficientNet-B7* dan *PCA-Clustering*

Pada Gambar 2 terlihat bahwa terdapat beberapa langkah untuk menentukan visualisasi hasil. Berikut merupakan keterangan proses dari langkah-langkah pada Gambar 2:

Langkah 1: Penyajian Data Kasus dan Metodologi Singkat, memulai dengan menginputkan gambar bangunan pasca bencana alam sebagai objek kasus. Untuk input gambarnya terdapat pada Gambar 3. Kemudian Gambar 3 masuk proses mengidentifikasi objek agar dapat menggunakan pendekatan analisis yang tepat. Pada penelitian ini menggunakan pendekatan analisis PCA yang menggunakan input data hasil dari ekstraksi fitur metode *EfficientNet-B7*.



Gambar 3. Input data bangunan pasca bencana alam

Langkah 2: Analisis Parameter Tekstur, pada tahapan ini merupakan tahapan proses mengekstraksi fitur gambar menggunakan teknik *EfficientNet-B7* yang menghasilkan nilai *figure entropy*, *normalized std*, *contrast*, *homogeneity*, dan *skewness*. Untuk masing-masing fitur memiliki fungsi yang berbeda-beda seperti *figure entropy* berfungsi untuk mengetahui kompleksitas dari nilai fitur, *normalized std* berfungsi untuk mengetahui nilai dari variasi dari hasil nilai fitur, *contrast* merupakan gambaran dari nilai kekuatan tepi dari hasil ekstraksi fitur menggunakan gambar, sedangkan *homogeneity* merupakan nilai dari keseragaman nilai fitur hasil dari ekstraksi fitur gambar, dan *skewness* merupakan nilai yang menggambarkan distribusi asimetri dari hasil ekstraksi fitur gambar. Gambar 3 menghasilkan *characteristics* nilai *figure entropy*, *normalized std*, *contrast*, *homogeneity*, dan *skewness* yang berbeda-beda, untuk melihat nilai semua fitur tersebut terdapat pada Tabel 1.

Tabel 1. Nilai Texture characteristics

Fitur	
Nama	Nilai
<i>Figure Entropy</i>	0.9547
<i>Normalized Std</i>	4.7592
<i>Contrast</i>	1.0000
<i>Homogeneity</i>	0.1736
<i>Skewness</i>	1.3967

Hasil nilai *texture characteristics* Gambar 3 sudah terlihat pada Tabel 1 maka langkah selanjutnya menganalisis hasil kuantitatif menggunakan PCA-Clustering. Proses awal PCA-Clustering adalah menggunakan Tabel 1 sebagai input data untuk mengetahui pengelompokan data dari semua nilai *texture characteristics*. Jika sudah mengetahui *cluster* dari semua data yang ada pada Tabel 1 maka langkah selanjutnya memberi label dari masing-masing *cluster* berdasarkan penelitiannya Almais et al, yang membahas standard nilai PC1 tingkat kerusakan bangunan pasca bencana alam [21].


Tabel 2 merupakan standard tingkat kerusakan bangunan pasca bencana alam berdasarkan nilai PC1.

Tabel 2. Standard nilai PC1 [21].

Nilai PC1	Label
$PC1 < 0$	Rusak Ringan
$0 \leq PC1 < 2$	Rusak Sedang
$PC1 \geq 2$	Rusak Berat

Hasil Gambar 3 berdasarkan hasil *texture characteristics* yang ada pada Tabel 2 yang sudah masuk proses PCA-Clustering menghasilkan nilai PC1 adalah 5.000, nilai PC1 tersebut lebih dari 2, maka Gambar 3 memiliki informasi tingkat kerusakan bangunan rusak berat.

Langkah 3: Visualisasi Hasil, hasil nilai PC1 merupakan nilai koordinat sumbu x untuk visualisasi 2 dimensi. Dengan menggunakan grafik 2 dimensi dapat untuk menggambarkan letak nilai koordinat hasil dari PC1, pada langkah 2 sudah menjelaskan nilai dari PC1. Sehingga nilai PC1 tersebut tervisualisasi seperti pada Gambar 4, yang menjelaskan letak dari nilai PC1 terletak pada titik koordinat lebih dari 2. Sehingga memiliki label informasi rusak berat. Dengan menggunakan visualisasi 2 dimensi dapat memudahkan pembaca dalam memvisualisasikan temuannya secara langsung.



