

***CLUSTERING KERUSAKAN BANGUNAN PASCABENCANA ALAM
MENGUNAKAN INTEGRASI *EFFICIENTNET-B7* DAN PCA***

TESIS

**oleh:
ADILA MUJTAHIDAH
NIM. 240605210005**



**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

***CLUSTERING KERUSAKAN BANGUNAN PASCABENCANA ALAM
MENGUNAKAN INTEGRASI *EFFICIENTNET-B7* DAN PCA***

TESIS

**Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Magister Komputer (M.Kom)**

**Oleh:
ADILA MUJTAHIDAH
NIM. 240605210005**

**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

HALAMAN PERSETUJUAN

***CLUSTERING* KERUSAKAN BANGUNAN PASCABENCANA ALAM MENGUNAKAN INTEGRASI *EFFICIENTNET-B7* DAN PCA**

TESIS

oleh:
ADILA MUJTAHIDAH
NIM. 240605210005

Telah diperiksa dan disetujui untuk diuji:
Tanggal: 22 Mei 2026

Pembimbing I,



Dr. Ir. Yunifa Miftachul Arif, M.T
NIP: 19830616 201101 1 004

Pembimbing II,



Dr. Agung Teguh Wibowo A, M.T
NIP. 19860301202321 1 016

Mengetahui dan Mengesahkan
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Prof. Dr. Ir. Muhammad Faisal, S.Kom., M.T
NIP. 19740510 200501 1 007

HALAMAN PENGAJUAN

***CLUSTERING* KERUSAKAN BANGUNAN PASCABENCANA ALAM
MENGUNAKAN INTEGRASI *EFFICIENTNET-B7* DAN *PCA***

TESIS

Diajukan kepada:

**Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk Memenuhi Salah Satu Persyaratan Dalam
Memperoleh Gelar Magister Komputer (M.Kom)**

Oleh:

**ADILA MUJTAHIDAH
NIM. 240605210005**

**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

HALAMAN PENGESAHAN

CLUSTERING KERUSAKAN BANGUNAN PASCABENCANA ALAM MENGUNAKAN INTEGRASI *EFFICIENTNET-B7* DAN PCA

TESIS

oleh:
ADILA MUJTAHIDAH
NIM. 240605210005

Telah Dipertahankan di Depan Dewan Penguji Tesis
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan

untuk Memperoleh Gelar Magister Komputer (M.Kom)

Tanggal:

Susunan Dewan Penguji

- Penguji I : Dr. Totok Chamidy, M. Kom
NIP. 19691222 200604 1 001
- Penguji II : Dr. Irwan Budi Santoso, M.Kom
NIP. 19770103 201101 1 004
- Pembimbing I : Dr. Ir. Yunifa Miftachul Arif, M.T
NIP: 19830616 201101 1 004
- Pembimbing II : Dr. Agung Teguh Wibowo Almais, M.T
NIP. 19860301202321 1 016

Mengetahui dan Mengesahkan
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Prof. Dr

Prof. Dr. J. Muhammad Faisal, S.Kom., M.T
NIP. 19740510 200501 1 007

HALAMAN PERNYATAAN

Saya yang bertanda tangan dibawah ini:

Nama : Adila Mujtahidah
NIM : 240605210005
Program Studi : Magister Informatika
Fakultas : Sains dan Teknologi

Menyatakan dengan sebenarnya bahwa Tesis yang saya tulis ini benar-banar merupakan hasil karya saya sendiri, bukan merupakan pengambilalihan data, tulisan atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan Tesis ini hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 22 Mei 2026
Yang Membuat Pernyataan,

Adila Mujtahidah
240605210005

MOTTO

*Extracting the best features of life, reducing the weights of challenges, and
clustering endless love from Ayska, Aisy, and Aishwa into this scientific journey.*

HALAMAN PERSEMBAHAN

Karya ini kutitipkan pada semesta, didekasikan seutuhnya untuk tiga permata hati pelipur lara:

Ayska Marsyela Wibowo, Aisy Marla Wibowo, dan Aishwa Maula Wibowo kalian adalah bait-bait doa yang menjelma menjadi kekuatan. Maafkan untuk detak waktu bermain yang sempat tercuri oleh bisingnya baris kode dan rumitnya analisis data.

Keberhasilan ini adalah pesan sunyi yang mama simpan untuk masa depan kalian: bahwa kelak, tidak ada dinding yang terlalu tinggi untuk membatasi mimpi-mimpi kalian sebagai perempuan.

Tumbuhlah menjadi jiwa yang tangguh, cerdas, dan shalihah. Di setiap klaster keberhasilan yang mama tuju, nama kalian adalah esensi kebahagiaan yang paling nyata.

Malang, 22 Mei 2026

Adila Mujtahidah

KATA PENGANTAR

Assalamu'alaikum Wr. Wb.

Syukur alhamdulillah penulis haturkan kehadiran Allah SWT yang telah melimpahkan Rahmat dan Hidayah-Nya, sehingga penulis dapat menyelesaikan studi di Program Studi Magister Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang sekaligus menyelesaikan Tesis ini dengan baik

Selanjutnya penulis haturkan ucapan terima kasih seiring do'a dan harapan jazakumullah ahsanal jaza' kepada semua pihak yang telah membantu terselesaikannya Tesis ini. Ucapan terima kasih ini penulis sampaikan kepada:

1. Ibu Prof. Dr. Hj. Ilfi Nur Diana, M.Si, CAHRM, CRMP., selaku Rektor UIN Maulana Malik Ibrahim Malang.
2. Bapak Dr. H. Agus Mulyono, M.Si., selaku Dekan Fakultas Sains dan Teknologi UIN Maulana Malik Ibrahim Malang.
3. Bapak Prof. Dr. Muhammad Faisal, M.T., selaku Ketua Program Studi Magister Informatika UIN Maulana Malik Ibrahim Malang.
4. Bapak Dr. Ir. Yunifa Miftachul Arif, M.T., selaku Dosen Pembimbing I, yang telah meluangkan waktu, tenaga, dan pikiran dengan penuh kesabaran dalam memberikan arahan, bimbingan, dan motivasi yang tak ternilai harganya selama proses penelitian ini.

5. Bapak Dr. Agung Teguh Wibowo Almais, M.T., selaku Dosen Pembimbing II, yang telah memberikan masukan, koreksi, dan wawasan berharga demi kesempurnaan penelitian ini.
6. Bapak Dr. Totok Chamidy, M. Kom., selaku penguji I dan Bapak Dr. Irwan Budi Santoso, M.Kom., selaku penguji II, Fakultas Sains dan Teknologi UIN Maulana Malik Ibrahim Malang, atas ilmu dan pelayanan yang telah diberikan.
7. Ibu Dr. Ririen Kusumawati, M.Kom. selaku dosen wali yang telah menjadi penasehat akademik.
8. Segenap civitas akademika Program Studi Magister Informatika, khususnya para dosen yang telah memberikan ilmu dan bimbingan selama masa studi.
9. Segenap keluarga, yang selalu memberikan semangat dan motivasi hingga saya dapat menyelesaikan tesis ini.
10. Seluruh pihak yang tidak dapat penulis sebutkan satu persatu, yang telah memberikan bantuan baik secara langsung maupun tidak langsung.

Penulis menyadari bahwa dalam penyusunan Tesis ini masih terdapat kekurangan dan penulis berharap semoga Tesis ini bisa memberikan manfaat kepada para pembaca khususnya bagi penulis secara pribadi. Amin Ya Rabbal Alamin.

Wassalamu'alaikum Wr. Wb.

Malang, 22 Mei 2026

Adila Mujtahidah
NIM. 240605210005

ABSTRAK

Menilai kerusakan bangunan dengan cepat dan akurat setelah bencana alam sangat penting untuk tanggap darurat dan pemulihan. Walaupun metode tradisional seperti Gray Level Co-occurrence Matrix (GLCM) yang terintegrasi dengan Principal Component Analysis (PCA) sudah dapat mengetahui karakterisasi kerusakan berbasis tekstur [1], pendekatan tersebut bergantung pada ekstraksi fitur yang masih manual dan memerlukan penyesuaian parameter secara manual (misalnya, jarak piksel, sudut), dan kurang memiliki daya representasi dari pembelajaran mendalam. Untuk mengatasi keterbatasan tersebut maka penelitian ini memperkenalkan kerangka kerja berbasis pembelajaran mendalam yang menggantikan GLCM dengan EfficientNet-B7 untuk ekstraksi fitur otomatis dan kuat, sambil mempertahankan pengelompokan berbasis PCA untuk kategorisasi kerusakan bangunan pasca bencana alam. *EfficientNet*-B7 mengekstrak fitur spasial dan semantik tingkat tinggi dari gambar bangunan pascabencana, yang kemudian direduksi dan dikelompokkan menggunakan teknik PCA. Dengan menggunakan komponen utama pertama (PC1) sebagai indikator kerusakan, hasilnya dapat mengklasifikasikan bangunan ke dalam tiga tingkat kerusakan: rusak ringan ($PC1 < 0$), rusak sedang ($0 \leq PC1 < 2$), dan rusak berat ($PC1 \geq 2$). Hasil eksperimen menunjukkan bahwa teknik tersebut tidak hanya mengotomatisasi proses ekstraksi fitur tetapi juga mencapai daya diskriminatif yang lebih tinggi dibandingkan dengan GLCM-PCA, sebagaimana dibuktikan oleh nilai PC1 yang jelas sebesar 5.000 untuk sampel yang rusak berat. Penelitian ini mengembangkan penelitian berbasis GLCM sebelumnya dengan menghilangkan ketergantungan parameter manual, meningkatkan kekayaan fitur, dan menawarkan pengembangan saluran dengan pembelajaran mendalam yang dapat terintegrasi dengan penilaian pasca-bencana. Integrasi antara EfficientNet-B7 dan PCA-Clustering merupakan bentuk usulan yang menunjukkan potensi kuat untuk aplikasi manajemen bencana di dunia nyata.

Keyword: *EfficientNet*-B7, *PCA-Clustering*, *Feature Ekstration*, Kerusakan Bangunan

ABSTRACT

Rapidly and accurately assessing building damage after a natural disaster is crucial for emergency response and recovery. Although traditional methods like the Gray Level Co-occurrence Matrix (GLCM) integrated with Principal Component Analysis (PCA) can characterize texture-based damage, this approach relies on manual feature extraction, requires manual parameter tuning (e.g., pixel distance, angles), and lacks the representational power of deep learning. To address these limitations, this study introduces a deep learning-based framework that replaces GLCM with EfficientNet-B7 for automated and robust feature extraction, while retaining PCA-based clustering for post-disaster building damage categorization. EfficientNet-B7 extracts high-level spatial and semantic features from post-disaster building imagery, which are then reduced and clustered using PCA techniques. By utilizing the first principal component (PC1) as a damage indicator, the results classify buildings into three damage levels: light damage ($PC1 < 0$), moderate damage ($0 \leq PC1 < 2$), and heavy damage ($PC1 \geq 2$). Experimental results demonstrate that this technique not only automates the feature extraction process but also achieves higher discriminative power compared to GLCM-PCA, as evidenced by a clear PC1 value of 5,000 for heavily damaged samples. This study advances previous GLCM-based research by eliminating manual parameter dependency, enhancing feature richness, and offering a deep learning pipeline development that integrates seamlessly with post-disaster assessment. The integration of EfficientNet-B7 and PCA-Clustering represents a proposed framework with strong potential for real-world disaster management applications.

Keywords: EfficientNet-B7, PCA-Clustering, Feature Extraction, Building Damage

الملخص

يُعدّ التقييم السريع والدقيق لأضرار المباني بعد الكوارث الطبيعية أمراً بالغ الأهمية لجهود الاستجابة المدمجة مع تحليل (GLCM) الطارئة والتعافي. ورغم أن الطرائق التقليدية مثل مصفوفة التزامن الرمادية تستطيع تحديد خصائص الأضرار المعتمدة على النسيج [1]، إلا أن هذه (PCA) المكونات الرئيسية المقاربات تعتمد على استخلاص المعالم يدوياً، وتتطلب ضبطاً يدوياً للمعاملات (كمسافة البكسل والزاوية)، وتفتقر إلى قدرة التمثيل التي يوفرها التعلّم العميق. وللتغلب على هذه القيود، يقدم هذا البحث لاستخلاص EfficientNet-B7 بشبكة GLCM إطاراً عملياً قائماً على التعلّم العميق يستبدل مصفوفة لتصنيف أضرار المباني بعد الكوارث PCA المعالم بشكل تلقائي ومتين، مع الاحتفاظ بالتجميع المعتمد على معالم مكانية ودلالية عالية المستوى من صور المباني ما EfficientNet-B7 الطبيعية. تستخلص شبكة كمؤشر (PC1) وباستخدام المكون الرئيسي الأول PCA بعد الكارثة، ثم تُختزل وتُجمّع باستخدام تقنية وضرر ($PC1 < 0$) للضرر، تستطيع النتائج تصنيف المباني إلى ثلاث درجات من الضرر: ضرر طفيف أظهرت النتائج التجريبية أن هذه التقنية لا تعمل على ($PC1 \geq 2$) وضرر شديد ($0 \leq PC1 < 2$) متوسط GLCM-PCA، أتمتة عملية استخلاص المعالم فحسب، بل تحقق أيضاً قدرة تمييزية أعلى مقارنة بطريقة الواضحة البالغة 5.000 للعينات شديدة التضرر. يطور هذا البحث الدراسات PC1 كما يتضح من قيمة من خلال التخلص من الاعتماد على الضبط اليدوي للمعاملات، وزيادة GLCM السابقة المعتمدة على غنى المعالم، وتقديم مسار تطوري بواسطة التعلّم العميق يمكن دمج مع تقييم ما بعد الكوارث. ويشكل مقترحاً يُظهر إمكانات قوية للتطبيق العملي في إدارة الكوارث PCA مع تجميع EfficientNet-B7 دمج الواقعية.

استخلاص المعالم، أضرار المباني، PCA، تجميع، EfficientNet-B7: الكلمات المفتاحية.

DAFTAR ISI

HALAMAN PERSETUJUAN	iii
HALAMAN PENGAJUAN	iv
HALAMAN PENGESAHAN	v
HALAMAN PERNYATAAN	vi
MOTTO	vii
HALAMAN PERSEMBAHAN	viii
KATA PENGANTAR	ix
ABSTRAK	xi
ABSTRACT	xii
الملخص	xiii
DAFTAR ISI	xiv
DAFTAR TABEL	xvi
DAFTAR GAMBAR	xvii
BAB I PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Pernyataan Masalah	4
1.3 Tujuan Penelitian	5
1.4 Hipotesis	5
1.5 Manfaat Penelitian	5
1.6 Batasan Masalah	6
1.7 Sistematika Penulisan	6
BAB II TINJAUAN PUSTAKA	8
2.1 Bencana Alam	8
2.2 <i>EfficientNet-B7</i>	10
2.3 <i>PCA-Clustering</i>	16
2.4 Konsep Kerangka Teori	18
BAB III METODOLOGI PENELITIAN	22
3.1 Kerangka Konsep	22
3.2 Desain Sistem	29
3.3 <i>Data Preparation</i>	32
3.4 Skenario Uji Coba	33
3.5 Instrumen Penelitian	37
BAB IV HASIL DAN IMPLEMENTASI	40

4.1. Penyajian Data Kasus dan Metodologi Singkat	41
4.2. Analisis Parameter Tekstur	41
4.3. Visualisasi Hasil.....	51
4.4 Interpretasi Tingkat Kerusakan Berdasarkan Kluster	58
BAB V UJI COBA.....	60
BAB VI PEMBAHASAN.....	63
BAB VI PENUTUP	83
6.1 Kesimpulan	83
6.2 Saran	84
DAFTAR PUSTAKA.....	86

DAFTAR TABEL

Tabel 2. 1 Penelitian terkait.....	19
Tabel 3. 1 Nilai Numerik dan Label Tingkat Kerusakan Bangunan Pascabencana Alam (A. T. W. Almais, Susilo, Naba, Sarosa, Crysdian, Wicaksono, et al., 2023).	32
Tabel 4. 1 Nilai Texture characteristics.....	45
Tabel 4. 2 Standard nilai PC1 (A. T. W. Almais, Susilo, Naba, Sarosa, Crysdian, Wicaksono, et al., 2023).....	47
Tabel 4. 3 Cluster Statistics for PC1	48
Tabel 4. 4 Cluster Statistics for PC2	50

DAFTAR GAMBAR

Gambar 2. 1 Contoh bangunan rusak pascabencana alam	10
Gambar 2. 2 Arsitektur EfficientNet-B7 (Chowdhury, 2023).....	12
Gambar 2. 3 EfficientNet-B7 Dense Layer (Chowdhury, 2023).....	14
Gambar 2. 4 Alur Penerapan PCA-Clustering (A. T. W. Almais, Susilo, Naba, Sarosa, Crysdian, Wicaksono, et al., 2023).....	18
Gambar 3. 1 Kerangka Konsep Penelitian.....	24
Gambar 3. 2 Desain Sistem.....	29
Gambar 4. 1 Visualisasi hasil penerapan EffficientNet-B7 dan PCA-Clustering..	40
Gambar 4. 2 Input data bangunan pasca bencana alam	41
Gambar 4. 3 Hasil Visualisasi Titik Koordinat PC1	52
Gambar 4. 4 Kurva Akurasi Pelatihan dan Validasi EfficientNet-B7	53
Gambar 4. 5 Kurva Loss Pelatihan dan Validasi EfficientNet-B7.....	54
Gambar 4. 6 Kontribusi Variasi Setiap Komponen Utama PCA	55
Gambar 4. 7 Sebaran Data pada Ruang PCA.....	56
Gambar 4. 8 Distribusi Data pada Tiga Kluster Tingkat Kerusakan	57

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Bencana alam seperti gempa bumi (Fariza et al., 2016; Supendi et al., 2020), tanah longsor (Tantri & Rakhmawati, 2019), dan banjir (Amani et al., 2025; Riza et al., 2020) sering kali menyebabkan kerusakan signifikan pada infrastruktur bangunan (Adhikari et al., 2023), yang berdampak besar pada kehidupan manusia dan ekonomi (Nugroho et al., 2022). Penilaian cepat dan akurat terhadap kerusakan bangunan pascabencana alam sangat penting untuk merencanakan respon darurat dan upaya pemulihan (Bachriwindi et al., 2019). Metode tradisional yang mengandalkan survei manual di lapangan sering kali memakan waktu dan berisiko bagi surveyor (A. T. W. Almais et al., 2016, 2019; Bachriwindi et al., 2019).

