

**ANALISIS DATA MENGGUNAKAN METODE *VGG-11 Net* UNTUK
EKSTRAKSI FITUR TINGKAT KERUSAKAN
BANGUNAN PASCA BENCANA ALAM**

SKRIPSI

Oleh :
ACHMAD RAKA MUFTI LASON
NIM. 210605110175



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

**ANALISIS DATA MENGGUNAKAN METODE VGG-11 NET UNTUK
EKSTRAKSI FITUR TINGKAT KERUSAKAN BANGUNAN PASCA
BENCANA ALAM**

SKRIPSI

Diajukan kepada:

Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)

Oleh:

ACHMAD RAKAMUFTI LASON
NIM. 210605110175

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

HALAMAN PERSETUJUAN

**ANALISIS DATA MENGGUNAKAN METODE VGG-11 NET UNTUK
EKSTRAKSI FITUR TINGKAT KERUSAKAN BANGUNAN PASCA
BENCANA ALAM**

SKRIPSI

Oleh :
ACHMAD RAKA MUFTI LASON
NIM. 210605110175

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 5 Juni 2025

Pembimbing I,



Dr. Agung Teguh Wibowo Almais, M.T
NIP. 19860301 202321 1 016

Pembimbing II,



Fajar Rohman Hariri, M.Kom
NIP. 19890515 201801 1 001

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



Dr. H. Fachrul Kurniawan, M.MT., IPU
NIP. 19771020 200912 1 001

HALAMAN PENGESAHAN

ANALISIS DATA MENGGUNAKAN METODE VGG-11 NET UNTUK
EKSTRAKSI FITUR TINGKAT KERUSAKAN BANGUNAN PASCA
BENCANA ALAM

SKRIPSI

Oleh :
ACHMAD RAKA MUFTI LASON
NIM. 210605110175

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 20 Juni 2025

Susunan Dewan Penguji

Ketua Penguji	: <u>Dr. Totok Chamidy, M.Kom</u> NIP. 19691222 200604 1 001	()
Anggota Penguji I	: <u>Ashri Shabrina Afrah, M.T</u> NIP. 19900430 202012 2 003	()
Anggota Penguji II	: <u>Dr. Agung Teguh Wibowo Almais, M.T</u> NIP. 19860301 202321 1 016	()
Anggota Penguji III	: <u>Fajar Rohman Hariri, M.Kom</u> NIP. 19890515 201801 1 001	()

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




Dr. Fachrul Kurniawan, M.MT., IPU
NIP. 19771020 200912 1 001

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Achmad Raka Mufti Lason
NIM : 210605110175
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Analisis Data Menggunakan Metode *VGG-11 Net*
untuk Ekstraksi Fitur Tingkat Kerusakan
Bangunan Pasca Bencana Alam

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan 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 skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 13 Juni 2025
Yang membuat pernyataan,



Achmad Raka Mufti Lason
NIM. 21060510175

MOTTO

“Usaha memang penting, tapi doa lebih penting”

HALAMAN PERSEMBAHAN

Alhamdulillah, Segala puji bagi Allah SWT yang telah memberikan limpahan rahmat dan hidayah kepada hamba-Nya, sehingga saya bisa menyelesaikan karya ini. Shalawat dan salam selalu tercurahkan kepada Nabi Muhammad SAW.

Skripsi ini saya persembahkan kepada :

Keluarga kecil penulis

Ayah dan Bunda tercinta, Bapak Romi dan Bunda Diny yang selalu memberikan doa , dukungan dan kasih sayang yang tak pernah henti kepada penulis. Serta adik penulis yang tercinta, Ifitahurrizki Kamelia

. Teman – teman seperjuangan

Seluruh mahasiswa Teknik Informatika khususnya untuk angkatan 2021 ”ASTER”, terima kasih atas dukungan, ilmu yang dibagikan, dan pengalaman

Yang berarti bagi penulis,

Diri sendiri,

Terima kasih karena sudah mau berjuang dan bertahan hingga saat ini.