Gambar 4. Hasil visualisasi titik koordinat PC1

Berdasarkan hasil analisis menggunakan input Gambar 3 mengindikasikan bahwa masuk *cluster* tingkat kerusakan bangunan pasca bencana alam yaitu rusak berat. Gambar 3 terdeteksi masuk *cluster* rusak berat karena hasil ekstraksi fitur memiliki nilai PC1 lebih besar dari 2 yaitu 5.000. Dari hasil tersebut terdapat beberapa hal yang menarik untuk menjadi pembahasan dan diskusi untuk keberlanjutan dan keterbaruan dari peneliti ini:

- Validasi hasil *clustering* dan labeling: Nilai koordinat PC1 yang lebih dari 2 (yaitu 5.000) menunjukkan bahwa tingkat kerusakan pada Gambar 3 adalah rusak berat. Hal tersebut memberi makna bahwa hasil ekstraksi fitur pada Gambar 3 memiliki karakteristik bangunan yang sudah hancur. Berdasarkan penelitiannya Bachriwindi et al, bahwa untuk mengetahui tingkat kerusakan bangunan pasca bencana alam dapat menggunakan 5 kriteria yaitu kondisi bangunan, struktur kondisi bangunan, kondisi fisik bangunan rusak, fungsi bangunan, dan kondisi pendukung lainnya [7]. Jadi Gambar 3 memiliki informasi rusak berat karena hasil nilai ekstraksi fitur menggambarkan 5 kriteria tersebut memiliki nilai kerusakan maksimal.

- b. Pendekatan yang Efektif: menerapkan teknik PCA-Clustering untuk menganalisis hasil ekstraksi fitur gambar kerusakan bangunan pasca bencana alam sudah terbukti mampu, hasil yang sesuai dengan informasi yang sebenarnya. Hal tersebut menunjukkan bahwa PCA-Clustering sudah cukup robust untuk menginterpretasikan karakteristik kerusakan bangunan pasca bencana alam menggunakan data gambar (citra) dengan mengandalkan pola tekstur dan fitur yang unik pada setiap input data gambar (citra).
- c. Future work: walaupun gambar 4 sudah muncul informasi tingkat kerusakan bangunannya dengan menerapkan gabungan hasil ekstraksi fitur dengan EfficientNet-B7 dan PCA-Clustering, masih perlu inspeksi atau validasi dari ahli struktur bangunan atau insinyur teknik sipil yang dapat menjadi sebagai salah satu bentuk validasi dari hasil temuan penelitian ini. Selain itu dapat menjadi identifikasi awal pada setiap kerusakan bangunan pasca bencana alam yang mungkin terlewat oleh analisis otomatis yang ada pada penelitian ini. Secara keseluruhan pada penelitian ini memberikan hasil analisis awal yang positif pada Gambar 4 yang memberikan informasi rusak berat, namun perlu adanya validasi lebih lanjut dari ahli struktur bangunan dan tindakan pemeliharaan bangunan yang sesuai dengan tingkat kerusakannya.

5. KESIMPULAN DAN SARAN

Penelitian ini menyimpulkan bahwa integrasi EfficientNet-B7 dan PCA-Clustering merupakan metode yang objektif dan konsisten (*robust*) untuk mengevaluasi tingkat kerusakan bangunan pasca bencana alam. EfficientNet-B7 digunakan khusus untuk mengekstraksi lima fitur gambar (seperti *entropy*, *normalized std*, dll.), yang kemudian diproses dan divisualisasikan menggunakan PCA-Clustering. Hasil pengujian menunjukkan nilai PC1 sebesar 5.000, yang secara akurat mengklasifikasikan bangunan ke dalam kategori "rusak berat" ($PC1 \geq 2$) sesuai dengan standar dan riset terdahulu. Meskipun metode ini sangat potensial dan berguna untuk evaluasi cepat di lapangan pada kondisi darurat, validasi lebih lanjut dari ahli struktur bangunan tetap diperlukan agar penerapannya lebih terjamin dan bermanfaat bagi *stakeholder*.