Pada penelitian Almais et al., menerapkan salah satu teknik *image analysis* yaitu *Gray Level Co-Occurrence Matrix* (GLCM). Hasil dari teknik GLCM menghasilkan nilai fitur yang dapat mengelompokkan tingkat kerusakan bangunan pascabencana alam dengan teknik *PCA-Clustering* dengan mengacu pada sudut, jarak, dan parameter yang ada pada teknik GLCM (Almais et al., 2024). Terdapat kelemahan pada teknik GLCM, yaitu masih manual dalam menentukan nilai sudut, jarak, dan parameter yang ada pada GLCM untuk mendapatkan nilai fitur yang dapat terbaca informasinya. Dengan kemajuan teknologi penginderaan jauh dan pembelajaran mesin, analisis gambar berbasis *Artificial Intelligence* (AI) telah menjadi alat yang efektif karena tidak tergantung pada suatu parameter dan nilai

tertentu, tetapi tergantung pada data yang ada, sebagai contoh, untuk penilaian kerusakan bangunan (Tang et al., 2024; Zheng et al., 2021). Salah satu model AI adalah model *deep learning* dapat dibangun menggunakan metode *Convolutional Neural Network* (CNN), pada penelitian (Gupta et al., 2021) menyebutkan bahwa menerapkan metode *Convolutional Neural Network* (CNN) untuk menentukan keadaan jalur atau jalan evakuasi setelah bencana alam di Provinsi Palu menggunakan *open data satellite OSM*. Penerapan *deep learning* pada (Gupta et al., 2021) menggunakan aktivasi Relu untuk menerapkan arsitektur *Convolutional Neural Network* (CNN). Arsitektur *Convolutional Neural Network* (CNN) merupakan suatu cara atau teknik dalam memecahkan problem yang menggunakan *deep learning*. Menurut (Fatichah, 2021) metode *Convolutional Neural Network* (CNN) memiliki beberapa aplikasi dan setiap aplikasi memiliki arsitektur masing-masing. Salah satunya adalah *EfficientNet-B7*, pada penelitiannya Tan et al., menjelaskan bahwa *EfficientNet-B7* merupakan arsitektur CNN yang memiliki kinerja unggul dalam ekstraksi fitur dalam gambar beresolusi tinggi (Tan & Le, 2019). Penggunaan *EfficientNet-B7* memungkinkan ekstraksi fitur yang lebih akurat dan efisien dari gambar kerusakan bangunan pascabencana alam.

Namun, ekstraksi fitur saja tidak cukup untuk memberikan gambaran lengkap tentang tingkat kerusakan. Oleh karena itu, analisis lebih lanjut menggunakan teknik *clustering* modern, yaitu *Principal Component Analysis* (PCA) yang dapat mengelompokkan dan mengidentifikasi pola kerusakan. Teknik *PCA-Clustering* merupakan pengembangan dari PCA yang dapat mengelompokkan data berdasarkan nilai yang memiliki karakter yang sama (A. T. W. Almais, Susilo,

Naba, Sarosa, Crysdiyan, Wicaksono, et al., 2023). PCA membantu dalam mengurangi dimensi data yang kompleks, sementara *Clustering* memungkinkan karakteristik data berdasarkan kesamaan fitur, sehingga memudahkan dalam mengidentifikasi area yang paling terdampak.

Teknik PCA-*Clustering* memainkan peran penting dalam penelitian ini. PCA mengurangi dimensi data dengan mempertahankan variabilitas yang paling signifikan, sehingga mempermudah analisis data yang besar dan kompleks. Setelah data direduksi, teknik *Clustering* digunakan untuk mengelompokkan data ke dalam kategori yang bermakna. Dalam konteks penilaian kerusakan bangunan, *Clustering* dapat membantu mengidentifikasi dan mengelompokkan bangunan berdasarkan tingkat kerusakan, memungkinkan respons yang lebih terfokus dan efisien.

Dalam menghadapi bencana, Islam mengajarkan keseimbangan antara tawakal dan ikhtiar. Sebagaimana disebutkan dalam QS Al-Hadid ayat 22:

وَكُنْتُمْ أَزْوَاجًا ثَلَاثَةً ۚ فَأَصْحَابُ الْمَيْمَنَةِ ۚ وَمَا أَصْحَابُ الْمَيْمَنَةِ ۚ وَأَصْحَابُ الْمَشْأَمَةِ ۚ وَمَا أَصْحَابُ الْمَشْأَمَةِ ۚ وَالسَّابِقُونَ السَّابِقُونَ ۚ

Artinya: “Kamu menjadi tiga golongan. Yaitu golongan kanan, alangkah mulianya golongan kanan itu. Dan golongan kiri, alangkah sengsaranya golongan kiri itu. Selain itu, (golongan ketiga adalah) orang-orang yang paling dahulu (beriman). Merekalah yang paling dahulu (masuk surga).”

Sebagaimana diinformasikan dalam redaksi ayat, pada hari kiamat manusia akan terbagi menjadi tiga kelompok. Kelompok pertama disebut *ashab al-maimanah*, kelompok kedua dinamakan *ashab al-masy'amah*, dan kelompok ketiga

disebut *as-sabiqun as-sabiqun*. Klasifikasi ini ada yang menyebutnya dengan tempat atau kedudukan manusia di hari kiamat, seperti penjelasan yang dikutip dalam Tafsir At-Tabari. Jadi, ada dua kelompok yang bertempat di surga dan satu kelompok di neraka. Demikian lanjutan penjelasan At-Tabari (Limmatus Sauda, n.d.).

Dalam konteks ini, penelitian tentang karakteristik kerusakan bangunan pascabencana alam menggunakan metode *EfficientNet-B7* dan *PCA-Clustering* menjadi bentuk nyata dari ikhtiar tersebut. Teknologi ini memungkinkan identifikasi cepat dan akurat terhadap tingkat kerusakan bangunan, sehingga proses rehabilitasi dapat dilakukan secara lebih terarah dan efisien.

Penelitian ini bertujuan untuk mengembangkan metode yang menggabungkan ekstraksi fitur berbasis *EfficientNet-B7* dan analisis *PCA-Clustering* untuk mendeteksi kerusakan bangunan pascabencana alam secara otomatis dan akurat. Dengan pendekatan ini, diharapkan dapat memberikan solusi yang lebih cepat dan aman dalam penilaian kerusakan bangunan, yang pada akhirnya dapat mendukung upaya mitigasi dan pemulihan bencana yang lebih efektif.

1.2 Pernyataan Masalah

1. Bagaimana kinerja *EfficientNet-B7* dalam mengekstraksi fitur dari gambar kerusakan bangunan pascabencana alam?
2. Bagaimana mengcluster tingkat kerusakan bangunan pascabencana alam hasil ekstraksi fitur *EfficientNet-B7* menggunakan *PCA-Clustering*?

1.3 Tujuan Penelitian

1. Mengetahui kinerja *EfficientNet-B7* dalam mengekstraksi fitur dari gambar kerusakan bangunan pascabencana alam.
2. Mengklaster tingkat kerusakan bangunan pascabencana alam hasil ekstraksi fitur *EfficientNet-B7* menggunakan *PCA-Clustering*.

1.4 Hipotesis

Penerapan metode ekstraksi fitur berbasis *EfficientNet-B7* yang terintegrasi dengan reduksi dimensi menggunakan *Principal Component Analysis* (PCA) mampu mengelompokkan tingkat kerusakan bangunan pascabencana alam secara lebih akurat dan efisien dibandingkan dengan metode *clustering* konvensional. Penggunaan *EfficientNet-B7* diperkirakan dapat menghasilkan representasi fitur visual bangunan yang lebih optimal, sedangkan PCA berperan dalam mengurangi kompleksitas data tanpa menghilangkan informasi penting, sehingga proses pengelompokan kerusakan bangunan dapat menghasilkan klaster yang lebih jelas, terstruktur, dan memiliki tingkat akurasi yang lebih tinggi dalam mendukung proses analisis serta pengambilan keputusan mitigasi bencana.

1.5 Manfaat Penelitian

1. Dalam konteks teknik informatika, temuan ini memperkaya pemahaman mengenai implementasi *clustering* untuk menilai tingkat kerusakan infrastruktur pascabencana alam. Dalam bidang teknik geofisika, penelitian

ini menawarkan inovasi dengan memanfaatkan *Artificial Intelligence* (AI) untuk menentukan tingkat kerusakan, sebuah pendekatan yang lebih maju dibandingkan metode konvensional yang bergantung pada data manual dari survei lapangan.

2. Penelitian ini juga memberikan manfaat praktis bagi Badan Penanggulangan Bencana Daerah (BPBD) dalam mengumpulkan data untuk rehabilitasi dan rekonstruksi dengan cara yang lebih akurat dan efisien.

1.6 Batasan Masalah

1. Untuk mendeteksi bangunan pascabencana alam.
2. Menggunakan data gambar kerusakan bangunan pascabencana alam di Propinsi Jawa Timur.
3. Menggunakan teknik *clustering* untuk mengetahui informasi tingkat kerusakan bangunan pascabencana alam karena data gambar yang digunakan adalah data *unsupervised*.

1.7 Sistematika Penulisan

1. BAB I: PENDAHULUAN

Bab ini membahas tentang Latar Belakang, Rumusan Masalah, Tujuan Penelitian, Hipotesis, Batasan Masalah, Manfaat Penelitian serta Sistematika Penulisan.

2. BAB II: TINJAUAN PUSTAKA

Dalam bab ini akan dijabarkan mengenai Tinjauan Pustaka yang meliputi penjelasan tentang Karakteristik *Clustering* Berdasarkan Gambar, Penelitian Terkait, Kerangka Teori serta Integrasi Al-Qur'an dan Hadis.

3. BAB III: DESAIN DAN INTEGRASI SISTEM PENELITIAN

Bab ini memuat tentang Kerangka Konsep Penelitian, *Collection Data*, Metode yang digunakan, Desain Sistem, Skenario Uji Coba, dan Instrumen Penelitian.

4. BAB IV: IMPLEMENTASI METODE

Pada bab ini menjelaskan tentang hasil implementasi karakteristik tingkat kerusakan bangunan menggunakan *EfficientNet-B7* dan *Principal Component Analysis (PCA) Clustering*.

5. BAB V: UJI COBA

Pada bab ini menjelaskan tentang hasil Uji Coba karakteristik tingkat kerusakan bangunan menggunakan *EfficientNet-B7* dan *Principal Component Analysis (PCA) Clustering*.

6. BAB VI: PENUTUP

Bab ini memuat tentang simpulan dari hasil penelitian yang dilakukan dan saran saran untuk pengembangan tesis ini lebih lanjut.

BAB II

TINJAUAN PUSTAKA

2.1 Bencana Alam

Bencana alam merupakan fenomena yang tidak dapat diprediksi sepenuhnya dan memiliki daya rusak yang luar biasa terhadap kehidupan manusia serta tatanan infrastruktur di berbagai belahan dunia. Beragam jenis bencana, seperti gempa bumi yang mengguncang permukaan tanah dengan intensitas bervariasi, letusan gunung berapi yang menyemburkan material vulkanik panas dan abu beracun, tanah longsor yang mengubur pemukiman di lereng-lereng curam, tsunami yang menghantam kawasan pesisir dengan gelombang raksasa, angin topan yang merobohkan bangunan dan pohon-pohon besar, banjir bandang yang merendam permukiman dan lahan pertanian, tornado yang berputar dengan kecepatan ekstrem, kebakaran hutan yang melalap jutaan hektar lahan hijau, kekeringan berkepanjangan yang mengancam ketahanan pangan dan sumber daya air, serta suhu ekstrem yang memicu berbagai masalah kesehatan dan lingkungan, semuanya tercatat sebagai ancaman serius yang dihadapi oleh manusia ((Abdalzaher et al., 2023); (Moustafa et al., 2022)). Setiap jenis bencana memiliki karakteristik fisik yang berbeda, namun kesemuanya memiliki satu kesamaan, yaitu potensi untuk menimbulkan kerusakan material yang masif serta jatuhnya korban jiwa dalam jumlah yang tidak sedikit. Dampak dari peristiwa-peristiwa alam ini tidak hanya dirasakan pada saat kejadian berlangsung, tetapi juga meninggalkan efek jangka panjang berupa trauma psikologis, kerugian ekonomi, terganggunya

layanan publik seperti kesehatan dan pendidikan, serta rusaknya jaringan transportasi dan komunikasi yang menghambat upaya evakuasi dan bantuan kemanusiaan.

Wilayah-wilayah yang berada di jalur cincin api Pasifik, zona patahan aktif, maupun daerah pesisir yang rendah, termasuk Indonesia, menjadi kawasan yang sangat rentan terhadap bencana alam majemuk. Dalam konteks ini, bangunan-bangunan sebagai aset fisik yang paling vital bagi tempat tinggal, perkantoran, fasilitas umum, dan pusat kegiatan ekonomi sering kali menjadi objek yang paling pertama dan paling parah terdampak. Kerusakan bangunan tidak hanya mengancam keselamatan jiwa penghuninya pada saat bencana terjadi, tetapi juga menentukan cepat atau lambatnya proses pemulihan pasca-bencana. Oleh karena itu, upaya untuk mendokumentasikan, mengidentifikasi, dan mengklasifikasikan tingkat kerusakan bangunan menjadi sangat krusial dalam rangka mitigasi, penanganan darurat, serta perencanaan rehabilitasi dan rekonstruksi yang tepat sasaran. Sebagai salah satu bentuk dokumentasi visual, Gambar 2.1 menyajikan contoh nyata dari bangunan yang mengalami kerusakan pascabencana alam, yang diambil secara langsung menggunakan kamera di lapangan. Citra semacam ini menjadi data mentah yang sangat berharga karena merekam secara visual kondisi eksisting dari elemen-elemen struktur seperti dinding, atap, kolom, dan fondasi, yang kemudian dapat dianalisis lebih lanjut melalui pendekatan pengolahan citra digital untuk mengekstrak informasi tekstur, bentuk, dan pola kerusakan. Dengan demikian, gambar tersebut tidak hanya berfungsi sebagai bukti dokumentatif, tetapi juga

sebagai pintu masuk bagi analisis kuantitatif yang lebih objektif dan terukur dalam menilai tingkat kerusakan bangunan pasca-bencana alam.



Gambar 2. 1 Contoh bangunan rusak pascabencana alam

2.2 *EfficientNet-B7*

EfficientNet-B7 adalah model CNN yang sangat efisien dan akurat, dirancang melalui optimasi otomatis (NAS) dan menjadi fondasi bagi keluarga *EfficientNet*. Kombinasi arsitektur MBConv, *squeeze-and-excitation*, dan *compound scaling* menjadikannya unggul dalam hal akurasi, ukuran model, dan kecepatan inferensi dibandingkan model konvensional (Tan & Le, 2019).

EfficientNet-B7 adalah model jaringan saraf convolutional (CNN) yang dirancang secara cerdas untuk menyeimbangkan akurasi tinggi dan efisiensi komputasi. Dibangun melalui proses pencarian arsitektur neural otomatis (*Neural Architecture Search/NAS*), model ini menjadi fondasi bagi seri *EfficientNet-B7*


yang lebih besar. Arsitekturnya mengoptimalkan tiga aspek utama: kedalaman jaringan (jumlah lapisan), lebar jaringan (jumlah channel), dan resolusi gambar input.

Keunggulan utama *EfficientNet-B7* terletak pada efisiensinya yang luar biasa. Dengan hanya 5.3 juta parameter dan kebutuhan komputasi sebesar 0.39 miliar FLOPS, model ini jauh lebih ringan dibandingkan model sejenis seperti ResNet-50. Namun, efisiensi ini tidak mengorbankan performa – *EfficientNet-B7* mampu mencapai akurasi 76.3% pada dataset *ImageNet*, yang cukup kompetitif untuk ukurannya yang kecil.

Kunci kecanggihan model ini ada pada penggunaan blok MBConv (*Mobile Inverted Bottleneck*) yang dikombinasikan dengan mekanisme *Squeeze-and-Excitation*. Blok ini dirancang khusus untuk komputasi yang efisien sambil tetap mempertahankan kemampuan mengekstrak fitur penting dari gambar. Selain itu, model ini dirancang agar mudah diskalakan.

Keberhasilan *EfficientNet-B7* membuktikan bahwa model *deep learning* tidak harus besar dan boros sumber daya untuk berkinerja baik. Model ini sangat cocok untuk implementasi di perangkat mobile dan aplikasi *edge computing* yang membutuhkan keseimbangan antara akurasi, kecepatan, dan konsumsi daya. Dengan desain yang optimal, *EfficientNet-B7* menawarkan solusi praktis untuk berbagai tantangan implementasi AI di dunia nyata.

Pada Gambar 2.2 merupakan arsitektur *EfficientNet-B7* yang diterapkan pada penelitian ini:




Gambar 2. 2 Arsitektur EfficientNet-B7 (Chowdhury, 2023)

Arsitektur yang disajikan pada Gambar 2.2 menggambarkan alur pemrosesan citra yang terinspirasi dari struktur EfficientNet-B7, yang dirancang untuk mencapai keseimbangan antara akurasi tinggi dan efisiensi komputasi melalui penskalaan yang seimbang pada kedalaman, lebar, dan resolusi jaringan. Proses dimulai dari *input image*, yaitu citra bangunan pasca-bencana yang menjadi objek analisis. Citra tersebut kemudian dilewatkan ke lapisan konvolusi awal (*Conv* 3×3) yang berfungsi sebagai tahap ekstraksi fitur tingkat rendah. Lapisan ini bertugas menangkap pola-pola dasar seperti tepi, sudut, tekstur kasar, dan gradien intensitas yang menjadi fondasi bagi representasi visual yang lebih kompleks di tahap berikutnya. Setelah melewati konvolusi awal, fitur-fitur tersebut diproses melalui serangkaian blok utama yang diberi label Block 1 hingga Block 7. Pada setiap blok, arsitektur ini menerapkan tiga kali operasi *Max Pooling* dengan ukuran kernel 3×3 secara berurutan, yang bertujuan untuk mereduksi dimensi spasial peta fitur secara bertahap sekaligus mempertahankan informasi paling dominan dari setiap wilayah lokal. Penggunaan *Max Pooling* secara berlapis ini membantu mengurangi beban komputasi, meningkatkan invarian terhadap translasi, serta

memperluas bidang reseptif jaringan agar mampu menangkap konteks spasial yang lebih luas tanpa kehilangan fitur-fitur penting.

Meskipun gambar tidak secara eksplisit menuliskan MBConv, berdasarkan referensi dari Chowdhury (2023) (*Chowdhury, 2023*), blok-blok yang ditampilkan sebenarnya mengadopsi mekanisme *Mobile Inverted Bottleneck Convolution* (MBConv) dengan variasi kernel 3×3 dan 5×5 di dalam setiap bloknya. MBConv merupakan komponen inti dari *EfficientNet* yang sangat efisien karena memanfaatkan *depthwise separable convolution* untuk memisahkan operasi spasial dan kanal, sehingga mengurangi jumlah parameter secara signifikan tanpa mengorbankan kemampuan representasi. Selain itu, MBConv juga dilengkapi dengan mekanisme ekspansi kanal yang memperluas dimensi fitur sebelum akhirnya dikompresi kembali, sehingga memungkinkan jaringan untuk mempelajari hubungan antar kanal yang lebih kaya dan kompleks. Dengan demikian, setiap blok dari *Block 1* hingga *Block 7* tidak hanya melakukan reduksi resolusi melalui *Max Pooling*, tetapi juga melakukan transformasi fitur yang mendalam melalui MBConv, baik dengan kernel 3×3 maupun 5×5 , yang masing-masing dioptimalkan untuk menangkap pola spasial pada skala yang berbeda—kernel 3×3 untuk detail lokal yang halus, dan kernel 5×5 untuk struktur yang lebih besar dan lebih global. Proses ini diulangi secara hierarkis di ketujuh blok, sehingga setiap lapisan mampu mengekstraksi fitur-fitur yang semakin abstrak dan spesifik, mulai dari tepi sederhana, tekstur permukaan dinding, pola retakan, hingga bentuk kerusakan struktural yang lebih kompleks. Pada akhir alur, seluruh fitur yang telah diekstraksi dan direduksi tersebut akan menghasilkan *Feature Map* yang kaya akan

informasi spasial dan semantik, yang siap untuk digunakan sebagai masukan bagi tahap klasifikasi atau analisis lebih lanjut, misalnya dalam menentukan tingkat kerusakan bangunan berdasarkan tekstur dan pola visual yang terekam.