KATA PENGANTAR

Assalamualaikum Warahmatullahi Wabarakatuh

Dengan Menyebut Nama Allah yang Maha Pengasih lagi Maha Penyayang, segala puji bagi Allah Tuhan Semesta Alam. Atas segala rahmat dan karunia-Nya sehingga penulis mampu menyelesaikan skripsi dengan judul "Analisis Data Menggunakan Metode VGG-11 Net untuk Ekstraksi Fitur Tingkat Kerusakan Bangunan Pasca Bencana Alam". Sholawat serta salam semoga selalu tercurah limpahkan kepada Nabi Muhammad SAW yang telah membimbing umatnya dari zaman jahiliyah menuju zaman islamiyah yakni addinul islam, semoga kita mendapatkan syafaatnya di hari kiamat nanti, Aamiin.

Dalam penulisan skripsi ini, tak lepas dari peran dan dukungan kepada banyak pihak yang tak ternilai. Oleh karena itu, penulia ingin menyampaikan terima kasih kepada :

1. Prof. Dr. H. M. Zainuddin, M.A., selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Prof. Dr. Sri Harini, M.Si., selaku dekan Fakultas Sains dan Teknologi.
3. Dr. Ir. Fachrul Kurniawan, M.MT., IPU selaku Ketua Program Studi Teknik Informatika.
4. Dr. Agung Teguh Wibowo Almais, M.T selaku Dosen Pembimbing I yang telah memberikan arahan, bimbingan selama penulisan skripsi sehingga penulis dapat menyelesaikan skripsi dengan baik dan tepat waktu

5. Fajar Rohman Hariri, M.Kom selaku Dosen Pembimbing II yang telah membimbing dan memberikan arahan serta masukan kepada penulis sehingga penulis dapat menyelesaikan skripsi ini.
6. Dr. Totok Chamidy, M.Kom selaku Penguji I dan Ashri Shabrina Arfah, MT selaku Penguji II yang telah memberikan saran dan kritik selama proses pengujian skripsi ini.
7. Segenap dosen, laboran, dan jajaran staff Program Studi Teknik Informatika yang telah memberikan ilmu, pengetahuan, dan dukungan selama penulis menjalani studi hingga selesainya skripsi ini
8. Keluarga kecil penulis, Ayah dan Bunda tercinta, Ayah Romi dan Bunda Diny, yang selalu memberikan doa, dukungan, serta kasih sayang yang tak pernah henti kepada penulis. Terima kasih atas segala pengorbanan, kesabaran, dan cinta yang tak terhingga, yang selalu memberi semangat bagi penulis untuk terus maju dan berkarya. Tak lupa, terima kasih juga kepada adikku tercinta, Iftitahurrizki Kamelia, atas segala dukungan, kebersamaan, dan cinta yang selalu menyertai penulis dalam setiap langkah perjalanan ini. Semoga Allah SWT senantiasa melimpahkan berkah-Nya kepada keluarga yang telah memberikan segala bentuk dukungan yang tak ternilai harganya.
9. Saudara dan Teman dekat penulis Daffa, Nadhif, Raya, Ega, Zarnawi, Ricky, Hafidz, Naufal, Ijang, Angga, Dino, Patah, Dhendi, Ali, Asyraf Hannan yang selalu bersama penulis mulai awal perkuliahan hingga penyusunan skripsi ini. Terima Kasih sudah selalu ada, memberi semangat,

dukungan, dan motivasi yang sudah diberikan selama ini, terima kasih sudah hadir di kehidupan penulis.

10. Teman seimbang, Najah, Charles, Roihan, Gigih, Intan, Aulia, Al Ikhlas, Iqlima, Izza, Annisa, Salsa terima kasih atas segala bantuan yang diberikan. Terima Kasih sudah selalu ada, memberi semangat, dukungan, dan motivasi yang sudah diberikan selama ini.
11. Seluruh warga besar Teknik Informatika UIN Malang, khususnya angkatan 2021 "ASTER" yang telah memberikan dukungan dan bantuan kepada penulis.
12. Seluruh pihak yang telah terlibat, baik secara langsung maupun tidak langsung dari awal perkuliahan hingga akhir penulisan skripsi ini.
13. Diri sendiri, Achmad Raka Mufti Lason, terima kasih sudah berjuang sejauh ini. Terima kasih sudah berusaha semaksimal mungkin semoga segala harapan yang diimpikan bisa menjadi sebuah kenyataan.