DAFTAR PUSTAKA

- [1] A. Fariza, N. P. Abhimata, and J. A. N. Hasim, "Earthquake disaster risk map in east Java, Indonesia, using analytical hierarchy process — Natural break classification," in *2016 International Conference on Knowledge Creation and Intelligent Computing (KCIC)*, IEEE, Jun. 2016, pp. 141–147. doi: 10.1109/KCIC.2016.7883638.
- [2] P. Supendi *et al.*, "Relocated aftershocks and background seismicity in eastern Indonesia shed light on the 2018 Lombok and Palu earthquake sequences," *Geophys. J. Int.*, vol. 221, no. 3, pp. 1845–1855, Jun. 2020, doi: 10.1093/gji/ggaa118.
- [3] A. H. Tantri and N. A. Rakhmawati, "Designing A Natural Disaster Ontology for Indonesia," in *2019 12th International Conference on Information & Communication Technology and System (ICTS)*, IEEE, Jun. 2019, pp. 130–134. doi: 10.1109/ICTS.2019.8850979.
- [4] H. Riza, E. W. Santoso, I. G. Tejakusuma, and F. Prawiradisastara, "Advancing Flood Disaster Mitigation in Indonesia Using Machine Learning Methods," in *2020 International Conference on ICT for Smart Society (ICISS)*, IEEE, Jun. 2020, pp. 1–4. doi: 10.1109/ICISS50791.2020.9307561.
- [5] R. K. Adhikari *et al.*, "GLOSI taxonomy: A tool for 'seismic risk assessment' oriented classification of school buildings," *International Journal of Disaster Risk Reduction*, vol. 87, p. 103594, Jun. 2023, doi: 10.1016/j.ijdr.2023.103594.
- [6] A. Nugroho *et al.*, "Impacts of village fund on post disaster economic recovery in rural Aceh Indonesia," *International Journal of Disaster Risk Reduction*, vol. 70, p. 102768, Jun. 2022, doi: 10.1016/j.ijdr.2021.102768.
- [7] A. Bachriwindi, E. K. Putra, U. M. Munawaroh, and A. T. W. Almais, "Implementation of Web-Based Weighted Product Use Decision Support System to Determine the Post-Disaster Damage and Loss," *J. Phys. Conf. Ser.*, vol. 1413, no. 1, p. 12019, Jun. 2019, doi: 10.1088/1742-6596/1413/1/012019.
- [8] A. T. W. Almais, M. Sarosa, and M. A. Muslim, "Implementation Of Multi Experts Multi Criteria Decision Making For Rehabilitation And Reconstruction Action After A Disaster," *MATICS*, vol. 8, no. 1, p. 27, Jun. 2016, doi: 10.18860/mat.v8i1.3480.
- [9] A. T. W. Almais, . Fatchurrohman, K. F. H. Holle, K. S. Kinasih, D. A. Wiranti, and S. Y. Yasin, "Implementation Fuzzy Weighted Product Preparation Post Disaster Reconstruction and Rehabilitation Action based Dynamics Decision Support System," in *Proceedings of the International Conferences on Information System and Technology*, SCITEPRESS - Science and Technology Publications, 2019, pp. 272–277. doi: 10.5220/0009909002720277.
- [10] A. T. W. Almais *et al.*, "Characterization of Structural Building Damage in Post-Disaster using GLCM-PCA Analysis Integration," *IEEE Access*, pp. 1–1, 2024, doi: 10.1109/ACCESS.2024.3469637.
- [11] Z. Zheng, Y. Zhong, J. Wang, A. Ma, and L. Zhang, "Building damage assessment for rapid disaster response with a deep object-based semantic change detection framework: From natural disasters to man-made disasters," *Remote*