Gambar 2. 3 EfficientNet-B7 Dense Layer (Chowdhury, 2023)

Pada gambar 2.3 mengilustrasikan secara visual konsep penskalaan yang menjadi fondasi utama dari arsitektur *EfficientNet-B7*, yaitu *compound scaling*, yang dirancang untuk meningkatkan performa jaringan secara proporsional tanpa meningkatkan biaya komputasi secara berlebihan. Pada bagian awal gambar, ditampilkan sebuah lapisan dasar (*baseline network*) dengan dimensi kanal ($\#channels$), resolusi spasial ($resolution\ H \times W$), dan kedalaman lapisan ($layer_i$) sebagai titik acuan. Dari titik awal ini, terdapat tiga jalur penskalaan independen yang masing-masing menggambarkan pendekatan penskalaan tradisional. Pertama, *width scaling* (penskalaan lebar) yang ditandai dengan simbol *wider*, yaitu memperlebar jumlah kanal pada setiap lapisan sehingga jaringan mampu menangkap lebih banyak variasi fitur dalam satu lapisan. Kedua, *depth scaling* (penskalaan kedalaman) yang ditandai dengan simbol "deeper", yaitu menambah jumlah lapisan konvolusi atau blok secara berurutan sehingga jaringan dapat

mengeksktraksi fitur yang lebih abstrak dan hierarkis. Ketiga, *resolution scaling* (penskalaan resolusi) yang ditandai dengan simbol *higher resolution* yang muncul dua kali, yaitu meningkatkan ukuran spasial citra masukan agar jaringan dapat menangkap detail yang lebih halus dan presisi, terutama untuk objek-objek kecil dalam citra.

Namun, ketiga pendekatan penskalaan tersebut jika dilakukan secara terpisah cenderung menimbulkan ketidakseimbangan, dimana peningkatan pada satu dimensi akan dengan cepat mencapai titik jenuh dan tidak lagi memberikan peningkatan akurasi yang berarti. Oleh karena itu, *EfficientNet-B7* memperkenalkan *compound scaling* yang digambarkan pada bagian paling kanan gambar, yaitu sebuah pendekatan terpadu yang menggabungkan ketiga dimensi secara bersamaan dan proporsional. Pada *compound scaling*, lebar kanal, kedalaman lapisan, dan resolusi citra ditingkatkan secara bersamaan dengan faktor skala yang telah dioptimalkan melalui pencarian grid (*grid search*) sehingga ketiganya saling melengkapi dan tidak ada satu pun yang menjadi hambatan bagi yang lain. Hasil dari penskalaan majemuk ini adalah jaringan yang lebih lebar, lebih dalam, dan memproses citra dengan resolusi yang lebih tinggi secara simultan, seperti yang ditunjukkan oleh blok besar berwarna biru pada bagian akhir gambar. Dengan cara ini, *EfficientNet-B7* mampu mencapai akurasi yang lebih tinggi dibandingkan arsitektur CNN konvensional, seperti ResNet atau DenseNet, namun dengan jumlah parameter yang jauh lebih efisien dan biaya komputasi yang lebih rendah.


Pada bagian akhir jaringan, setelah seluruh proses ekstraksi fitur melalui blok-blok konvolusi dan penskalaan majemuk selesai dilakukan, fitur-fitur yang telah diekstraksi tersebut kemudian diteruskan ke *dense layer* atau *fully connected layer*. Lapisan ini berfungsi sebagai tahap akhir dalam arsitektur, di mana representasi fitur multidimensi yang dihasilkan oleh *feature map* akhir dikompresi menjadi vektor fitur berdimensi lebih rendah yang siap untuk diproses lebih lanjut. Pada tahap inilah proses klasifikasi sesungguhnya terjadi, misalnya untuk menentukan tingkat kerusakan bangunan pasca-bencana ke dalam kategori-kategori tertentu seperti rusak ringan, sedang, berat, atau hancur total. Selain itu, *dense layer* juga dapat berperan sebagai penghasil representasi fitur akhir yang dapat digunakan untuk keperluan transfer learning, visualisasi, atau analisis kluster. Dengan demikian, keseluruhan arsitektur EfficientNet-B7 yang mengintegrasikan *compound scaling* secara cerdas dan diakhiri dengan *fully connected layer* menjadikannya sangat andal untuk tugas klasifikasi citra yang membutuhkan ketelitian tinggi, seperti dalam konteks penilaian kerusakan bangunan berdasarkan citra tekstur pasca-bencana alam.

2.3 PCA-Clustering

Terdapat banyak jenis teknik atau metode clustering data antara lain K-Means, Hierarchical, DBSCAN, GMM, dan PCA-Clustering. K-Means merupakan metode yang mengelompokkan data ke dalam K cluster berdasarkan jarak terdekat dari centroid dan cocok diterapkan pada data dengan cluster berbentuk bulat (Kapoor & Singhal, 2017). Hierarchical, bekerja dengan mengelompokkan data

secara bertahap melalui pendekatan *agglomerative* (bottom-up) atau *divisive* (top-down), dan sangat berguna untuk data yang memiliki struktur hierarki (Fahad et al., 2014). DBSCAN (*Density-Based Spatial Clustering of Applications with Noise*), mengelompokkan data berdasarkan kepadatan titik data, sehingga efektif untuk data dengan bentuk cluster tidak beraturan dan mengandung *noise* (Sander et al., 1998). *Gaussian Mixture Models* (GMM), mengasumsikan bahwa data berasal dari campuran beberapa distribusi Gaussian, dan cocok untuk data dengan karakteristik distribusi probabilistik (Chander & Vijaya, 2021). PCA-Clustering merupakan metode yang digunakan untuk mengelompokkan data hasil dari reduksi dimensi menggunakan *Principal Component Analysis* (PCA), yang berguna untuk meng-cluster data bersifat *unsupervised* dan menjadikan data menjadi *supervised* sehingga dapat menghasilkan nilai standar pada suatu kumpulan data (A. T. W. Almais, Susilo, Naba, Sarosa, Crysdian, Wicaksono, et al., 2023; A. T. W. Almais, Susilo, Naba, Sarosa, Juwono, et al., 2024).

PCA-Clustering adalah teknik *clustering* yang efektif dalam menangani data berdimensi tinggi dan kompleks, sehingga data tersebut dapat terkelompok berdasarkan karakteristik tertentu dan dapat juga melabelkan data tersebut berdasarkan karakteristiknya. Pada Gambar 2.4 merupakan alur dari teknik PCA-Clustering (A. T. W. Almais, Susilo, Naba, Sarosa, Crysdian, Wicaksono, et al., 2023):



Gambar 2. 4 Alur Penerapan PCA-Clustering (A. T. W. Almais, Susilo, Naba, Sarosa, Crysdian, Wicaksono, et al., 2023)

2.4 Konsep Kerangka Teori

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 pascabencana alam dengan menggunakan input berupa gambar bangunan (A. T. W. Almais, Susilo, Naba, Sarosa, Juwono, et al., 2024). Dari integrasi GLCM dan PCA-Clustering menghasilkan suatu teknik baru untuk mengetahui informasi yang ada pada gambar, tetapi pada teknik tersebut terdapat kelemahan yang mendasar yaitu masih menggunakan model manual untuk tuning parameter yang ada pada GLCM yaitu merubah nilai jarak dan sudutnya. 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 salah satu jenis teknik AI yang biasanya untuk mengolah data berupa gambar (Gonçalves et al., 2022; Han et al., 2018; Hendria et al., 2021; Kumar & Kumar, 2023; Wagner et al., 2023). Pada Tabel 2.1. merupakan perbedaan dari penelitian-penelitian sebelumnya yang membahas tentang ekstraksi fitur dan kebencanaan.

Tabel 2. 1 Penelitian terkait

Referensi	Topik	Metode	Subjek
(You et al., 2022)	Ekstraksi Fitur bangunan	EfficientUNet+	Mengekstraksi fitur gambar bangunan pusat penampungan
(Deng & Wang, 2022)	Kerusakan bangunan	U-Net	Menilai kerusakan bangunan pascabencana alam menggunakan U-Net

Referensi	Topik	Metode	Subjek
	pascabencana alam		
(A. T. W. Almais, Susilo, Naba, Sarosa, Crysodian, Wicaksono, et al., 2023)	<i>Clustering</i> Kerusakan bangunan pascabencana alam	PCA- <i>Clustering</i>	Mengkluster tingkat kerusakan bangunan pascabencana alam menggunakan teknik PCA- <i>Clustering</i>
(A. T. W. Almais, Susilo, Naba, Sarosa, Juwono, et al., 2024)	Ekstraksi fitur gambar bangunan pascabencana alam	GLCM dan PCA- <i>Clustering</i>	Menilai tingkat kerusakan bangunan pascabencana alam menggunakan integrasi GLCM dengan PCA- <i>Clustering</i>
(Nguyen et al., 2021)	Seleksi Fitur Gambar	PCA- <i>Autoencoder</i>	Penggunaan PCA untuk seleksi fitur yang membantu model autoencoder clustering

Referensi	Topik	Metode	Subjek
			dalam mendeteksi anomali jaringan
(Piernik & Morzy, 2021)	<i>Clustering</i> data untuk ekstraksi data	<i>Clustering</i>	Mengeksplorasi penggunaan clustering data untuk ekstraksi fitur guna meningkatkan kinerja model pembelajaran mesin
Penelitian ini	Ekstraksi fitur gambar bangunan untuk mengetahui tingkat kerusakannya	<i>EfficientNet-B7</i> dan <i>PCA-Clustering</i>	Mengekstraksi fitur gambar bangunan rusak pascabencana alam menggunakan <i>EfficientNet</i> untuk mengetahui tingkat kerusakannya menggunakan <i>PCA-Clustering</i>

BAB III

METODOLOGI PENELITIAN

3.1 Kerangka Konsep

Pemilihan metode *EfficientNet-B7* yang diintegrasikan dengan PCA didasarkan pada kebutuhan akan sistem penilaian kerusakan yang cepat, aman, dan akurat. *EfficientNet-B7* dipilih karena efisiensinya dalam menyeimbangkan kedalaman dan resolusi jaringan melalui *compound scaling*. Yang memungkinkannya menghasilkan representasi fitur visual yang kaya dan optimal dari citra bangunan. Keunggulan ini memungkinkan sistem untuk menangkap karakteristik fisik bangunan yang rusak secara lebih mendalam dibandingkan dengan metode ekstraksi fitur tradisional.

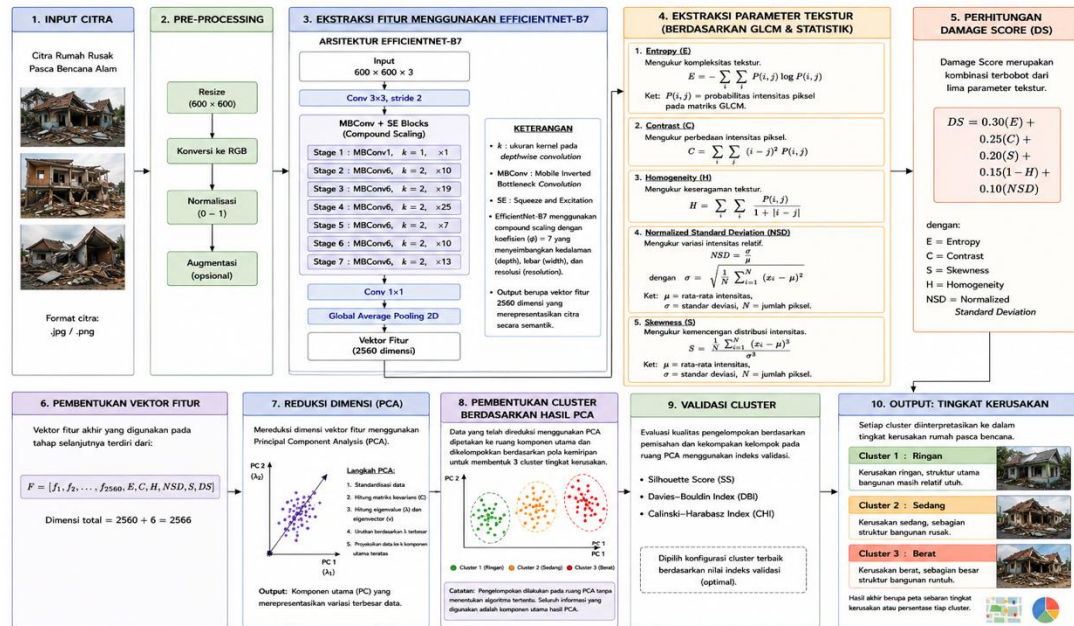
Data berdimensi tinggi yang dihasilkan oleh *EfficientNet-B7* kemudian diproses menggunakan *Principal Component Analysis* (PCA) sebagai variabel antara untuk mengurangi kompleksitas komputasi dan menghilangkan noise. PCA berperan penting dalam mentransformasi data *unsupervised* menjadi informasi yang lebih terstruktur, sehingga memudahkan teknik *clustering* dalam mengelompokkan tingkat kerusakan bangunan ke dalam kategori ringan, sedang, atau berat secara otomatis. Dengan menggabungkan kedua metode ini, penelitian ini bertujuan menciptakan solusi mitigasi bencana yang mampu memberikan hasil deteksi yang konsisten dan selaras dengan standar teknis evaluasi ahli di lapangan.

Sehingga kerangka konsep untuk penelitian ini berfokus pada pengembangan metode deteksi kerusakan bangunan pascabencana alam

menggunakan pendekatan berbasis teknologi kecerdasan buatan (AI), yang mengintegrasikan *EfficientNet-B7* dan *PCA-Clustering*. Pada tahap awal, variabel bebas yang diperoleh dari gambar bangunan yang rusak dianalisis untuk mengekstraksi fitur penting seperti warna, tekstur, dan bentuk. Metode *EfficientNet-B7* digunakan dalam proses ekstraksi fitur ini karena efisiensinya dalam mengolah data gambar dan kemampuannya menghasilkan representasi fitur yang kaya.

Selanjutnya, hasil ekstraksi fitur ini diolah lebih lanjut sebagai variabel antara melalui metode *Principal Component Analysis* (PCA). PCA berfungsi mengurangi dimensi data tanpa menghilangkan informasi signifikan, sehingga memudahkan proses analisis lebih lanjut dan mengurangi kompleksitas komputasi. Fitur yang telah direduksi dengan PCA kemudian dikelompokkan menggunakan teknik *clustering*, yang akan mengelompokkan data berdasarkan kemiripan fitur untuk mengidentifikasi tingkat kerusakan.

Hasil akhir dari proses ini, yang merupakan variabel terikat, adalah tingkat kerusakan bangunan yang dikategorikan secara otomatis menggunakan *PCA-Clustering*. Variabel terikat ini mencakup label tingkat kerusakan, yaitu rusak ringan, sedang, atau berat, yang dihasilkan dari analisis clustering. Hasil dari kerangka ini diharapkan mampu memberikan deteksi dan tingkat kerusakan bangunan secara cepat dan akurat, yang sangat bermanfaat dalam respon bencana dan perencanaan rekonstruksi. Pada Gambar 3.1 merupakan alur dari kerangka konsep pada penelitian ini:



Gambar 3. 1 Kerangka Konsep Penelitian

Pada Gambar 3.1 menunjukkan tahapan metodologi penelitian yang digunakan untuk mengidentifikasi dan mengelompokkan tingkat kerusakan rumah pasca bencana alam berdasarkan karakteristik visual citra. Metodologi ini mengintegrasikan pendekatan *deep learning* melalui arsitektur *EfficientNet-B7*, ekstraksi parameter tekstur, perhitungan indeks kerusakan (*Damage Score*), serta analisis *Principal Component Analysis* (PCA) untuk membentuk kelompok tingkat kerusakan secara objektif.

1. Input Citra

Tahap awal pada penelitian ini adalah pengumpulan data berupa citra rumah rusak pasca bencana alam. Citra diperoleh dalam format digital (.jpg atau .png) yang merepresentasikan berbagai tingkat kerusakan bangunan, mulai dari kerusakan ringan hingga kerusakan berat. Data citra digunakan sebagai sumber informasi

utama untuk mengekstraksi karakteristik visual yang berkaitan dengan kondisi fisik bangunan.

2. Pre-processing

Tahap pre-processing dilakukan untuk menyiapkan data citra sebelum diproses lebih lanjut oleh model *deep learning*. Seluruh citra diubah ukurannya menjadi 600×600 piksel agar memiliki dimensi yang seragam. Selanjutnya citra dikonversi ke ruang warna RGB dan dilakukan normalisasi nilai piksel ke rentang 0-1 untuk meningkatkan stabilitas proses pembelajaran. Pada tahap ini juga dapat diterapkan augmentasi data, seperti rotasi, translasi, dan flipping, untuk meningkatkan keragaman data dan mengurangi risiko *overfitting*.

3. Ekstraksi Fitur Menggunakan *EfficientNet-B7*

Pada tahap ini, citra hasil pre-processing diproses menggunakan arsitektur *EfficientNet-B7* untuk memperoleh representasi fitur tingkat tinggi. *EfficientNet-B7* dipilih karena mampu menghasilkan performa yang tinggi dengan jumlah parameter yang relatif efisien melalui mekanisme compound scaling yang menyeimbangkan dimensi kedalaman (*depth*), lebar jaringan (*width*), dan resolusi input. Proses ekstraksi fitur dimulai dari lapisan konvolusi awal (*Conv 3×3*), dilanjutkan dengan serangkaian blok *Mobile Inverted Bottleneck Convolution* (MBConv) yang dilengkapi mekanisme *Squeeze-and-Excitation* (SE). Selanjutnya dilakukan proses *Global Average Pooling* untuk menghasilkan vektor fitur berdimensi 2560 yang merepresentasikan karakteristik visual citra secara komprehensif.

4. Ekstraksi Parameter Tekstur

Selain fitur yang diperoleh dari *EfficientNet-B7*, penelitian ini juga mengekstraksi parameter tekstur untuk menggambarkan pola kerusakan permukaan bangunan. Parameter tekstur dihitung menggunakan pendekatan *Gray Level Co-occurrence Matrix* (GLCM) dan statistik citra.

Parameter yang digunakan meliputi:

- a. **Entropy (E)**, yang mengukur tingkat kompleksitas dan ketidakteraturan tekstur citra.
- b. **Contrast (C)**, yang mengukur perbedaan intensitas antar piksel sehingga dapat menunjukkan tingkat variasi tekstur.
- c. **Homogeneity (H)**, yang menggambarkan tingkat keseragaman distribusi intensitas pada citra.
- d. **Normalized Standard Deviation (NSD)**, yang digunakan untuk mengukur tingkat variasi relatif intensitas piksel terhadap rata-ratanya.
- e. **Skewness (S)**, yang menunjukkan tingkat kemencengan distribusi intensitas piksel.

Parameter-parameter tersebut digunakan sebagai indikator tambahan dalam mengidentifikasi tingkat kerusakan bangunan.

5. Perhitungan *Damage Score* (DS)

Setelah parameter tekstur diperoleh, dilakukan perhitungan *Damage Score* (DS) sebagai indeks komposit yang merepresentasikan tingkat kerusakan bangunan.