Akhir kata, penulis menyadari bahwa skripsi ini masih memiliki kekurangan, baik dalam aspek keilmuan maupun penulisan. Oleh karena itu, penulis dengan senang hati menerima kritik dan saran yang membangun. Harapannya, skripsi ini dapat memberikan manfaat bagi berbagai pihak.

Malang, 4 Juni 2025

Penulis

DAFTAR ISI

HALAMAN PENGAJUAN	ii
HALAMAN PERSETUJUAN	Error! Bookmark not defined.
HALAMAN PENGESAHAN	Error! Bookmark not defined.
PERNYATAAN KEASLIAN TULISAN	Error! Bookmark not defined.
MOTTO	i
HALAMAN PERSEMBAHAN	ii
KATA PENGANTAR	iii
DAFTAR ISI	vi
DAFTAR GAMBAR	viii
DAFTAR TABEL	ix
ABSTRAK	x
ABSTRACT	xi
المخلص	xii
BAB I PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah	3
1.3 Batasan Masalah	3
1.4 Tujuan Penelitian.....	4
1.5 Manfaat Penelitian.....	4
BAB II STUDI PUSTAKA	6
2.1 Penelitian Terkait.....	6
2.2 Kajian Teoritis	12
2.2.1 Pengolahan Citra	12
2.2.2 <i>Image Preprocessing</i>	13
2.2.3 <i>Convolutional Neural networks</i>	15
2.2.4 <i>Transfer Learning</i>	16
2.2.5 <i>VGG-11 Net</i>	17
2.2.6 Ekstraksi Fitur	18
BAB III METODE PENELITIAN	20
3.1 Desain Sistem	20
3.1.1 Pengumpulan Data.....	20
3.1.2 <i>Image Preprocessing</i>	21
3.1.3 <i>Feature Extraction</i> menggunakan <i>VGG-11 Net</i>	23
3.1.4 <i>Feature Storage</i>	31
3.1.6 <i>Feature Analysis</i>	32
3.2 <i>Data Preparation</i>	32
3.3 <i>Feature Analysis/Feature Evaluation</i>	32
3.3.1 <i>Principal Component Analysis (PCA)</i>	33
3.3.2 Proses Evaluasi	34
BAB IV UJI DAN PEMBAHASAN	35
4.1 Data Pengujian.....	35
4.2 Skenario Pengujian	36
4.3 Hasil Uji Coba	38

4.4 Pembahasan	39
4.5 Integrasi Islam	42
BAB V KESIMPULAN DAN SARAN	45
5.1 Kesimpulan.....	45
5.2 Saran	45
DAFTAR PUSTAKA	
LAMPIRAN-LAMPIRAN	

DAFTAR GAMBAR

Gambar 3.1 Desain Sistem.....	20
Gambar 3.2 Data Gambar Kerusakan Bangunan	21
Gambar 3.3 Arsitektur <i>VGG-11 Net</i>	23
Gambar 4.1 Hasil <i>Eigenvalues</i> dan <i>Explained PCA</i>	38

DAFTAR TABEL

Tabel 2.1 Penelitian Terkait	10
Tabel 3.1 Hasil Conv1	24
Tabel 3.2 Hasil ReLU1	25
Tabel 3.3 Hasil Max Pooling1.....	25
Tabel 3.4 Hasil Conv2	25
Tabel 3.5 Hasil ReLU2	26
Tabel 3.6 Hasil Max Pooling2.....	26
Tabel 3.7 Hasil Conv3	26
Tabel 3.8 Hasil ReLU3	27
Tabel 3.9 Hasil Conv4	27
Tabel 3.10 Hasil ReLU4.....	27
Tabel 3.11 Hasil Max Pooling4.....	28
Tabel 3.12 Hasil Conv5.....	28
Tabel 3.13 Hasil ReLU5.....	28
Tabel 3.14 Hasil Conv6.....	29
Tabel 3.15 Hasil ReLU6.....	29
Tabel 3.16 Hasil Max Pooling6.....	29
Tabel 3.17 Hasil Conv7.....	29
Tabel 3.18 Hasil Conv8.....	30
Tabel 3.19 Hasil ReLU8.....	30
Tabel 3.20 Hasil ReLU8.....	30
Tabel 3.21 Hasil Max Pooling8.....	31
Tabel 4.1 Hasil 1 Sample Ekstraksi Fitur	36
Tabel 4.2 Skenario dan Komponen.....	37
Tabel 4.3 Hasil PCA	38
Tabel 4.4 Hasil Scatter Plot PCA.....	40