- Sens. Environ.*, vol. 265, p. 112636, Nov. 2021, doi: 10.1016/j.rse.2021.112636.
- [12] J. Tang, S. Yang, S. Huang, and B. Xiao, "Remote Sensing Building Damage Assessment Based on Machine Learning," *International Journal of Advanced Network, Monitoring and Controls*, vol. 9, no. 3, pp. 1–12, Sep. 2024, doi: 10.2478/ijanmc-2024-0021.
- [13] M. Tan and Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," May 2019, [Online]. Available: <http://arxiv.org/abs/1905.11946>
- [14] P. Purnamasari, M. Imamudin, S. Zaman, A. Syauqi, and A. T. W. Almais, "Clustering of Post-Disaster Building Damage Levels Using Discrete Wavelet Transform and Principal Component Analysis," *Journal of Information Technology and Cyber Security*, vol. 3, no. 1, pp. 33–44, Jan. 2025, doi: 10.30996/jitcs.12270.
- [15] M. Christaki, C. Vasilakos, E.-E. Papadopoulou, G. Tataris, I. Siarkos, and N. Soulakellis, "Building Change Detection Based on a Gray-Level Co-Occurrence Matrix and Artificial Neural Networks," *Drones*, vol. 6, no. 12, p. 414, Dec. 2022, doi: 10.3390/drones6120414.
- [16] C. B. Gonçalves, J. R. Souza, and H. Fernandes, "CNN architecture optimization using bio-inspired algorithms for breast cancer detection in infrared images," *Comput. Biol. Med.*, vol. 142, p. 105205, Jun. 2022, doi: 10.1016/j.compbimed.2021.105205.
- [17] D. Han, Q. Liu, and W. Fan, "A new image classification method using CNN transfer learning and web data augmentation," *Expert Syst. Appl.*, vol. 95, pp. 43–56, Jun. 2018, doi: 10.1016/j.eswa.2017.11.028.
- [18] F. Wagner, A. Eltner, and H.-G. Maas, "River water segmentation in surveillance camera images: A comparative study of offline and online augmentation using 32 CNNs," *International Journal of Applied Earth Observation and Geoinformation*, vol. 119, p. 103305, Jun. 2023, doi: 10.1016/j.jag.2023.103305.
- [19] W. F. Hendria, Q. T. Phan, F. Adzaka, and C. Jeong, "Combining transformer and CNN for object detection in UAV imagery," *ICT Express*, Jun. 2021, doi: 10.1016/j.ict.2021.12.006.
- [20] S. Kumar and D. Kumar, "Human brain tumor classification and segmentation using CNN," *Multimed. Tools Appl.*, vol. 82, no. 5, pp. 7599–7620, Feb. 2023, doi: 10.1007/s11042-022-13713-2.
- [21] A. T. W. Almais *et al.*, "Principal Component Analysis-Based Data Clustering for Labeling of Level Damage Sector in Post-Natural Disasters," *IEEE Access*, p. 1, 2023, doi: 10.1109/ACCESS.2023.3275852.
- [22] J. Hariharakrishnan, S. Mohanavalli, Srividya, and K. B. Sundhara Kumar, "Survey of pre-processing techniques for mining big data," in *2017 International Conference on Computer, Communication and Signal Processing (ICCCSP)*, IEEE, Jan. 2017, pp. 1–5. doi: 10.1109/ICCCSP.2017.7944072.
- [23] M. Shahnawaz and M. Kumar, "A Comprehensive Survey on Big Data Analytics: Characteristics, Tools and Techniques," *ACM Comput. Surv.*, vol. 57, no. 8, pp. 1–33, Aug. 2025, doi: 10.1145/3718364.
- [24] K. Foysal Haque, F. Farhan Haque, L. Gandy, and A. Abdelgawad, "Automatic Detection of COVID-19 from Chest X-ray Images with Convolutional Neural Networks," in *2020 International Conference on Computing, Electronics & Communications Engineering (iCCECE)*, IEEE, Aug. 2020, pp. 125–130. doi: 10.1109/iCCECE49321.2020.9231235.
- [25] S. Hallur and A. Gavade, "Image Feature Extraction Techniques: A Comprehensive Review," *Franklin Open*, p. 100366, Sep. 2025, doi: 10.1016/j.fraope.2025.100366.
- [26] P. Krauss *et al.*, "Analysis and visualization of sleep stages based on deep neural networks," *Neurobiol. Sleep Circadian Rhythms*, vol. 10, p. 100064, May 2021, doi: 10.1016/j.nbscr.2021.100064.