Damage Score dihitung menggunakan kombinasi berbobot dari lima parameter tekstur dengan persamaan:

$$DS = 0,30(E) + 0,25(C) + 0,20(S) + 0,15(1 - H) + 0,10(NSD)$$

Persamaan tersebut dirancang untuk memberikan bobot yang lebih besar pada parameter yang memiliki kontribusi signifikan terhadap identifikasi kerusakan, seperti *entropy* dan *contrast*. Nilai *Damage Score* yang lebih tinggi menunjukkan tingkat kerusakan yang lebih besar.

6. Pembentukan Vektor Fitur

Tahap berikutnya adalah pembentukan vektor fitur akhir yang digunakan dalam proses analisis. Vektor fitur dibangun dengan menggabungkan fitur hasil ekstraksi *EfficientNet-B7* sebanyak 2560 dimensi dengan enam fitur tambahan yang terdiri atas *Entropy*, *Contrast*, *Homogeneity*, *Normalized Standard Deviation*, *Skewness*, dan *Damage Score*. Dengan demikian, total dimensi vektor fitur yang digunakan dalam penelitian ini adalah 2566 dimensi.

7. Reduksi Dimensi Menggunakan *Principal Component Analysis* (PCA)

Vektor fitur yang memiliki dimensi tinggi selanjutnya direduksi menggunakan metode *Principal Component Analysis* (PCA). PCA digunakan untuk mentransformasikan data ke ruang komponen utama yang mampu mempertahankan sebagian besar variasi informasi dengan jumlah dimensi yang lebih sedikit. Tahapan PCA meliputi standarisasi data, pembentukan matriks kovarians, perhitungan eigenvalue dan eigenvector, serta pemilihan komponen utama berdasarkan nilai eigenvalue terbesar. Hasil PCA berupa sekumpulan komponen

utama yang merepresentasikan karakteristik data secara lebih ringkas tanpa kehilangan informasi yang signifikan.

8. Pembentukan Kluster Berdasarkan Hasil PCA

Data yang telah direpresentasikan dalam ruang komponen utama kemudian dianalisis untuk membentuk kelompok berdasarkan pola kemiripan karakteristik kerusakan. Pengelompokan dilakukan menggunakan representasi hasil PCA sehingga struktur data dapat diamati secara lebih jelas. Pada penelitian ini terbentuk tiga kelompok utama yang merepresentasikan tingkat kerusakan bangunan, yaitu kelompok kerusakan ringan, kelompok kerusakan sedang, dan kelompok kerusakan berat.

9. Validasi Kluster

Kualitas hasil pengelompokan dievaluasi menggunakan beberapa indeks validasi kluster, yaitu *Silhouette Score* (SS), *Davies–Bouldin Index* (DBI), dan *Calinski–Harabasz Index* (CHI). *Silhouette Score* digunakan untuk mengukur tingkat kesamaan data dalam satu kluster dibandingkan dengan kluster lainnya. *Davies–Bouldin Index* digunakan untuk mengevaluasi tingkat pemisahan antar kluster, sedangkan *Calinski–Harabasz Index* digunakan untuk menilai rasio antara variasi antar kluster dan variasi dalam kluster. Nilai indeks-indeks tersebut digunakan untuk menentukan konfigurasi kluster yang paling optimal.

10. Output Tingkat Kerusakan

Tahap akhir menghasilkan klasifikasi tingkat kerusakan rumah pasca bencana ke dalam tiga kategori, yaitu kerusakan ringan, kerusakan sedang, dan kerusakan berat.

Hasil ini dapat digunakan sebagai dasar dalam proses penilaian kondisi bangunan, perencanaan rehabilitasi dan rekonstruksi, serta pengambilan keputusan terkait prioritas penanganan pasca bencana. Dengan mengintegrasikan fitur *deep learning*, parameter tekstur, *Damage Score*, dan analisis PCA, metodologi yang diusulkan diharapkan mampu menghasilkan identifikasi tingkat kerusakan bangunan yang lebih objektif, konsisten, dan akurat.

3.2 Desain Sistem

Pada sub bab ini menjelaskan tentang tahapan dalam mengerjakan penelitian ini agar terseruktur dan memiliki alur penelitian yang jelas dan terarah. Pada Gambar 3.2 merupakan alur dari desain sistem penelitian ini. Pada Gambar 3.2 terlihat jelas alur dari tahapan dasar dalam membangun suatu sistem yaitu input, proses, dan output.



Gambar 3. 2 Desain Sistem

Diagram Gambar 3.2 menggambarkan proses analisis tingkat kerusakan bangunan pascabencana alam menggunakan pendekatan *deep learning* dan analisis statistik. Proses diawali dengan input gambar bangunan yang rusak akibat bencana alam, seperti gempa atau banjir. Input merupakan tahap awal dalam membangun suatu sistem, pada penelitiannya *Shukla et al.* menjelaskan bahwa input merupakan masukan suatu data yang berasal dari pengguna, bisa menggunakan gambar, teks, audio, video, atau sinyal (*Shukla et al., 2021*). Pada penelitian ini menggunakan

input berupa gambar RGB atau UAV rumah rusak pasca bencana alam yang berasal dari suatu device (kamera/ drone).

Kemudian melalui tahap *pre-processing* untuk persiapan data, termasuk *resizing*, normalisasi piksel, dan augmentasi jika diperlukan. Selanjutnya gambar diproses menggunakan salah satu metode *Convutional Neural Network* (CNN) yaitu *EfficientNet-B7*, untuk mengekstraksi fitur gambar. *EfficientNet-B7* merupakan suatu metode CNN yang cocok untuk mengekstraksi fitur gambar menjadi numerik sehingga dapat menjadi input data pada tahapan selanjutnya (Ul Amin et al., 2024). *EfficientNet-B7* menggunakan library dari python *GlobalAveragePooling2D()* untuk mendapatkan vector 1 dimensi (1D) sehingga dapat menghasilkan suatu *vector* dengan dimensi tinggi yaitu 1280.

Hasil dimensi tinggi tersebut kemudian masuk proses ekstraksi karakteristik tekstur dengan menghitung enam parameter kunci yaitu *Entropi* (kompleksitas), *Normalized Std* (variasi), *Contrast* (kekuatan tepi), *Homogenitas* (keseragaman), dan *Skewness* (asimetri) (A. T. W. Almaisi, Susilo, Naba, Sarosa, Juwono, et al., 2024). Setelah mendapat nilai dari enam parameter tersebut maka langkah berikutnya adalah menghitung kuantifikasi damage score dengan cara menghitung indikator kerusakan bangunan menggunakan rumus berbobot pada masing-masing parameter tersebut dengan nilai *Normalized Std* (30%) + *Entropy* (25%) + *Contrast* (20%) + *Skewness* (15%) + (1 - *Homogeneity*) (10%).

Bobot setiap parameter sudah ada maka langkah selanjutnya adalah menentukan PC1 dengan cara melakukan pemetaan linear dari *Damage Indicator* ke nilai *Principal Component 1* (PC1) untuk menentukan tingkat kerusakannya.

Sedangkan untuk menentukan PC2 dengan cara menghitung nilai PC2 berdasarkan tingkat kompleksitas tekstur (entropi) untuk memberikan informasi variasi tambahan. Setelah itu proses ekstraksi fitur tersebut, hasilnya dianalisis lebih lanjut menggunakan PCA untuk memahami distribusi dan pola data. Mengurangi *noise* dan kompres fitur untuk clustering data dapat menggunakan teknik PCA, menurut *Jolliffe* bahwa PCA merupakan teknik untuk mereduksi data yang memiliki dimensi tinggi, tetapi tidak mengurangi informasi pada data tersebut (I.T.Jolliffe, 2002). Pada penelitian ini menggunakan data berdimensi tinggi yaitu 1280, hasil dari ekstraksi fitur metode *EfficientNet-B7*.

Berdasarkan penelitian *Almais et al.* menjelaskan bahwa dimensi tinggi pada suatu data dapat direduksi menggunakan PCA dengan memperhatikan nilai dari eigen value, jadi mengambil jumlah PC berdasarkan nilai *eigenvalue* yang lebih dari nol (0) (A. T. W. Almais, Susilo, Naba, Sarosa, Crysdian, Wicaksono, et al., 2023). Sehingga pada penelitian ini dapat mengacu jumlah PC dengan mengambil nilai *eigenvalue* yang lebih besar dari nol (0). Tahapan PCA meliputi pembuatan data frame label, normalisasi data, pembentukan komponen utama, serta penentuan rasio varians dan nilai *eigen* untuk mengevaluasi signifikansi setiap PC. Hasil analisis divisualisasikan dalam bentuk grafik 2D berdasarkan PC dari PCA, untuk memudahkan interpretasi data. Pada tahap akhir merupakan tahap labeling data hasil dari teknik PCA *Clustering* dengan menggunakan acuan dari Almais et al, yang memiliki standart numerik tingkat kerusakan bangunan paca bencana alam yang terdapat pada Tabel 3.1 berikut:

Tabel 3. 1 Nilai Numerik dan Label Tingkat Kerusakan Bangunan Pascabencana Alam (A. T. W. Almais, Susilo, Naba, Sarosa, Crysdian, Wicaksono, et al., 2023)

Nilai (n)	Label
$n < 0$	Rusak Ringan
$0 \leq n < 2$	Rusak Sedang
$n \geq 2$	Rusak Berat

3.3 Data Preparation

Data primer yang digunakan dalam penelitian ini bersumber dari Badan Penanggulangan Bencana Daerah (BPBD) Provinsi Jawa Timur. Pemilihan dataset dari institusi ini didasarkan pada pertimbangan ketersediaan data citra yang telah melalui proses kurasi awal, sehingga memiliki tingkat akurasi dan konsistensi yang cukup baik untuk keperluan analisis visual. Secara kuantitatif, dataset ini mencakup kurang lebih 100 citra yang telah diklasifikasikan berdasarkan jenis bencana yang terekam, seperti banjir, gempa bumi, atau tanah longsor. Keragaman sumber visual yang terkandung di dalamnya—mulai dari citra satelit resolusi menengah, foto udara yang diambil menggunakan drone, hingga rekaman visual langsung dari lapangan—memberikan kekayaan informasi spasial dan temporal yang sangat berharga. Selain itu, seluruh citra tersebut memiliki resolusi yang memadai, sehingga mendukung proses ekstraksi fitur visual secara mendalam, terutama untuk parameter seperti warna, tekstur, dan bentuk objek bangunan yang menjadi fokus analisis.

Penggunaan data dari BPBD yang bersifat terbuka dan dapat diakses secara publik memberikan keuntungan strategis bagi penelitian ini, terutama dalam hal

transparansi dan reproduktifitas. Dengan mengandalkan sumber data yang terverifikasi secara kelembagaan, penelitian ini memiliki landasan empiris yang kuat dan dapat dipertanggungjawabkan secara ilmiah. Ketersediaan data yang sudah terklasifikasi berdasarkan jenis bencana juga memungkinkan peneliti untuk melakukan pengelompokan awal sebelum menerapkan pendekatan unsupervised learning, yang bertujuan untuk mengidentifikasi pola kerusakan bangunan tanpa ketergantungan pada label pelatihan yang bersifat subjektif. Pendekatan ini memanfaatkan secara optimal fitur-fitur visual yang terekstraksi dari citra, seperti perubahan warna pada material bangunan, kekasaran tekstur puing, serta deformasi bentuk struktural, untuk menghasilkan klaster kerusakan yang bermakna. Dengan demikian, dataset dari BPBD Provinsi Jawa Timur tidak hanya berfungsi sebagai sumber informasi visual, tetapi juga sebagai fondasi metodologis yang menjamin bahwa seluruh tahapan analisis berjalan di atas data yang kredibel, terdokumentasi dengan baik, dan terbuka untuk diuji ulang oleh peneliti lain di masa mendatang.

3.4 Skenario Uji Coba

Pengujian pada penelitian ini menggunakan *Internal* dan *External Validation*. Dalam konteks ekstraksi fitur berbasis *EfficientNet-B7* dan *PCA-Clustering* untuk deteksi kerusakan bangunan pascabencana alam, *internal validation* menggunakan *Silhouette Score* (Punhani et al., 2022) merupakan metrik yang digunakan untuk mengevaluasi kualitas *clustering* dengan mengukur seberapa baik data dalam sebuah cluster serupa satu sama lain (koherensi) dan seberapa baik cluster tersebut terpisah dari *cluster* lainnya (separasi).

3.4.1 Validasi Internal

Nilai *Silhouette Score* mengevaluasi sejauh mana data dalam cluster serupa dan terpisah dari *cluster* lain. Nilai berkisar antara -1 (buruk) hingga +1 (baik).

- a. +1: Indikasi *clustering* sangat baik. Data berada di *cluster* yang benar dan jauh dari cluster lainnya.
- b. 0: Data berada di batas dua *cluster*, menunjukkan *ambiguitas*.
- c. -1: *Clustering* buruk. Data lebih dekat ke cluster yang salah daripada ke *cluster* yang benar.

Rumus untuk *Silhouette Score* untuk setiap data i dihitung dengan Persamaan 3.1 (Punhani et al., 2022):

$$S(i) = \frac{b(i) - a(i)}{\max(a(i), b(i))} \dots \dots \dots (3.1)$$

Keterangan:

- a. $a(i)$: Rata-rata jarak data i ke semua data lain dalam cluster yang sama (*internal cohesiveness*).
- b. $b(i)$: Rata-rata jarak data i ke semua data dalam cluster terdekat lainnya (*external separability*).
- c. $\max(a(i), b(i))$: Nilai maksimum antara $a(i)$ dan $b(i)$ untuk normalisasi.

Langkah-langkah perhitungan *Silhouette Score*:

1. Menghitung *Cohesiveness* $a(i)$: Untuk setiap data i dalam cluster C , hitung rata-rata jarak *Euclidean* ke semua data lain dalam cluster C (Persamaan 3.2).

$$a(i) = \frac{1}{|C|-1} \sum_{j \in C, j \neq i} d(i, j) \dots \dots \dots (3.2)$$

Keterangan:

$d(i,j)$: Jarak *Euclidean* antara data i dan j .

$|C|$: Jumlah data dalam cluster C .

2. Menghitung *Separability* $b(i)$: Untuk setiap data i , identifikasi cluster lain C' yang terdekat. Hitung rata-rata jarak data i ke semua data dalam cluster C' .
3. Menghitung *Silhouette Score* untuk Data i : Substitusi nilai $a(i)$ dan $b(i)$ ke dalam rumus (Persamaan 3.3).

$$S(i) = \frac{b(i)-a(i)}{\max(a(i),b(i))} \dots\dots\dots(3.3)$$

4. Menghitung *Silhouette Score* Rata-rata untuk semua data: Setelah menghitung $S(i)$ untuk setiap data, hitung rata-rata semua $S(i)$ untuk mendapatkan skor keseluruhan (Persamaan 3.4).

$$S_{avg} = \frac{1}{N} \sum_{i=1}^N S(i) \dots\dots\dots(3.4)$$

5. Interpretasi Hasil:
 - a. $S_{avg} > 0.5$ *Clustering* sangat baik. Data dalam *cluster* sangat kohesif dan terpisah dengan jelas.
 - b. $0.25 < S_{avg} \leq 0.5$ *Clustering* cukup baik tetapi mungkin ada *overlap* antar-*cluster*.
 - c. $0.25 < S_{avg}$: *Clustering* kurang baik. Data tidak terbagi dengan baik ke dalam *cluster*.

3.4.2 Skenario Tuning Jumlah Cluster

Skenario ini dilakukan dengan melakukan eksperimen terhadap variasi jumlah cluster (k). Sistem akan menguji skenario $k=2$, $k=3$ (sesuai kategori rusak ringan, sedang, berat), hingga $k=5$. Tujuan dari tuning tersebut adalah untuk mencari nilai Silhouette Score tertinggi yang menunjukkan jumlah kelompok paling optimal yang dapat dibentuk oleh fitur visual dari *EfficientNet-B7*. Hal ini memastikan bahwa kategori kerusakan yang dihasilkan bukan merupakan paksaan subjektif, melainkan representasi alami dari sebaran data.

3.4.3 Validasi Eksternal

Skenario terakhir adalah menguji akurasi sistem dengan membandingkan label hasil *PCA-Clustering* terhadap data asli (*ground truth*) yang telah divalidasi oleh ahli atau literatur terkait. Validasi ini menggunakan 5 parameter teknis penilaian kerusakan pascabencana, yaitu:

- Keadaan bangunan.
- Struktur bangunan.
- Kondisi fisik bangunan.
- Fungsi bangunan.
- Kondisi bangunan lainnya.

Data dari 5 parameter ini diolah menggunakan teknik *Weighted Product* (WP) untuk menghasilkan skor kerusakan manual. Skenario dinyatakan berhasil jika label yang dihasilkan sistem (berdasarkan nilai PC1) menunjukkan konsistensi (*robust*) dengan hasil penilaian teknis manual tersebut, misalnya pada saat sistem memberikan nilai $PC1 \geq 2$ untuk kategori "Rusak Berat".

Meskipun pengembangan sistem ekstraksi fitur berbasis AI bertujuan untuk mencapai otomatisasi, survei manual tetap diposisikan sebagai instrumen krusial dalam tahap validasi eksternal. Data pembanding (*ground truth*) diperoleh melalui penilaian ahli yang mengacu pada 5 parameter teknis utama, yaitu keadaan bangunan, struktur, kondisi fisik, fungsi, dan kondisi bangunan lainnya (A. T. Almais et al., 2020; A. T. W. Almais et al., 2016; Bachriwindi et al., 2019; Safitri et al., 2022). Prosedur ini dilakukan untuk memastikan bahwa pengelompokan tingkat kerusakan yang dihasilkan oleh algoritma PCA-Clustering memiliki landasan yang valid secara teknis dan selaras dengan standar penilaian yang berlaku di lapangan (A. T. W. Almais, Susilo, Naba, Sarosa, Crysdian, Wicaksono, et al., 2023).

3.5 Instrumen Penelitian

Variabel bebas dalam penelitian ini adalah fitur visual yang diekstraksi dari gambar bangunan pascabencana alam menggunakan metode *EfficientNet-B7*. Fitur-fitur ini mencakup tekstur, warna, dan bentuk. Tekstur menggambarkan pola atau struktur permukaan bangunan yang terekam dalam gambar, sedangkan warna memberikan informasi visual untuk membedakan area yang rusak atau utuh. Bentuk menggambarkan kontur atau struktur geometris bangunan. Semua fitur ini dihasilkan dari pengolahan gambar menggunakan *EfficientNet-B7*, sebuah arsitektur jaringan saraf tiruan yang dirancang untuk menangkap informasi visual secara efisien.

Variabel antara dalam penelitian ini adalah hasil reduksi dimensi data menggunakan metode PCA. PCA digunakan untuk mengurangi dimensi data fitur

yang besar dan kompleks menjadi sejumlah komponen utama yang signifikan, sekaligus mempertahankan informasi penting dari data tersebut. Hasil reduksi ini kemudian digunakan sebagai input dalam proses *clustering* untuk mengelompokkan tingkat kerusakan bangunan.

Variabel terikat adalah tingkat kerusakan bangunan, yang merupakan hasil akhir dari analisis *clustering*. Tingkat kerusakan ini dikategorikan ke dalam tiga kategori utama, yaitu rusak ringan (kerusakan kecil yang tidak mengganggu struktur utama bangunan), rusak sedang (kerusakan yang memengaruhi sebagian besar struktur), dan rusak berat (kerusakan parah yang membuat bangunan tidak dapat digunakan lagi). Kategori ini ditentukan berdasarkan analisis *PCA-Clustering* yang mengidentifikasi pola kerusakan dari fitur visual yang telah diekstraksi.