ABSTRAK

Lason, Achmad Raka Mufti. 2025. **Analisis Data Menggunakan Metode VGG-11 Net untuk Ekstraksi Fitur Tingkat Kerusakan Bangunan Pasca Bencana Alam.** Skripsi. Program Studi Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Dr. Agung Teguh Wibowo Almais, M.T (II) Fajar Rohman Hariri, M.Kom

Kata Kunci: *Virtual Geometry Group* (VGG), Ekstraksi Fitur, Bangunan Rusak, Bencana Alam.

Penelitian ini bertujuan untuk menganalisis data visual berupa citra bangunan pasca bencana alam menggunakan metode ekstraksi fitur berbasis *deep learning*, yaitu arsitektur *VGG-11 Net*. Citra bangunan diproses melalui tahapan *preprocessing*, termasuk *resizing*, normalisasi, dan augmentasi, sebelum diekstraksi fiturnya oleh model *VGG-11*. Hasil ekstraksi fitur kemudian dianalisis menggunakan metode *Principal Component Analysis* (PCA) untuk mereduksi dimensi dan memvisualisasikan distribusi data. Evaluasi dilakukan tanpa proses klasifikasi eksplisit, tetapi melalui analisis pola hasil proyeksi PCA yang menunjukkan terbentuknya tiga kelompok visual utama. Hal ini mengindikasikan bahwa fitur yang diekstraksi memiliki kemampuan untuk membedakan karakteristik visual tingkat kerusakan. Penelitian ini menunjukkan bahwa metode *VGG-11 Net* efektif digunakan sebagai pendekatan awal dalam memahami distribusi visual kerusakan bangunan, serta membuka peluang pengembangan lebih lanjut dalam sistem evaluasi otomatis berbasis citra.

ABSTRACT

Lason, Achmad Raka Mufti. 2025. **Data Analysis Using VGG-11 Net Method for Feature Extraction of Building Damage Level after Natural Disaster**. Thesis. Informatics Engineering Study Program, Faculty of Science and Technology, Maulana Malik Ibrahim State Islamic University Malang. Advisor: (I) Dr. Agung Teguh Wibowo Almais, M.T (II) Fajar Rohman Hariri, M.Kom

This research aims to analyze visual data in the form of post-natural disaster building images using a deep learning-based feature extraction method, namely the VGG-11 Net architecture. Building images are processed through preprocessing stages, including resizing, normalization, and augmentation, before their features are extracted by the VGG-11 model. The feature extraction results were then analyzed using the Principal Component Analysis (PCA) method to reduce dimensionality and visualize data distribution. The evaluation was done without an explicit classification process, but through analyzing the pattern of the PCA projection results, which showed the formation of three main visual groups. This indicates that the extracted features have the ability to distinguish the visual characteristics of the damage level. This research shows that the VGG-11 Net method is effective as an initial approach in understanding the visual distribution of building damage, and opens up opportunities for further development in image-based automated evaluation systems.

Keywords: *Virtual Geometry Group (VGG)*, Feature Extraction, Damaged Building, Natural Disaster.

الملخص

لاسون، أحمد رাকা مفتي. 2025. تحليل البيانات باستخدام طريقة شبكة VGG-11 الصافية لاستخراج خصائص مستوى الأضرار التي لحقت بالمباني بعد الكوارث الطبيعية. الأطروحة. برنامج دراسة الهندسة المعلوماتية، كلية العلوم والتكنولوجيا، الجامعة الإسلامية الحكومية، مولانا مالك إبراهيم مالانج. المشرف: (الأول) د. أغونغ تيغوه ويوو أليس، م. ت. (الثاني) فجر رحمان حريري، م. كوم.