Hubungan antar variabel dimulai dari variabel bebas, yaitu fitur yang diekstraksi menggunakan *EfficientNet-B7*, yang memengaruhi proses reduksi dimensi (variabel antara) melalui PCA. Variabel antara ini menjadi dasar bagi pengelompokan tingkat kerusakan. Variabel terikat, yaitu tingkat kerusakan bangunan, merupakan hasil akhir yang bergantung pada kualitas fitur yang diekstraksi dan keakuratan pengelompokan yang dilakukan. Alur hubungan ini menunjukkan keterkaitan logis antara setiap variabel dalam mendukung analisis kerusakan bangunan pascabencana alam. Instrumen penelitian ini melibatkan berbagai aspek yang mendukung tujuan penelitian. Data yang digunakan adalah gambar bangunan pascabencana alam dari BPBD Provinsi Jawa Timur, yang bersumber dari citra satelit, foto drone, dan rekaman lapangan langsung. Gambar-gambar ini dipilih dengan kriteria resolusi yang cukup untuk memungkinkan

ekstraksi fitur, serta dikategorikan berdasarkan lokasi, jenis bencana, dan tingkat kerusakan.

BAB IV

HASIL DAN IMPLEMENTASI

Pada bab hasil dan implementasi dijelaskan tentang proses dalam menentukan tingkat kerusakan bangunan menggunakan *EfficientNet-B7* dan *PCA-Clustering*. Proses input gambar sampai bentuk visualisasi hasil terlihat pada Gambar 4.1 yang merupakan bentuk hasil akhir dari proses penerapan *EfficientNet-B7* dan *PCA-Clustering* dalam menentukan tingkat kerusakan bangunan pascabencana alam.



Gambar 4. 1 Visualisasi hasil penerapan *EfficientNet-B7* dan *PCA-Clustering*

Pada Gambar 4.1 terlihat bahwa terdapat beberapa langkah untuk menentukan visualisasi hasil. Berikut merupakan keterangan proses dari langkah-langkah pada Gambar 4.1:

4.1. Penyajian Data Kasus dan Metodologi Singkat

Menginputkan gambar bangunan pascabencana alam sebagai objek kasus. Input gambarnya terdapat pada Gambar 4.2. Kemudian, Gambar 4.2 masuk proses identifikasi objek agar dapat menggunakan pendekatan analisis yang tepat. Penelitian ini menggunakan pendekatan analisis PCA yang menggunakan input data hasil dari ekstraksi fitur metode *EfficientNet-B7*.



Gambar 4. 2 Input data bangunan pasca bencana alam

4.2. Analisis Parameter Tekstur

Tahapan ini merupakan tahapan proses mengekstraksi fitur gambar menggunakan teknik *EfficientNet-B7* yang menghasilkan nilai *feature entropy*,

normalized std, *contrast*, *homogeneity*, dan *skewness*. Untuk masing-masing fitur memiliki fungsi yang berbeda-beda seperti *future entropy* berfungsi untuk mengetahui kompleksitas dari nilai fitur. Untuk penerapan *future entropy* menggunakan Persamaan (4.2), sedangkan *normalized std* berfungsi untuk mengetahui nilai dari variasi dari hasil nilai fitur menggunakan Persamaan (4.1), *contrast* merupakan gambaran dari nilai kekuatan tepi dari hasil ekstraksi fitur menggunakan gambar yang menggunakan Persamaan (4.3), sedangkan *homogeneity* merupakan nilai dari keseragaman nilai fitur hasil dari ekstraksi fitur gambar yang menggunakan Persamaan (4.4), dan *skewnes* merupakan nilai yang menggambarkan distribusi asimetri dari hasil ekstraksi fitur gambar yang menggunakan Persamaan (4.5). Berikut ini merupakan tahapan-tahapan ekstraksi fitur menggunakan *EfficientNet-B7*:

1. Tahap Prapemrosesan Citra

Sebelum diekstraksi, citra bangunan harus disiapkan agar sesuai dengan standar input model *EfficientNet-B7*:

- **Resize:** mengubah ukuran citra menjadi 600x600 piksel.
- **Format Warna:** mengkonversi cita menjadi format RGB.
- **Normalisasi:** Nilai piksel diproses menggunakan fungsi *preprocess_input* untuk menyesuaikan distribusi data dengan bobot prainstal (*ImageNet*).

2. Ekstraksi Fitur Deep Learning

Menggunakan model *EfficientNet-B7* sebagai ekstraktor fitur utama:

- Memuat model tanpa menggunakan lapisan klasifikasi akhir (*include_top=False*) dengan *pooling* rata-rata global (*avg pooling*).
- Hasilnya adalah sebuah vektor fitur tunggal berdimensi 2560 yang merepresentasikan detail visual tingkat tinggi dari citra tersebut.

3. Ekstraksi Karakteristik Tekstur

Setelah mendapatkan vektor fitur berdimensi 2560 (F), sistem melakukan analisis adaptif untuk menghitung statistik tekstur berikut:

- Variasi Tekstur (*Normalized Std*):

Untuk mengukur sebaran data fitur terhadap rata-ratanya, dapat menggunakan Persamaan 4.1.

$$V = \frac{\sigma(F)}{\mu(F)+10^{-8}} \quad 4.1$$

- Entropi (*Complexity*):

Menggunakan Persamaan 4.2 untuk mengukur tingkat kompleksitas fitur.

Sebelumnya menormalisasi fitur terlebih dahulu menggunakan persamaan

$$\text{berikut: } p = \frac{|F|}{\sum |F|}$$

$$E = \frac{-\sum (p \cdot \log(p+10^{-8}))}{\log(\text{textlen}(F))} \quad 4.2$$

- Kontras (*Edge Strength*):

Menggunakan Persamaan 4.3 untuk mengestimasi kekuatan tepi visual berdasarkan rentang nilai fitur.

$$C = \frac{\max(F) - \min(F)}{\mu(F)+10^{-8}} \times 0.1 \quad 4.3$$

- Homogenitas (*Uniformity*):

Menggunakan Persamaan 4.4 untuk mengukur keseragaman permukaan berdasarkan koefisien variasi $cv = \sigma/\mu$.

$$H = \frac{1.0}{1.0+cv} \quad 4.4$$

- Asimetri (*Skewness*):

Persamaan 4.5 merupakan persamaan untuk mengukur kemiringan distribusi data fitur.

$$S = \left| \frac{\sum(F-\mu)^3}{n \cdot \sigma^3} \right| \quad 4.5$$

4. Penggabungan Menjadi *Damage Indicator*

Menggabungkan semua hasil fitur tekstur tersebut menggunakan rumus berbobot yang ada pada Persamaan 4.6 untuk menghasilkan skor kerusakan tunggal:

$$DamageScore = (V \times 0.30) + (E \times 0.25) + (C \times 0.20) + (S \times 0.15) + ((1 - H) \times 0.10) \quad 4.6$$

Langkah selanjutnya menggunakan hasil nilai *Damage Score* untuk memetakan menjadi PC1 untuk menentukan apakah bangunan termasuk tingkat kerusakan ringan, sedang, atau berat. Kemudian memvisualisasikan hasil dari *Damage Score* dalam bentuk grafik batang untuk mempermudah interpretasi karakteristik fisik bangunan yang rusak.

Hasil dari seluruh ekstraksi fitur menggunakan *EfficientNet-B7* dengan input gambar, yaitu Gambar 4.2, telah menghasilkan karakteristik nilai fitur

entropy, normalized std, contrast, homogeneity, dan skewness yang berbeda-beda.

Untuk melihat nilai semua fitur tersebut, terdapat pada Tabel 4.1.

Tabel 4. 1 Nilai Texture characteristics

Fitur	
Nama	Nilai
<i>Future 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 ekstraksi nilai *texture characteristics* yang tercantum pada Gambar 4.2 telah berhasil dikuantifikasi dan disajikan secara sistematis dalam Tabel 4.1. Tabel tersebut memuat beragam parameter tekstur, seperti kontras, korelasi, energi, homogenitas, dan entropi, yang merepresentasikan karakteristik visual dari setiap sampel citra bangunan pasca-bencana. Dengan tersedianya data kuantitatif tersebut, langkah analisis selanjutnya adalah melakukan interpretasi lebih lanjut guna mengungkap pola tersembunyi yang tidak kasat mata secara langsung. Untuk itu, pendekatan statistika multivariat yang digunakan adalah kombinasi antara *Principal Component Analysis* (PCA) dan algoritma *Clustering* (PCA-Clustering). Pendekatan ini dipilih karena kemampuannya dalam mereduksi dimensi data yang kompleks tanpa kehilangan informasi penting, sekaligus mengelompokkan objek berdasarkan kemiripan karakteristik teksturnya secara objektif.

Proses awal dalam kerangka PCA-Clustering dimulai dengan menjadikan Tabel 4.1 sebagai matriks input utama. Seluruh nilai *texture characteristics* dari setiap sampel diperlakukan sebagai variabel independen yang saling berkorelasi. Melalui PCA, data awal yang bersifat multidimensi ditransformasi menjadi komponen-komponen utama (*principal components*) yang tidak saling berkorelasi, di mana komponen pertama (PC1) dan komponen kedua (PC2) biasanya menampung sebagian besar varians total. Transformasi ini sangat penting karena menyederhanakan struktur data, sehingga memudahkan proses visualisasi dan identifikasi pola pengelompokan. Setelah diperoleh skor PCA untuk setiap sampel, langkah berikutnya adalah menerapkan algoritma *clustering*, misalnya *K-Means* atau *Hierarchical Clustering*, terhadap skor komponen utama tersebut. Tujuan dari tahap ini adalah untuk mengetahui secara empiris bagaimana data dari seluruh nilai *texture characteristics* terbagi ke dalam sejumlah klaster alami berdasarkan tingkat kemiripan sifat teksturnya. Jumlah klaster optimum dapat ditentukan melalui metode *elbow* atau *silhouette score* untuk memastikan bahwa pengelompokan yang dihasilkan memiliki validitas statistik yang kuat.

Setelah proses *clustering* berhasil dilakukan dan setiap sampel telah memperoleh keanggotaan klaster tertentu, langkah krusial selanjutnya adalah memberikan interpretasi atau pelabelan terhadap masing-masing klaster tersebut. Pelabelan ini tidak dilakukan secara sembarangan, melainkan mengacu pada kerangka acuan yang telah teruji secara ilmiah, yaitu penelitian yang dilakukan oleh Almais et al. (2023). Dalam penelitian tersebut, telah ditetapkan sebuah standar baku mengenai tingkat kerusakan bangunan pasca bencana alam yang didasarkan

pada rentang nilai PC1. Standar ini memetakan nilai PC1 ke dalam beberapa kategori kerusakan, misalnya mulai dari "ringan", "sedang", "berat", hingga "hancur total", dengan batas ambang yang jelas dan terukur. Dengan mengacu pada standar tersebut, setiap klaster yang terbentuk dari data tekstur dapat diberi label kerusakan yang sesuai, sehingga hubungan antara karakteristik tekstur citra dan tingkat kerusakan fisik bangunan dapat dimaknai secara kuantitatif dan objektif. Proses pelabelan ini juga memungkinkan dilakukannya validasi silang antara hasil *clustering* berbasis data dengan klasifikasi kerusakan yang telah ditetapkan secara teoritis. Akhirnya, Tabel 4.2 disusun sebagai ringkasan dari standar nilai tingkat kerusakan bangunan pasca bencana alam berdasarkan nilai PC1, yang sekaligus menjadi acuan utama dalam interpretasi hasil PCA-Clustering. Dengan adanya tabel tersebut, analisis tidak hanya berhenti pada pengelompokan statistik, tetapi juga menghasilkan informasi yang aplikatif dan relevan secara praktis bagi upaya mitigasi dan penanganan pasca-bencana.

Tabel 4. 2 Standard nilai PC1 (A. T. W. Almais, Susilo, Naba, Sarosa, Crysdian, Wicaksono, et al., 2023).

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

Hasil Gambar 4.2 berdasarkan hasil *texture characteristics* pada Tabel 4.1 yang sudah masuk proses PCA-Clustering menghasilkan nilai PC1 sebesar 5.000. Nilai PC1 tersebut lebih dari 2, maka berdasarkan standar nilai yang ada pada Tabel

4.2, Gambar 4.2 memiliki informasi tingkat kerusakan bangunan rusak berat (warna merah).

Tabel 4. 3 *Cluster Statistics for PC1*

	PC1	PC1	PC1	PC1	PC1	PC1	PC1	PC1
	count	mean	std	min	25%	50%	75%	max
Cluster								
0	249	0.806936	0.171596	0.414582	0.68427	0.790471	0.926177	1.344355
1	250	-1.55177	0.17448	-1.96866	-1.67013	-1.55534	-1.42853	-1.14354
2	250	0.979696	0.164417	0.528369	0.882085	0.971934	1.086666	1.382043
3	251	-0.23071	0.18054	-0.71983	-0.34665	-0.22741	-0.09577	0.252207

Tabel 4.3 menyajikan hasil ringkasan statistik dari pengelompokan (*clustering*) data berdasarkan komponen utama pertama (PC1) yang dihasilkan dari analisis PCA terhadap nilai-nilai *texture characteristics*. Secara keseluruhan, data berhasil dikelompokkan menjadi empat klaster berbeda, yang diberi label 0 hingga 3, dengan jumlah anggota yang hampir seimbang, yaitu masing-masing sekitar 249 hingga 251 sampel. Hal ini menunjukkan bahwa proses *clustering* berjalan dengan baik dan tidak terjadi ketimpangan distribusi data antar klaster.

Dari sisi nilai PC1, terlihat bahwa keempat klaster memiliki rentang nilai yang sangat kontras satu sama lain. Klaster 1 memiliki nilai PC1 terendah, dengan rata-rata (mean) mencapai -1,55 dan rentang dari -1,97 hingga -1,14, yang mengindikasikan bahwa sampel dalam klaster ini memiliki karakteristik tekstur yang sangat berbeda secara ekstrem dari klaster lainnya. Sebaliknya, klaster 2 menunjukkan nilai PC1 tertinggi, dengan rata-rata 0,98 dan rentang 0,53 hingga 1,38, yang menempatkannya sebagai kelompok dengan kecenderungan tekstur paling tinggi. Sementara itu, klaster 0 berada di posisi menengah atas dengan rata-rata 0,81 dan rentang 0,41 hingga 1,34, sedangkan klaster 3 terletak di posisi

menengah bawah dengan rata-rata -0,23 dan rentang -0,72 hingga 0,25. Dengan demikian, keempat klaster membentuk spektrum yang terurut dari nilai PC1 terendah (klaster 1) hingga tertinggi (klaster 2), dengan klaster 3 dan 0 berada di antara keduanya.

Selain nilai rata-rata, standar deviasi (*std*) dari keempat klaster juga relatif kecil dan seragam, berkisar antara 0,16 hingga 0,18, yang menunjukkan bahwa data di dalam masing-masing klaster memiliki tingkat penyebaran yang rendah dan cenderung homogen. Artinya, setiap klaster benar-benar mewakili kelompok sampel dengan karakteristik tekstur yang mirip satu sama lain. Nilai kuartil (25%, 50%, dan 75%) juga memperkuat konsistensi ini, di mana sebaran antar kuartil terlihat kompak tanpa adanya lonjakan nilai yang mencolok. Nilai minimum dan maksimum dari masing-masing klaster juga tidak tumpang tindih secara signifikan antar klaster, terutama untuk klaster 1 dan 2, yang menunjukkan bahwa pemisahan antar kelompok sangat jelas dan diskrit.

Secara keseluruhan, tabel ini memberikan gambaran bahwa hasil PCA-Clustering berhasil memisahkan data tekstur bangunan ke dalam empat tingkatan yang berbeda secara statistik. Berdasarkan acuan standar dari Almaiz et al. (2023), nilai PC1 yang semakin rendah dapat diinterpretasikan sebagai tingkat kerusakan yang semakin berat, sedangkan nilai PC1 yang semakin tinggi menunjukkan kondisi bangunan yang relatif lebih utuh atau rusak ringan. Dengan demikian, klaster 1 kemungkinan besar mewakili bangunan dengan kerusakan paling parah, klaster 3 mewakili kerusakan sedang, klaster 0 mewakili kerusakan ringan, dan klaster 2 mewakili bangunan dalam kondisi paling baik atau hampir tidak rusak.

Pemetaan ini sangat bermanfaat untuk mendukung analisis lanjutan dan pengambilan keputusan dalam penanganan pasca-bencana.

Tabel 4. 4 *Cluster Statistics for PC2*

	PC2	PC2	PC2	PC2	PC2	PC2	PC2	PC2
	count	mean	std	min	25%	50%	75%	max
Cluster								
0	249	-0.57388	0.171796	-1.01796	-0.69569	-0.57817	-0.46224	-0.05072
1	250	0.64299	0.176099	0.037734	0.531757	0.634879	0.769971	1.093469
2	250	1.179692	0.175406	0.70359	1.064583	1.183964	1.293542	1.584934
3	251	-1.24611	0.16804	-1.87483	-1.36121	-1.2362	-1.14823	-0.70819

Tabel tersebut menyajikan statistik deskriptif nilai PC2 (*Principal Component 2*) pada hasil *clustering* yang terdiri dari 4 *cluster* (0, 1, 2, dan 3). Masing-masing *cluster* memiliki jumlah anggota yang relatif seimbang, yaitu *Cluster* 0 sebanyak 249 data, *Cluster* 1 sebanyak 250 data, *Cluster* 2 sebanyak 250 data, dan *Cluster* 3 sebanyak 251 data.

Berdasarkan nilai rata-rata (*mean*), *Cluster* 2 memiliki nilai PC2 tertinggi yaitu 1,179692, menunjukkan bahwa anggota cluster ini cenderung berada pada sisi positif yang paling tinggi pada komponen utama kedua. Sebaliknya, *Cluster* 3 memiliki nilai rata-rata terendah yaitu -1,24611, sehingga anggotanya berada pada sisi negatif yang paling rendah. Sementara itu, *Cluster* 1 memiliki rata-rata positif yang lebih rendah yaitu 0,64299, dan *Cluster* 0 memiliki rata-rata negatif sebesar -0,57388.

Dilihat dari penyebaran data (*standard deviation*), seluruh cluster memiliki nilai simpangan baku yang relatif kecil, berkisar antara 0,16804 hingga 0,175406, yang menunjukkan bahwa data dalam masing-masing *cluster* cukup homogen dan terkonsentrasi di sekitar nilai rata-ratanya. Nilai minimum dan maksimum juga


memperlihatkan batas sebaran setiap *cluster*. Cluster 2 memiliki rentang nilai dari 0,70359 hingga 1,584934, sedangkan Cluster 3 memiliki rentang dari -1,87483 hingga -0,70819. *Cluster* 1 berada pada rentang 0,037734 hingga 1,093469, sementara Cluster 0 berada pada rentang -1,01796 hingga -0,05072.

Nilai kuartil (25%, 50%, dan 75%) semakin menegaskan karakteristik masing-masing cluster. Median (50%) Cluster 2 sebesar 1,183964 dan Cluster 3 sebesar -1,2362, menunjukkan posisi pusat data yang sangat berbeda di sepanjang sumbu PC2. Cluster 1 memiliki median 0,634879, sedangkan Cluster 0 memiliki median -0,57817. Secara keseluruhan, hasil ini menunjukkan bahwa proses clustering berhasil memisahkan data menjadi empat kelompok yang berbeda berdasarkan nilai PC2, dengan dua *cluster* berada pada wilayah nilai positif (*Cluster* 1 dan 2) dan dua *cluster* berada pada wilayah nilai negatif (Cluster 0 dan 3), serta memiliki tingkat variasi internal yang relatif rendah.

4.3. Visualisasi Hasil

Hasil nilai PC1 merupakan bentuk nilai koordinat sumbu x untuk visualisasi 2 dimensi (2D). Dengan menggunakan grafik 2D, dapat menggambarkan letak nilai koordinat hasil dari PC1. Nilai PC1 berasal dari proses ekstraksi fitur *EfficientNet-B7*. Hasilnya, nilai PC1 dapat divisualisasikan seperti pada Gambar 4.3, yang menjelaskan letak nilai PC1 pada titik koordinat lebih dari 2. Sehingga memiliki label informasi rusak berat (warna merah), karena berdasarkan standar acuan tingkat kerusakan bangunan pasca bencana alam yang ada pada Tabel 4.2. Sehingga, menggunakan visualisasi 2D dapat memudahkan pembaca dalam

memvisualisasikan informasinya secara langsung. Seperti terlihat pada Gambar 4.3 yang menggambarkan hasil dari Gambar 4.1 yang mengeluarkan informasi lebih mudah terbaca karena langsung bentuk titik yang menempatkan posisinya berdasarkan proses ekstraksi fitur menggunakan *EfficientNet-B7* yang mengelompokkan datanya menggunakan PCA atau istilahnya *PCA-Clustering* (A. T. W. Almaais, Susilo, Naba, Sarosa, Crysdian, Wicaksono, et al., 2023).




Gambar 4. 3 Hasil Visualisasi Titik Koordinat PC1

Berdasarkan hasil analisis menggunakan input Gambar 4.2, indikasi bahwa masuk ke *cluster* tingkat kerusakan bangunan pascabencana alam yaitu rusak berat (warna merah). Gambar 4.2 terdeteksi masuk ke *cluster* rusak berat karena hasil ekstraksi fitur memiliki nilai PC1 lebih besar dari 2, yaitu 5.000.

Pada Gambar 4.4 memperlihatkan perkembangan nilai akurasi (*accuracy*) selama proses pelatihan dan validasi model *EfficientNet-B7*. Akurasi pelatihan menunjukkan kemampuan model dalam mengenali pola kerusakan pada data yang digunakan selama proses pembelajaran, sedangkan akurasi validasi

menggambarkan kemampuan model dalam melakukan generalisasi terhadap data yang tidak terlibat langsung dalam proses pelatihan.



Gambar 4. 4 Kurva Akurasi Pelatihan dan Validasi EfficientNet-B7

Berdasarkan grafik Gambar 4.4., nilai akurasi mengalami peningkatan secara konsisten dari *epoch* awal hingga *epoch* akhir. Pada tahap awal pelatihan, model masih berada pada fase adaptasi sehingga akurasi relatif rendah. Seiring bertambahnya jumlah *epoch*, model mampu mempelajari karakteristik visual kerusakan rumah pasca bencana dengan lebih baik, yang ditunjukkan oleh peningkatan akurasi pada data pelatihan maupun data validasi.

Perbedaan yang relatif kecil antara kurva training *accuracy* dan validation *accuracy* menunjukkan bahwa model tidak mengalami gejala overfitting yang signifikan. Kondisi tersebut mengindikasikan bahwa fitur yang dipelajari oleh *EfficientNet-B7* mampu merepresentasikan karakteristik kerusakan bangunan secara umum dan tidak hanya menghafal pola pada data pelatihan. Hasil ini menunjukkan bahwa arsitektur *EfficientNet-B7* memiliki kemampuan yang baik

dalam mengekstraksi informasi visual yang relevan untuk membedakan tingkat kerusakan bangunan pasca bencana.

Sedangkan pada Gambar 4.5 menunjukkan perubahan nilai *loss* selama proses pelatihan dan validasi model *EfficientNet-B7*. Nilai *loss* merepresentasikan tingkat kesalahan model dalam memprediksi atau merepresentasikan data. Semakin kecil nilai *loss*, semakin baik kemampuan model dalam memahami pola yang terdapat pada data citra.




Gambar 4. 5 Kurva Loss Pelatihan dan Validasi EfficientNet-B7

Pada awal proses pelatihan, nilai *loss* masih relatif tinggi karena parameter model belum mampu menangkap karakteristik visual kerusakan secara optimal. Namun, seiring bertambahnya *epoch*, nilai *loss* mengalami penurunan yang signifikan baik pada data pelatihan maupun data validasi. Penurunan *loss* yang stabil menunjukkan bahwa proses optimasi berjalan dengan baik dan model berhasil menemukan representasi fitur yang semakin akurat. Selain itu, tidak terlihat adanya peningkatan *validation loss* pada *epoch* akhir sehingga dapat disimpulkan bahwa model tidak mengalami *overfitting* yang berlebihan. Hasil pada Gambar 4.5

memperlihatkan bahwa proses *fine-tuning EfficientNet-B7* berhasil menghasilkan model yang stabil dan mampu digunakan sebagai ekstraktor fitur untuk analisis tingkat kerusakan rumah pasca bencana.

Kemudian pada Gambar 4.6 menunjukkan kontribusi variasi data yang mampu dijelaskan oleh masing-masing komponen utama (*Principal Component*) hasil reduksi dimensi PCA. Variasi yang dijelaskan (*explained variance*) digunakan untuk mengukur seberapa besar informasi dari data asli yang dapat dipertahankan oleh setiap komponen utama.




Gambar 4. 6 Kontribusi Variasi Setiap Komponen Utama PCA

Pada Gambar 4.6 terlihat bahwa komponen utama pertama (PC1) memiliki kontribusi variasi terbesar dibandingkan komponen lainnya. Hal ini menunjukkan bahwa sebagian besar informasi yang terkandung dalam vektor fitur hasil ekstraksi *EfficientNet-B7* telah terwakili oleh PC1. Komponen utama kedua (PC2) memberikan kontribusi tambahan yang cukup signifikan dalam menjelaskan variasi data.

Semakin tinggi persentase variasi yang dijelaskan oleh beberapa komponen utama pertama, semakin efektif proses reduksi dimensi yang dilakukan oleh PCA.

Dengan demikian, data berdimensi tinggi dapat direpresentasikan dalam ruang dimensi yang lebih rendah tanpa kehilangan informasi yang signifikan. Hasil ini menunjukkan bahwa fitur yang dihasilkan *EfficientNet-B7* memiliki struktur informasi yang kuat sehingga dapat direduksi secara efektif menggunakan PCA.

Gambar 4.7 memperlihatkan distribusi data hasil ekstraksi fitur setelah diproyeksikan ke dalam dua komponen utama PCA, yaitu PC1 dan PC2. Visualisasi ini bertujuan untuk mengamati pola persebaran data dan hubungan antar sampel dalam ruang fitur yang telah direduksi.




Gambar 4. 7 Sebaran Data pada Ruang PCA

Pada Gambar 4.7 terlihat bahwa data membentuk beberapa kelompok yang relatif terpisah satu sama lain. Pemisahan tersebut menunjukkan bahwa fitur yang dihasilkan *EfficientNet-B7* mampu membedakan karakteristik visual rumah dengan tingkat kerusakan yang berbeda. Kelompok data yang memiliki jarak berdekatan menunjukkan kemiripan karakteristik visual, sedangkan kelompok yang berjauhan menunjukkan adanya perbedaan yang cukup signifikan dalam pola kerusakan bangunan. Dengan demikian, hasil visualisasi PCA memberikan indikasi awal

bahwa proses pengelompokan tingkat kerusakan dapat dilakukan secara efektif berdasarkan representasi fitur yang telah diekstraksi. Selain itu, visualisasi Gambar 4.7 juga menunjukkan bahwa reduksi dimensi menggunakan PCA berhasil mempertahankan struktur data asli sehingga hubungan antar sampel masih dapat diamati dengan jelas.

Selanjutnya pada Gambar 4.8 menunjukkan distribusi jumlah data pada tiga kelompok tingkat kerusakan yang terbentuk berdasarkan analisis PCA. Ketiga kelompok tersebut merepresentasikan kategori kerusakan ringan, kerusakan sedang, dan kerusakan berat. Distribusi data pada masing-masing kluster memberikan gambaran mengenai proporsi kondisi kerusakan yang terdapat dalam dataset penelitian. Kluster dengan jumlah anggota terbesar menunjukkan kategori kerusakan yang paling dominan ditemukan pada data citra rumah pasca bencana.



Gambar 4. 8 Distribusi Data pada Tiga Kluster Tingkat Kerusakan

Keberadaan tiga kelompok yang berbeda menunjukkan bahwa kombinasi fitur hasil ekstraksi *EfficientNet-B7*, parameter tekstur, dan *Damage Score* mampu membentuk struktur data yang cukup jelas untuk membedakan tingkat kerusakan bangunan. Selain memberikan informasi mengenai proporsi data, visualisasi ini juga menjadi dasar dalam interpretasi tingkat kerusakan yang digunakan pada tahap analisis selanjutnya.

4.4 Interpretasi Tingkat Kerusakan Berdasarkan Kluster

Berdasarkan hasil analisis PCA dan pembentukan kluster, diperoleh tiga kategori tingkat kerusakan bangunan pasca bencana, yaitu:

Kluster 1 – Kerusakan Ringan

Kelompok ini terdiri atas bangunan yang masih mempertahankan sebagian besar struktur utamanya. Kerusakan yang terlihat umumnya berupa retakan kecil pada dinding, kerusakan ringan pada atap, atau kerusakan non-struktural lainnya. Nilai *Damage Score* pada kelompok ini relatif rendah karena tingkat kompleksitas tekstur kerusakan masih kecil.

Kluster 2 – Kerusakan Sedang

Kelompok ini menunjukkan adanya kerusakan yang lebih signifikan dibandingkan kluster pertama. Beberapa bagian struktur bangunan mengalami kerusakan parsial, seperti runtuhnya sebagian atap atau kerusakan pada elemen struktural tertentu. Nilai parameter tekstur dan *Damage Score* cenderung berada pada tingkat menengah.

Kluster 3 – Kerusakan Berat

Kelompok ini merepresentasikan bangunan dengan tingkat kerusakan paling tinggi. Kerusakan yang terjadi umumnya melibatkan runtuhnya sebagian besar struktur bangunan sehingga menghasilkan pola tekstur yang sangat kompleks dan tidak teratur. Nilai *Damage Score* pada kelompok ini merupakan yang tertinggi dibandingkan kelompok lainnya.

Secara keseluruhan, hasil penelitian menunjukkan bahwa kombinasi *EfficientNet-B7*, parameter tekstur, *Damage Score*, dan PCA mampu menghasilkan pemisahan tingkat kerusakan bangunan yang jelas dan dapat digunakan sebagai dasar penilaian kondisi rumah pasca bencana secara otomatis.


BAB V

UJI COBA

Menggunakan jenis evaluasi hasil dengan dua jenis yaitu internal dan eksternal. Untuk internal dengan mengukur hasil cluster dari proses PCA-*Clustering* menggunakan teknik *Shilhouette Score*. Pada Gambar 5.1 merupakan hasil *shilhouette score* yang berdasarkan teorinya *Punhani et al*, jika nilai *shilhouette score* mendekati angka 1 maka hasil cluster adalah sangat baik (*Punhani et al.*, 2022). Pada penelitian ini menghasilkan nilai *Shilhouette Score* yang berbeda-beda pada setiap *cluster*, untuk *cluster* 0 memiliki nilai *Shilhouette Score* sebesar 0.9, *cluster* 1 sebesar 0.75, dan untuk *cluster* 2 memiliki nilai *Shilhouette Score* sebesar 0.9. Berdasarkan nilai *Shilhouette Score* yang sudah ada pada setiap cluster maka jika mengacu standart *Shilhouette Score* dari *Punhani et al*, maka hasil dari penelitian ini memiliki hasil cluster yang sangat baik.

Jenis evaluasi hasil yang kedua adalah menggunakan evaluasi eksternal yaitu membandingkan hasil dari PCA-*Clustering* dengan data aslinya yang sudah tervalidasi berdasarkan ahlinya atau bisa berdasarkan artikel yang membahas obyek yang sama dengan penelitian ini. Pada penelitiannya *Bachriwindi et al*, menjelaskan bahwa untuk menilai tingkat kerusakan bangunan pasca bencana alam dapat menggunakan 5 parameter yaitu keadaan bangunan, struktur bangunan, kondisi fisik bangunan, fungsi bangunan, dan kondisi bangunan lainnya (*Bachriwindi et al.*, 2019). Pada Gambar 4.2 jika menilai tingkat kerusakannya berdasarkan 5 parameter tersebut menghasilkan suatu hasil yang memiliki nilai 3 (rusak berat),

jika di proses menggunakan teknik *Weighted Product* (WP) akan menghasilkan tingkat kerusakan bangunan rusak berat. Karena 5 parameter yang digunakan memiliki nilai rusak berat semuanya.



Gambar 5. 1 Nilai Silhouette Score

Evaluasi terhadap efektivitas sistem dilakukan pada penelitian ini melalui dua pendekatan, yaitu validasi internal dan validasi eksternal.

- 1) Validasi Internal (*Silhouette Score*): Untuk mengukur kualitas pengelompokan (*clustering*), digunakan metrik Silhouette Score yang menilai tingkat kohesi dan separasi data. Hasil pengujian menunjukkan nilai yang sangat baik pada setiap cluster, yaitu *Cluster 0* sebesar 0.9, *Cluster 1* sebesar 0.75, dan *Cluster 2* sebesar 0.9. Berdasarkan standar interpretasi, skor yang mendekati angka 1 (khususnya di atas 0,5) menandakan bahwa data dalam setiap *cluster* sangat kohesif dan terpisah secara jelas dari *cluster* lainnya, sehingga hasil pengelompokan dalam penelitian ini dikategorikan sangat baik.

2) Validasi Eksternal dan Akurasi Metode Validasi eksternal dilakukan dengan membandingkan luaran sistem *PCA-Clustering* terhadap data asli yang telah diverifikasi oleh ahli berdasarkan lima kriteria teknis: keadaan bangunan, struktur, kondisi fisik, fungsi, dan kondisi lainnya. Sebagai contoh, pada pengujian gambar sampel, sistem menghasilkan nilai PC1 sebesar 5.000, yang secara otomatis menempatkan bangunan tersebut dalam kategori "Rusak Berat". Hasil ini terbukti konsisten (robust) dan akurat karena selaras dengan penilaian manual ahli yang juga menetapkan status rusak berat berdasarkan kriteria teknis yang sama.


Tingkat akurasi dan konsistensi yang tinggi ini merupakan hasil langsung dari sinergi antara *EfficientNet-B7* dan PCA. Penggunaan *EfficientNet-B7* sebagai ekstraktor fitur utama memungkinkan sistem menangkap detail visual tingkat tinggi secara otonom dari vektor berdimensi 2560, sehingga menghilangkan ketergantungan pada parameter manual dan mengurangi potensi bias atau subjektivitas manusia dalam penilaian.

Selanjutnya, peran PCA sangat krusial dalam mereduksi dimensi data yang kompleks tersebut dengan tetap mempertahankan informasi yang paling signifikan, sehingga pola tingkat kerusakan bangunan dapat diidentifikasi secara lebih terstruktur dan akurat dibandingkan dengan metode konvensional. Secara keseluruhan, hasil evaluasi ini menunjukkan bahwa kerangka kerja terintegrasi ini mampu memberikan pelabelan tingkat kerusakan yang masuk akal dan detail, yang sangat berguna untuk evaluasi cepat di lapangan dalam kondisi darurat pascabencana.

BAB VI

PEMBAHASAN

Dari hasil yang sudah ada pada BAB IV, terdapat beberapa hal yang menarik untuk menjadi pembahasan dan diskusi untuk keberlanjutan dan keterbaruan penelitian ini. Sebelum melakukan analisis terhadap hasil pelabelan, melakukan tuning jumlah cluster untuk memastikan bahwa model yang dibangun telah mencapai titik optimal. Pengujian dilakukan dengan membandingkan nilai *Silhouette Score* pada berbagai jumlah *cluster*. Gambar 6.1 merupakan grafik nilai *Silhouette Score* dari semua jumlah kluster (*k*).




Gambar 6. 1 Nilai Silhouette Score berdasarkan Jumlah Kluster (*k*)

Pada BAB V ini juga membahas untuk menampilkan hasil clustering pada setiap jumlah klaster (klaster yang berbeda dalam ruang PC1 dan PC2). Selain itu juga menganalisis pembahasan visualisasi *clustering* (PC1 vs PC2) pada setiap (k). Gambar 6.1 merupakan visualisasi yang menampilkan semua hasil *clustering* dengan berbagai jumlah klaster (k) dari 2 hingga 10, bersama dengan *Silhouette Score* yang sesuai untuk setiap konfigurasi. Berikut adalah pembahasan untuk setiap nilai (k):

Menggunakan jumlah $k = 2$


Menghasilkan nilai *Silhouette Score* sebesar 0.5553. Terlihat pada Gambar 6.2 bahwa menggunakan nilai ($k=2$) data terbagi menjadi 2 klaster besar. Visualisasi menunjukkan bahwa klaster ini mencoba memisahkan 2 kelompok besar titik data yang terdistribusi pada 4 data yang terpisah dalam bentuk kumpulan data. Untuk klaster 0 mencakup 2 kelompok pada sisi kiri-bawah dan kanan-bawah, sementara klaster 1 mencakup 2 kelompok di sisi kiri-atas dan kanan-atas. Pemisahan ini kurang optimal karena masing-masing klaster masih menggabungkan 2 kelompok yang sebenarnya terpisah secara visual. *Silhouette Score* yang relatif menengah menunjukkan adanya beberapa tumpang tindih atau klaster yang kurang padat secara internal.



Gambar 6. 2 Visualisasi Clustering dengan nilai $k=2$

Menggunakan jumlah $k = 3$


Menghasilkan nilai *Silhouette Score* sebesar 0.7377. Terlihat pada Gambar 6.3 bahwa pada $k=3$, *Silhouette Score* meningkat signifikan. Visualisasi menunjukkan bahwa satu klaster (misalnya Klaster 0) berhasil mengisolasi salah satu kumpulan data pada bagian kanan atas. Sementara itu, 2 klaster lainnya yaitu klaster 1 dan klaster 2 masih membagi sisa 3 kumpulan data. Meskipun ada peningkatan, masih terlihat bahwa 2 atau lebih kelompok alami digabungkan dalam 1 klaster, yang mengindikasikan bahwa $k=3$ belum sepenuhnya menangkap struktur data yang sebenarnya.



Gambar 6. 3 Visualisasi Clustering dengan nilai $k=3$

Menggunakan jumlah $k = 4$


Menghasilkan nilai *Silhouette Score* sebesar 0.7983. Pada Gambar 6.4 terlihat bahwa $k=4$ menghasilkan nilai *Silhouette Score* tertinggi di antara semua k yang diuji. Visualisasi pada $k=4$ dengan jelas menunjukkan 4 klaster yang terpisah dengan baik, masing-masing sesuai dengan kumpulan data yang terlihat jelas di *scatter plot*. Setiap klaster bersifat padat (*densely packed*) dan terpisah dengan baik dari klaster lainnya, menunjukkan bahwa hasil dari PCA dapat mengclusterkan data dan berhasil mengidentifikasi empat kelompok alami dalam data. Nilai *Silhouette Score* yang tinggi tersebut mengkonfirmasi bahwa $k=4$ adalah jumlah klaster yang optimal untuk data ini, sesuai dengan karakteristik data sintetis yang dihasilkan (yaitu, 4 *true clusters*).



Gambar 6. 4 Visualisasi Clustering dengan nilai k=4

Menggunakan jumlah k = 5

Menghasilkan nilai *Silhouette Score* sebesar 0.6625. Pada gambar 6.5 terlihat bahwa setelah mencapai puncaknya pada k=4, *Silhouette Score* mulai menurun. Pada k=5, terlihat bahwa terdapat data baru yang berasal dari terbaginya salah satu klaster alami menjadi dua sub-klaster, atau mencoba membagi titik-titik di antara klaster yang sudah ada. Ini mengakibatkan klaster menjadi kurang kohesif atau memunculkan klaster yang tidak memiliki pemisahan yang jelas. Penurunan *Silhouette Score* menunjukkan bahwa penambahan klaster kelima memperkenalkan kompleksitas yang tidak perlu atau memecah klaster alami menjadi bagian yang kurang bermakna.




Gambar 6. 5 Visualisasi Clustering dengan nilai $k=5$



Menggunakan jumlah $k = 6$ sampai $k = 10$



Menghasilkan nilai *Silhouette Score* yang menurun mulai dari $k=6$ sekitar 0.5401, $k=7$ sekitar 0.4578, $k=8$ sekitar 0.4526, $k=9$ sekitar 0.3340, dan $k=10$ sekitar 0.3386. Sehingga untuk nilai k yang lebih besar (6 sampai 10), memiliki nilai *Silhouette Score* yang terus menurun secara signifikan. Terlihat pada Gambar 6.6 - 6.10 memvisualisasikan untuk kumpulan data pada setiap nilai k yang menunjukkan fragmentasi klaster yang semakin turun nilai *Silhouette Score*-nya. Semakin tinggi nilai k maka semakin sulit untuk mengidentifikasi kelompok-kelompok yang berbeda, mulai memecah klaster alami menjadi sub-klaster yang sangat kecil dan seringkali tumpang tindih. Ini adalah indikasi yang jelas dari *over-clustering*, di mana algoritma mencoba memaksakan lebih banyak klaster daripada yang secara alami ada

dalam data. Klaster yang terbentuk menjadi kurang padat, batas-batasnya kabur, dan pemisahan antar klaster menjadi buruk.




Gambar 6. 6 Visualisasi Clustering dengan nilai $k=6$


Gambar 6. 7 Visualisasi Clustering dengan nilai $k=7$ Gambar 6. 8 Visualisasi Clustering dengan nilai $k=8$

Gambar 6. 9 Visualisasi Clustering dengan nilai $k=9$ Gambar 6. 10 Visualisasi Clustering dengan nilai $k=10$

Pembentukan visualisasi menggunakan 2 PC yaitu PC1 dan PC2 merupakan hasil dari 2 nilai *eigenvalue* yang tertinggi pada setiap PC. Kemudian dengan menggunakan *boxplot* dapat memvisualisasikan 2 PC tersebut agar mengetahui distribusi statistik dari PC1 dan PC2 di dalam setiap kluster. Hasil visualisasi pada Gambar 5.11 dan 5.12 dapat membantu dalam memahami variabilitas dan perbedaan median serta rentang data untuk PC1 dan PC2 berdasarkan setiap kluster.



Gambar 6. 11 Distribusi PC1 per-kluster



Gambar 6. 12 Distribusi PC2 per-kluster


Jika berdasarkan statistik deskriptif dari PC1 dan PC2 menghasilkan klaster terbaik adalah pada saat $k=4$, sehingga dapat mengidentifikasi karakteristik unik dari masing-masing klaster:

- a. Klaster 0 memiliki nilai rata-rata PC1 sekitar 0.806. Rentang nilai PC1 mayoritas positif, menunjukkan klaster ini berada di sisi kanan sumbu PC1. Ini mengindikasikan karakteristik fitur tertentu yang dominan dalam klaster ini. Sedangkan untuk nilai rata-rata PC2 sekitar -0.540. Rentang nilai PC2 mayoritas negatif, menempatkan klaster ini di bagian bawah sumbu PC2. Sehingga klaster ini terletak pada kuadran kanan bawah dari plot PC1 vs PC2. Anggota klaster ini memiliki nilai PC1 yang relatif tinggi dan nilai PC2 yang relatif rendah, membentuk kelompok yang terpisah dengan jelas.
- b. Klaster 1 memiliki nilai rata-rata PC1 sekitar -1.551. Rentang nilai PC1 sangat negatif, menempatkan klaster ini jauh di sisi kiri sumbu PC1. Sedangkan nilai rata-rata PC2 sekitar 0.697. Rentang nilai PC2 mayoritas positif, menempatkan klaster ini di bagian atas sumbu PC2. Sehingga Karakteristik dari klaster ini terletak pada kuadran kiri atas dari plot PC1 vs PC2. Anggota klaster ini menunjukkan bahwa karakteristik fitur yang berbeda secara signifikan dari klaster 0, dengan nilai PC1 yang sangat rendah dan nilai PC2 yang tinggi.
- c. Klaster 2 memiliki nilai rata-rata PC1 sekitar 0.806. Rentang nilai PC1 mayoritas positif, serupa dengan Klaster 0. Memiliki nilai rata-rata PC2 sekitar 0.697. Rentang nilai PC2 mayoritas positif, serupa dengan Klaster 1. Sehingga karakteristik dari klaster ini terletak pada kuadran kanan atas dari

plot PC1 vs PC2. Meskipun memiliki nilai PC1 yang mirip dengan kluster 0, kluster 2 dibedakan oleh nilai PC2 yang lebih tinggi, menunjukkan perbedaan karakteristik fitur yang signifikan pada grafik 2 dimensi.

- d. Kluster 3 memiliki nilai rata-rata PC1 sekitar -1.551. Rentang nilai PC1 sangat negatif, serupa dengan kluster 1. Untuk nilai rata-rata PC2 sekitar -0.540. Rentang nilai PC2 mayoritas negatif, serupa dengan kluster 0. Kluster 3 memiliki Karakteristik yang terletak pada kuadran kiri bawah dari plot PC1 vs PC2. Meskipun memiliki nilai PC1 yang mirip dengan Kluster 1, Kluster 3 dibedakan oleh nilai PC2 yang lebih rendah, menunjukkan perbedaan karakteristik fitur di dimensi kedua.

Pada Gambar 6.13 merupakan bentuk visualisasi 2D dari statistik deskriptif dari PC1 dan PC2 dengan menggunakan $k=4$.



Gambar 6. 13 Distribusi Persebaran Data Pada 4 Kluster

Hasilnya menunjukkan bahwa sistem menghasilkan nilai *Silhouette Score* tertinggi untuk data PCA sebesar 0.7983 untuk $k = 4$. Dengan demikian, jumlah kluster optimal yang disarankan untuk data PCA adalah 4. Tetapi menurut standar tingkat kerusakan bangunan pascabencana alam pada penelitiannya, Almais et al. menjelaskan bahwa terdapat 3 kluster tingkat kerusakan bangunan pascabencana alam yang digunakan pemerintah (A. T. W. Almais, Susilo, Naba, Sarosa, Crysdian, Basid, et al., 2023; A. T. W. Almais, Susilo, Naba, Sarosa, Crysdian, et al., 2024; A. T. W. Almais, Susilo, Naba, Sarosa, Crysdian, Wicaksono, et al., 2023). Berdasarkan acuan tersebut, penelitian ini menggunakan 3 kluster yang cukup stabil dan memiliki nilai *Silhouette score* yang cukup tinggi, yaitu mencapai 0.9 pada kluster 0 dan 2, serta 0.75 pada kluster 1. Hal ini secara matematis membuktikan bahwa fitur visual yang diekstraksi oleh *EfficientNet-B7* memang terbagi secara alami ke dalam 3 kelompok utama yang kohesif dan terpisah secara jelas. Justifikasi ini menjadi dasar yang kuat untuk melanjutkan analisis pada koordinat PC1 guna menentukan tingkat kerusakan secara akurat. Terdapat beberapa pembahasan yang sangat menarik dibahas pada penelitian ini, antara lain:

1. Validasi hasil *clustering* dan *labeling*: Nilai koordinat PC1 yang lebih dari 2 (yaitu 5.000) menunjukkan bahwa tingkat kerusakan pada Gambar 4.2 adalah rusak berat. Hal tersebut memberi makna bahwa hasil ekstraksi fitur pada Gambar 4.2 memiliki karakteristik bangunan yang sudah hancur. Berdasarkan penelitiannya, Bachriwindi et al. menyatakan bahwa untuk mengetahui tingkat kerusakan bangunan pascabencana alam dapat menggunakan 5 kriteria, yaitu kondisi bangunan, struktur kondisi bangunan, kondisi fisik bangunan rusak,

fungsi bangunan, dan kondisi pendukung lainnya (Bachriwindi et al., 2019). Jadi, Gambar 4.2 memiliki informasi rusak berat karena hasil penilaian 5 kriteria tersebut memiliki nilai kerusakan maksimal (rusak berat).

2. Pendekatan yang Efektif: menerapkan teknik *PCA-Clustering* untuk menganalisis hasil ekstraksi fitur gambar kerusakan bangunan pascabencana alam sudah terbukti mampu menghasilkan hasil yang sesuai dengan informasi yang sebenarnya. Hal tersebut menunjukkan bahwa *PCA-Clustering* sudah cukup robust untuk menginterpretasikan karakteristik kerusakan bangunan pascabencana alam menggunakan data gambar (citra) dengan mengandalkan pola tekstur dan fitur yang unik pada setiap input data gambar (citra).
3. *Future Work*: pada Gambar 4.3 sudah muncul informasi tingkat kerusakan bangunan dengan menerapkan gabungan hasil ekstasi fitur dengan *EfficientNet-B7* dan *PCA-Clustering* tetapi masih perlu suatu validasi dari ahlinya yaitu pihak yang berkepentingan pada bidang pemulihan kerusakan bangunan pasca bencana alam yaitu BPBD (Badan Penanggulangan Bencana Daerah). 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 4.3 yang memberikan informasi rusak berat.

Integrasi antara AI dan survei manual menciptakan sinergi di mana teknologi berperan sebagai penyaring cepat (*rapid screening*) untuk area terdampak luas, sementara validasi ahli tetap diperlukan untuk mengonfirmasi detail struktural yang mungkin terlewat oleh analisis visual otomatis. Meskipun metode tradisional

sering memakan waktu, perannya sebagai standar otoritas final tetap penting, terutama untuk mendeteksi kerusakan internal yang mungkin tidak tertangkap sepenuhnya oleh citra luar. Oleh karena itu, penggunaan *EfficientNet-B7* dan *PCA-Clustering* dalam penelitian ini diposisikan sebagai alat dukung bagi BPBD untuk mempercepat proses identifikasi awal secara objektif dan meminimalkan bias manusia dalam penilaian di lapangan.

Hasil eksperimen menunjukkan bahwa integrasi *EfficientNet-B7* dengan *PCA-Clustering* memberikan kerangka kerja yang kuat dan otomatis untuk karakterisasi kerusakan bangunan pascabencana. Berbeda dengan pendekatan GLCM-PCA yang ada pada penelitian *Almais et al.* yang bergantung pada fitur tekstur buatan dan penyetelan parameter manual (misalnya, pemilihan jarak piksel dan sudut) (A. T. W. Almais, Susilo, Naba, Sarosa, Juwono, et al., 2024). Pada penelitian ini menghilangkan kebutuhan intervensi manusia dalam ekstraksi fitur sehingga mengurangi subjektivitas dan potensi bias dalam penilaian kerusakan.

Nilai PC1 sebesar 5.000 pada hasil *experiment* menggunakan gambar sampel dengan jelas menempatkan bangunan dalam klaster "rusak berat", konsisten dengan inspeksi visual dan kriteria kerusakan yang ada (A. T. W. Almais, Susilo, Naba, Sarosa, Crysdian, Wicaksono, et al., 2023). Hasil tersebut tidak hanya memvalidasi efektivitas ekstraksi fitur berbasis pembelajaran mendalam tetapi juga menunjukkan peningkatan yang signifikan berdasarkan penelitian sebelumnya yang menggunakan metode GLCM, yang seringkali memerlukan optimasi parameter yang hati-hati untuk mencapai daya diskriminatif yang sebanding. Pada penelitian Almais et al. menjelaskan bahwa kinerja GLCM sangat bervariasi

dengan jarak piksel (1 atau 0.5), sehingga memerlukan validasi empiris untuk menentukan pengaturan optimal (A. T. W. Almais, Susilo, Naba, Sarosa, Juwono, et al., 2024). Sebaliknya, menggunakan metode *EfficientNet-B7* secara otonom mempelajari fitur yang invarian dan representatif, membuat sistem lebih dapat general dengan menggunakan berbagai kondisi citra dan jenis bencana.

Selain itu, meskipun saluran GLCM-PCA lebih ringan secara komputasi, ketergantungannya pada pengaturan deskriptor tekstur sebelumnya membatasi kemampuannya untuk menangkap semantik struktural tingkat tinggi, seperti atap yang runtuh atau dinding penahan beban yang retak, yang secara intuitif jaringan dalam lebih mudah dalam menndapatkan hasil yang optimal. Penelitian ini dapat menjembatani kesenjangan semantik antara analisis tekstur tingkat rendah dan pemahaman struktural tingkat tinggi, sehingga dapat menawarkan penilaian kerusakan yang lebih holistik yang selaras dengan evaluasi ahli.

Penelitian ini sangat bermanfaat bagi stakeholder yang membutuhkan dan secara utuh dapat terintegrasi dengan konsep *hablum minallah*, *hablum minnas*, dan *hablum minallam* berdasarkan data teknis dari proses penelitian ini mengenai analisis kerusakan bangunan pasca bencana alam:

a) Hablum Minallah (Hubungan dengan Allah)

Dalam penelitian ini, *hablum minallah* diwujudkan melalui penggunaan akal untuk menyingkap kebenaran data secara objektif.

- Penggunaan metode *EfficientNet-B7* secara otonom untuk mempelajari fitur yang representatif mampu menghilangkan kebutuhan intervensi manusia

dalam ekstraksi fitur. Hal ini mengurangi subjektivitas dan potensi bias dalam penilaian kerusakan.

- Sesuai dengan QS. Ali 'Imran: 190-191, aktivitas pada penelitian ini adalah bentuk tafakkur (berpikir) terhadap tanda-tanda kekuasaan Allah.

إِنَّ فِي خَلْقِ السَّمَوَاتِ وَالْأَرْضِ وَاخْتِلَافِ اللَّيْلِ وَالنَّهَارِ لَآيَاتٍ لِأُولَى الْأَلْبَابِ الَّذِينَ يَذْكُرُونَ اللَّهَ قِيَامًا
وَقُعُودًا وَعَلَى جُنُوبِهِمْ وَيَتَفَكَّرُونَ فِي خَلْقِ السَّمَوَاتِ وَالْأَرْضِ رَبَّنَا مَا خَلَقْتَ هَذَا بَاطِلًا
سُبْحَانَكَ فَقِنَا عَذَابَ النَّارِ

Artinya: *“Sesungguhnya dalam penciptaan langit dan bumi serta pergantian malam dan siang terdapat tanda-tanda (kebesaran Allah) bagi orang yang berakal, (yaitu) orang-orang yang mengingat Allah sambil berdiri, duduk, atau dalam keadaan berbaring, dan memikirkan tentang penciptaan langit dan bumi (seraya berkata), “Ya Tuhan kami, tidaklah Engkau menciptakan semua ini sia-sia. Maha Suci Engkau. Lindungilah kami dari azab neraka.”*

Berdasarkan Tafsir Kemenag menjelaskan bahwa seorang ulul albab adalah mereka yang menggunakan akalnya untuk melakukan penelitian mendalam terhadap fenomena alam agar menyadari bahwa tidak ada ciptaan-Nya yang sia-sia (LPMQ, 2022). Dengan mencari objektivitas melalui teknologi, peneliti berupaya menghadirkan kejujuran ilmiah sebagai bentuk pengabdian kepada Sang Pencipta.

b) Hablum Minannas (Hubungan dengan Sesama Manusia)

Nilai ini tercermin dalam tujuan sosial penelitian untuk mempercepat bantuan dan pemulihan bagi masyarakat terdampak bencana.

- Penelitian ini memberikan informasi rusak berat yang divalidasi melalui nilai koordinat PC1. Hasil analisis ini dirancang untuk membantu BPBD (Badan Penanggulangan Bencana Daerah) sebagai identifikasi awal yang akurat dalam bidang pemulihan kerusakan bangunan. Kerangka kerja ini dianggap lebih kuat dan otomatis dibandingkan metode sebelumnya.
- Hal ini selaras dengan QS. Al-Ma'idah: 2 tentang perintah tolong-menolong dalam kebajikan.

يَا أَيُّهَا الَّذِينَ آمَنُوا لَا تَحِلُّوا شَعَائِرَ اللَّهِ وَلَا الشُّهُرَ الْحَرَامَ وَلَا الْهَدْيَ وَلَا الْقَلَائِدَ وَلَا أَمِينَ الْبَيْتِ
الْحَرَامَ يَبْتَغُونَ فَضْلًا مِّن رَّبِّهِمْ وَرِضْوَانًا وَإِذَا حَلَلْتُمْ فَاصْطَادُوا وَلَا يَجْرِمَنَّكُمْ شَنَا نُ قَوْمٍ أَن صَدَّقْتُمْ
عَنِ الْمَسْجِدِ الْحَرَامِ أَن تَعْتَدُوا وَتَعَاوَنُوا عَلَى الْبِرِّ وَالتَّقْوَىٰ وَلَا تَعَاوَنُوا عَلَى الْإِثْمِ وَالْعُدْوَانِ وَاتَّقُوا
اللَّهَ إِنَّ اللَّهَ شَدِيدُ الْعِقَابِ

Artinya: *“Wahai orang-orang yang beriman, janganlah kamu melanggar syiar-syiar (kesucian) Allah, jangan (melanggar kehormatan) bulan-bulan haram, jangan (mengganggu) hadyu (hewan-hewan kurban) dan qalā'id (hewan-hewan kurban yang diberi tanda), dan jangan (pula mengganggu) para pengunjung Baitulharam sedangkan mereka mencari karunia dan rida Tuhannya! Apabila kamu telah bertahalul (menyelesaikan ihram), berburulah (jika mau). Janganlah sekali-kali kebencian(-mu) kepada suatu kaum, karena mereka menghalang-halangi dari Masjidilharam, mendorongmu berbuat melampaui batas (kepada mereka). Tolong-menolonglah kamu dalam (mengerjakan) kebajikan dan takwa, dan jangan tolong-menolong*

dalam berbuat dosa dan permusuhan. Bertakwalah kepada Allah, sesungguhnya Allah sangat berat siksaan-Nya.”

Berdasarkan Tafsir Kemenag bahwa menekankan pentingnya membantu sesama dalam kebaikan yang membawa manfaat luas (LPMQ, 2022). Dengan menyediakan sistem otomatis yang mampu mengidentifikasi bangunan yang benar-benar sesuai dengan keadaan sesungguhnya dengan secara cepat, peneliti berkontribusi agar bantuan kemanusiaan tersalurkan secara adil dan tepat sasaran kepada mereka yang paling membutuhkan.

c) Hablum Minalam (Hubungan dengan Alam)

Integrasi ini berkaitan dengan tanggung jawab manusia dalam memahami dan memperbaiki kerusakan pada lingkungan binaan.

- Hasil dari penelitian ini mampu menjembatani kesenjangan semantik untuk memahami semantik struktural tingkat tinggi, seperti atap yang runtuh atau dinding penahan beban yang retak. Penilaian kerusakan dilakukan secara holistik berdasarkan kriteria kondisi fisik, struktur, hingga fungsi bangunan.
- Sesuai dengan QS. Ar-Rum: 41, bahwa kerusakan yang tampak di darat (termasuk pada pemukiman) adalah peringatan agar manusia kembali ke jalan yang benar.

ظَهَرَ الْفَسَادُ فِي الْبَرِّ وَالْبَحْرِ بِمَا كَسَبَتْ أَيْدِي النَّاسِ لِيُذِيقَهُمْ بَعْضَ الَّذِي عَمِلُوا لَعَلَّهُمْ يَرْجِعُونَ

Artinya: *“Telah tampak kerusakan di darat dan di laut disebabkan perbuatan tangan manusia. (Melalui hal itu) Allah membuat mereka merasakan sebagian dari (akibat) perbuatan mereka agar mereka kembali (ke jalan yang benar).”*

Berdasarkan Tafsir Kemenag menjelaskan bahwa manusia harus merasakan dampak kerusakan tersebut agar terdorong melakukan perbaikan (*ishlah*) (LPMQ, 2022). Melalui kemampuan teknologi dari hasil penelitian ini dalam menginterpretasikan pola kerusakan alam secara mendalam, manusia menjalankan fungsinya sebagai khalifah untuk memulihkan keseimbangan lingkungan hunian yang rusak pasca bencana.

BAB VI

PENUTUP

6.1 Kesimpulan

Mengetahui karakteristik tingkat kerusakan bangunan pascabencana alam merupakan suatu hal yang perlu adanya keobjektifan hasil yang sesuai dengan kenyataan yang ada. Pada penelitian ini, diterapkan integrasi AI untuk mengekstraksi fitur gambar menggunakan *EfficientNet-B7* dengan teknik *clustering* modern, yaitu *PCA-Clustering*, sehingga dapat menghasilkan suatu keterbaruan dalam membaca informasi pada suatu gambar. Dengan menggunakan data berupa gambar kerusakan bangunan pascabencana alam yang melalui proses ekstraksi fitur menggunakan *EfficientNet-B7* menghasilkan nilai fitur *text entropy*, *normalized standard*, *contrast*, *homogeneity*, dan *skewness*. Kemudian, hasil nilai fitur tersebut masuk ke proses *PCA-Clustering* untuk mengetahui informasi yang tersimpan pada hasil ekstraksi fitur tersebut, yaitu tingkat kerusakan bangunan, dengan cara mengklaster hasil reduksi PCA dengan menggunakan bentuk visualisasi grafik 2 dimensi (2D). Proses ekstraksi fitur gambar menggunakan *EfficientNet-B7* merupakan penerapan salah satu jenis teknik AI yang masuk ke dalam kelompok CNN, tetapi pada penelitian ini diterapkan *EfficientNet-B7* untuk mengekstraksi fitur gambar, tidak untuk membuat data *training*. Hasil ekstraksi fitur tersebut kemudian masuk proses *PCA-Clustering* untuk mengetahui informasi tingkat kerusakan bangunannya menggunakan standar yang sudah ada. Pada penelitian ini, hasil nilai PC1 dari proses ekstraksi fitur menggunakan *EfficientNet-*

B7 dan PCA-*Clustering* yaitu 5.000. Berdasarkan standard yang sudah ada jika nilai PC1 lebih besar sama dengan 2 ($PC1 \geq 2$) maka termasuk dalam *cluster* dan *labeling* tingkat kerusakan bangunannya adalah rusak berat. Hasil tersebut juga sudah tervalidasi berdasarkan riset sebelumnya yang menyatakan bahwa bangunan pasca bencana alam rusak berat jika semua kriteria bangunan mengalami kerusakan yang maksimal.

Berdasarkan *experiment* pada penelitian ini memberi hasil yang konsisten (*robust*) dengan mengintegrasikan *EfficientNet-B7* dan PCA-*Clustering* untuk menentukan tingkat kerusakan bangunan pasca bencana alam. Kemampuan hasil analisis PCA-*Clustering* dalam membaca hasil ekstraksi fitur dari *EfficientNet-B7* memberikan *labeling* tingkat kerusakan bangunan pascabencana alam yang masuk akal dan interpretasi yang detail sehingga dapat sangat berguna untuk evaluasi cepat pada lapangan atau kondisi darurat. Tetapi perlu adanya validasi dari ahli struktur bangunan agar dapat memperkuat keberlanjutan dalam penelitian ini dan bisa bermanfaat bagi *stakeholder* yang membutuhkan. Selain itu, penelitian ini bukan sekadar inovasi teknologi mengintegrasikan *EfficientNet-B7* dan PCA-*Clustering*, melainkan sebuah alat yang mendukung nilai-nilai spiritual (objektivitas/syukur), sosial (bantuan tepat sasaran), dan lingkungan (pemulihan struktur alam) demi kemaslahatan bersama.

6.2 Saran

Meskipun pada Gambar 4.2 sudah muncul informasi tingkat kerusakan bangunannya dengan menerapkan gabungan hasil ekstraksi fitur *EfficientNet-B7* dan

PCA-Clustering, masih perlu inspeksi atau validasi dari ahli struktur bangunan atau insinyur teknik sipil yang dapat menjadi salah satu bentuk validasi dari hasil temuan penelitian ini. Selain itu, dapat menjadi identifikasi awal pada setiap kerusakan bangunan pascabencana alam yang mungkin terlewat oleh analisis otomatis yang ada pada penelitian ini.

Secara keseluruhan, penelitian ini memberikan hasil analisis awal yang positif pada Gambar 4.2 yang memberikan informasi kerusakan berat, namun perlu adanya validasi lebih lanjut dari ahli struktur bangunan dan tindakan pemeliharaan bangunan yang sesuai dengan tingkat kerusakannya. Untuk memperkuat implementasi di dunia nyata, disarankan agar hasil deteksi otomatis ini tetap diikuti dengan inspeksi manual lanjutan oleh ahli struktur bangunan atau insinyur teknik sipil. Sinkronisasi berkelanjutan dengan pihak otoritas seperti BPBD sangat diperlukan agar sistem ini dapat terintegrasi ke dalam prosedur standar operasi pemulihan bencana, sehingga bantuan kemanusiaan dapat tersalurkan secara lebih adil, tepat sasaran, dan akuntabel.

DAFTAR PUSTAKA

- Abdalzaher, M. S., Elsayed, H. A., Fouda, M. M., & Salim, M. M. (2023). Employing Machine Learning and IoT for Earthquake Early Warning System in Smart Cities. *Energies*, 16(1), 495. <https://doi.org/10.3390/en16010495>
- Adhikari, R. K., D'Ayala, D., Fernandez, R., Yamin, L., Nassirpour, A., Vatterli, A. P., Ferreira, C., & Cortes, F. (2023). GLOSI taxonomy: A tool for 'seismic risk assessment' oriented classification of school buildings. *International Journal of Disaster Risk Reduction*, 87, 103594. <https://doi.org/10.1016/j.ijdr.2023.103594>
- Almais, A. T., Fatchurrohman, F., & Holle, K. F. H. (2020). Implementasi fuzzy weighted product penyusunan aksi rehabilitasi rekonstruksi pasca bencana berbasis decision support system dynamic. *JURNAL ELTEK*, 18(1), 1. <https://doi.org/10.33795/eltek.v18i1.171>
- Almais, A. T. W., Fatchurrohman, ., Holle, K. F. H., Kinasih, K. S., Wiranti, D. A., & Yasin, S. Y. (2019). Implementation Fuzzy Weighted Product Preparation Post Disaster Reconstruction and Rehabilitation Action based Dynamics Decision Support System. *Proceedings of the International Conferences on Information System and Technology*, 272–277. <https://doi.org/10.5220/0009909002720277>
- Almais, A. T. W., Sarosa, M., & Muslim, M. A. (2016). Implementation Of Multi Experts Multi Criteria Decision Making For Rehabilitation And Reconstruction Action After A Disaster. *MATICS*, 8(1), 27. <https://doi.org/10.18860/mat.v8i1.3480>
- Almais, A. T. W., Susilo, A., Naba, A., Sarosa, M., Crysdian, C., Basid, P. M. N. S. A., Hariyadi, M. A., Tazi, I., Arif, Y. M., & Wicaksono, H. (2023). SASSD: A Smart Assessment System For Sector Damage Post-Natural Disaster Using Artificial Neural Networks. *2023 2nd International Conference on Computer System, Information Technology, and Electrical Engineering (COSITE)*, 96–101. <https://doi.org/10.1109/COSITE60233.2023.10249540>

- Almais, A. T. W., Susilo, A., Naba, A., Sarosa, M., Crysdian, C., Wicaksono, H., Arif, Y. M., Basid, P. M. N. S. A., & Tazi, I. (2024). SDDS: Damage Level Determination System for Post-Natural Disaster Sector Based on Building Characteristics. In *The 18th IMT-GT International Conference on Mathematics, Statistics and their Applications* (pp. 23–28). Sciendo. <https://doi.org/10.2478/9788367405713-005>
- Almais, A. T. W., Susilo, A., Naba, A., Sarosa, M., Crysdian, C., Wicaksono, H., Tazi, I., Hariyadi, M. A., Muslim, M. A., Basid, P. M. N. S. A., Arif, Y. M., Purwanto, M. S., Parwatiningtyas, D., & Supriyono. (2023). Principal Component Analysis-Based Data Clustering for Labeling of Level Damage Sector in Post-Natural Disasters. *IEEE Access*, 1. <https://doi.org/10.1109/ACCESS.2023.3275852>
- Almais, A. T. W., Susilo, A., Naba, A., Sarosa, M., Juwono, A. M., Crysdian, C., Muslim, M. A., & Wicaksono, H. (2024). Characterization of Structural Building Damage in Post-Disaster using GLCM-PCA Analysis Integration. *IEEE Access*, 1–1. <https://doi.org/10.1109/ACCESS.2024.3469637>
- Amani, H., Almais, A. T. W., Abidin, Z., Nugroho, F., Kurniawan, F., & Sugiharto, T. I. (2025). A hybrid GoogLeNet–GLCM feature extraction framework for textural representation of post-disaster building damage imagery. *Jurnal Ilmiah Teknologi Informasi Asia*, 20(1), 16–23. <https://doi.org/10.32815/jitika.v20i1.1214>
- Bachriwindi, A., Putra, E. K., Munawaroh, U. M., & Almais, A. T. W. (2019). Implementation of Web-Based Weighted Product Use Decision Support System to Determine the Post-Disaster Damage and Loss. *Journal of Physics: Conference Series*, 1413(1), 12019. <https://doi.org/10.1088/1742-6596/1413/1/012019>
- Chander, S., & Vijaya, P. (2021). Unsupervised learning methods for data clustering. In *Artificial Intelligence in Data Mining* (pp. 41–64). Elsevier. <https://doi.org/10.1016/B978-0-12-820601-0.00002-1>

- Chowdhury, Md. A. M. J. A. S. Md. N. I. Md. F. H. K. (2023). *Automated Parkinson 's Disease Diagnosis from Brain MRI Images Using Deep Convolutional Neural Network*. <https://doi.org/10.1109/ICCIT60459.2023.10441102>
- Deng, L., & Wang, Y. (2022). Post-disaster building damage assessment based on improved U-Net. *Scientific Reports*, 12(1), 15862. <https://doi.org/10.1038/s41598-022-20114-w>
- Fahad, A., Alshatri, N., Tari, Z., Alamri, A., Khalil, I., Zomaya, A. Y., Foufou, S., & Bouras, A. (2014). A Survey of Clustering Algorithms for Big Data: Taxonomy and Empirical Analysis. *IEEE Transactions on Emerging Topics in Computing*, 2(3), 267–279. <https://doi.org/10.1109/TETC.2014.2330519>
- Fariza, A., Abhimata, N. P., & Hasim, J. A. N. (2016). Earthquake disaster risk map in east Java, Indonesia, using analytical hierarchy process — Natural break classification. *2016 International Conference on Knowledge Creation and Intelligent Computing (KCIC)*, 141–147. <https://doi.org/10.1109/KCIC.2016.7883638>
- Fatichah, C. (2021). Membangun Model. In *Data Scientist: Artificial Intelligence untuk Dosen dan Instruktur*.
- Gonçalves, C. B., Souza, J. R., & Fernandes, H. (2022). CNN architecture optimization using bio-inspired algorithms for breast cancer detection in infrared images. *Computers in Biology and Medicine*, 142, 105205. <https://doi.org/10.1016/j.combiomed.2021.105205>
- Gupta, A., Watson, S., & Yin, H. (2021). Deep learning-based aerial image segmentation with open data for disaster impact assessment. *Neurocomputing*, 439, 22–33. <https://doi.org/10.1016/j.neucom.2020.02.139>
- Han, D., Liu, Q., & Fan, W. (2018). A new image classification method using CNN transfer learning and web data augmentation. *Expert Systems with Applications*, 95, 43–56. <https://doi.org/10.1016/j.eswa.2017.11.028>

- Hendria, W. F., Phan, Q. T., Adzaka, F., & Jeong, C. (2021). Combining transformer and CNN for object detection in UAV imagery. *ICT Express*. <https://doi.org/10.1016/j.ict.2021.12.006>
- I.T.Jolliffe. (2002). *Principal Component Analysis*. Springer-Verlag. <https://doi.org/10.1007/b98835>
- Kapoor, A., & Singhal, A. (2017). A comparative study of K-Means, K-Means++ and Fuzzy C-Means clustering algorithms. *2017 3rd International Conference on Computational Intelligence & Communication Technology (CICT)*, 1–6. <https://doi.org/10.1109/CICT.2017.7977272>
- Kumar, S., & Kumar, D. (2023). Human brain tumor classification and segmentation using CNN. *Multimedia Tools and Applications*, 82(5), 7599–7620. <https://doi.org/10.1007/s11042-022-13713-2>
- Limmatus Sauda. (n.d.). *Merenungi Tiga Macam Kondisi Manusia*. Tafsirquran.Id.
- LPMQ. (2022). *Quran Kemenag*. <https://Quran.Kemenag.Go.Id/>.
- Moustafa, S. S. R., Abdalzaher, M. S., & Abdelhafiez, H. E. (2022). Seismo-Lineaments in Egypt: Analysis and Implications for Active Tectonic Structures and Earthquake Magnitudes. *Remote Sensing*, 14(23), 6151. <https://doi.org/10.3390/rs14236151>
- Nguyen, V. Q., Nguyen, V. H., Cao, V. L., Khac, N.-A. Le, & Shone, N. (2021). A Robust PCA Feature Selection To Assist Deep Clustering Autoencoder-Based Network Anomaly Detection. *2021 8th NAFOSTED Conference on Information and Computer Science (NICS)*, 335–341. <https://doi.org/10.1109/NICS54270.2021.9701456>
- Nugroho, A., Fajri, Iqbal, R. M., Fadhiela, K., Apriyani, D., Ginting, L. N., & Nurdin, S. (2022). Impacts of village fund on post disaster economic recovery in rural Aceh Indonesia. *International Journal of Disaster Risk Reduction*, 70, 102768. <https://doi.org/10.1016/j.ijdrr.2021.102768>

- Piernik, M., & Morzy, T. (2021). A study on using data clustering for feature extraction to improve the quality of classification. *Knowledge and Information Systems*, 63(7), 1771–1805. <https://doi.org/10.1007/s10115-021-01572-6>
- Punhani, A., Faujdar, N., Mishra, K. K., & Subramanian, M. (2022). Binning-Based Silhouette Approach to Find the Optimal Cluster Using K-Means. *IEEE Access*, 10, 115025–115032. <https://doi.org/10.1109/ACCESS.2022.3215568>
- Riza, H., Santoso, E. W., Tejakusuma, I. G., & Prawiradisastra, F. (2020). Advancing Flood Disaster Mitigation in Indonesia Using Machine Learning Methods. *2020 International Conference on ICT for Smart Society (ICISS)*, 1–4. <https://doi.org/10.1109/ICISS50791.2020.9307561>
- Safitri, A. H., Almais, A. T. W., Syauqi, A., & Melani, R. I. (2022). Testing Optimization and Non-Optimization Query Topsis Methods to Determine Damage Level in Natural Disaster Sector. *Jurnal ELTIKOM*, 6(1), 89–99. <https://doi.org/10.31961/eltikom.v6i1.532>
- Sander, J., Ester, M., Kriegel, H.-P., & Xu, X. (1998). Density-Based Clustering in Spatial Databases: The Algorithm GDBSCAN and Its Applications. *Data Mining and Knowledge Discovery*, 2(2), 169–194. <https://doi.org/10.1023/A:1009745219419>
- Shukla, R., Kumar, V., Yadav, V., & Rahul, M. (2021). Input Data Characterization Using Machine Learning and Deep Learning. *IOP Conference Series: Materials Science and Engineering*, 1022(1), 012012. <https://doi.org/10.1088/1757-899X/1022/1/012012>
- Supendi, P., Nugraha, A. D., Widiyantoro, S., Pesicek, J. D., Thurber, C. H., Abdullah, C. I., Daryono, D., Wiyono, S. H., Shiddiqi, H. A., & Rosalia, S. (2020). Relocated aftershocks and background seismicity in eastern Indonesia shed light on the 2018 Lombok and Palu earthquake sequences. *Geophysical Journal International*, 221(3), 1845–1855. <https://doi.org/10.1093/gji/ggaa118>

- Tan, M., & Le, Q. V. (2019). *EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks*. <http://arxiv.org/abs/1905.11946>
- Tang, J., Yang, S., Huang, S., & Xiao, B. (2024). Remote Sensing Building Damage Assessment Based on Machine Learning. *International Journal of Advanced Network, Monitoring and Controls*, 9(3), 1–12. <https://doi.org/10.2478/ijanmc-2024-0021>
- Tantri, A. H., & Rakhmawati, N. A. (2019). Designing A Natural Disaster Ontology for Indonesia. *2019 12th International Conference on Information & Communication Technology and System (ICTS)*, 130–134. <https://doi.org/10.1109/ICTS.2019.8850979>
- Ul Amin, S., Sibtain Abbas, M., Kim, B., Jung, Y., & Seo, S. (2024). Enhanced Anomaly Detection in Pandemic Surveillance Videos: An Attention Approach With EfficientNet-B0 and CBAM Integration. *IEEE Access*, 12, 162697–162712. <https://doi.org/10.1109/ACCESS.2024.3488797>
- Wagner, F., Eltner, A., & Maas, H.-G. (2023). 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*, 119, 103305. <https://doi.org/10.1016/j.jag.2023.103305>
- You, D., Wang, S., Wang, F., Zhou, Y., Wang, Z., Wang, J., & Xiong, Y. (2022). EfficientUNet+: A Building Extraction Method for Emergency Shelters Based on Deep Learning. *Remote Sensing*, 14(9), 2207. <https://doi.org/10.3390/rs14092207>
- Zheng, Z., Zhong, Y., Wang, J., Ma, A., & Zhang, L. (2021). Building damage assessment for rapid disaster response with a deep object-based semantic change detection framework: From natural disasters to man-made disasters. *Remote Sensing of Environment*, 265, 112636. <https://doi.org/10.1016/j.rse.2021.112636>