الكلمات المفتاحية: مجموعة الهندسة الافتراضية (VGG) ، استخراج الخصائص، مبنى متضرر، كارثة طبيعية.

يهدف هذا البحث إلى تحليل البيانات المرئية في شكل صور مباني بعد الكوارث الطبيعية باستخدام طريقة استخراج السمات القائمة على التعلّم العميق، وهي بنية شبكة VGG-11. تتم معالجة صور المباني من خلال مراحل المعالجة المسبقة، بما في ذلك تغيير الحجم والتطبيع والتكبير، قبل أن يتم استخراج السمات بواسطة نموذج VGG-11. ثم تم تحليل نتائج استخراج السمات باستخدام طريقة تحليل المكونات الرئيسية (PCA) لتقليل الأبعاد وتصور توزيع البيانات. تم إجراء التقييم بدون عملية تصنيف واضحة، ولكن من خلال تحليل نمط نتائج إسقاط PCA ، والتي أظهرت تشكيل ثلاث مجموعات بصرية رئيسية. يشير هذا إلى أن السمات المستخرجة لديها القدرة على تمييز الخصائص البصرية لمستويات الضرر. يُظهر هذا البحث أن طريقة شبكة VGG-11 الشبكية فعالة كنهج أولي في فهم التوزيع البصري لأضرار المباني، وتفتح فرصًا لمزيد من التطوير في أنظمة التقييم الآلي القائمة على الصور.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Bencana alam seperti gempa bumi, tsunami, tanah longsor, dan sebagainya seringkali menyebabkan kerusakan signifikan pada infrastruktur, termasuk bangunan tempat tinggal, fasilitas umum, dan gedung perkantoran. Kota Malang, sebagai salah satu wilayah yang rawan terhadap bencana alam, kerap mengalami dampak dari kejadian-kejadian tersebut. Dalam konteks ini, firman Allah dalam Surah Ar-Rum ayat 41 mengingatkan:

ظَهَرَ الْفَسَادُ فِي الْبَرِّ وَالْبَحْرِ بِمَا كَسَبَتْ أَيْدِي النَّاسِ لِيُذِيقَهُمْ بَعْضَ الَّذِي عَمِلُوا لَعَلَّهُمْ يَرْجِعُونَ ﴿٤١﴾

"(41) 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)." (Q.S. Ar-Rum : 41)

Ayat ini memberikan refleksi mendalam bahwa berbagai kerusakan yang terjadi, termasuk bencana alam, tidak terlepas dari ulah manusia itu sendiri. Oleh karena itu, proses identifikasi dan evaluasi kerusakan bangunan pasca bencana menjadi sangat penting dalam menentukan langkah-langkah rehabilitasi dan rekonstruksi yang tepat, sekaligus sebagai bentuk introspeksi dan upaya kembali kepada jalan yang benar.

Pada penelitiannya (Almais et al., 2024), dijelaskan bahwa untuk menganalisis tingkat kerusakan bangunan pasca bencana alam, dapat digunakan hasil ekstraksi fitur dengan teknik GLCM yang kemudian dianalisis menggunakan pendekatan PCA-Clustering. Label atau kategori kerusakan ditentukan berdasarkan

standar yang dirujuk dari penelitian sebelumnya (Almais et al., 2023), yang telah menyusun acuan tingkat kerusakan bangunan pasca bencana. Selain itu, teknik *clustering* yang lebih baru juga mulai banyak digunakan untuk mengelompokkan data berdasarkan kesamaan karakteristik visual. Namun, dari penelitian-penelitian tersebut, terlihat bahwa masih terdapat ruang untuk pengembangan, khususnya dalam hal penerapan kecerdasan buatan (*Artificial Intelligence/AI*) untuk analisis data citra.

Dalam beberapa tahun terakhir, metode berbasis AI telah berkembang pesat dan diterapkan di berbagai bidang, termasuk dalam analisis citra digital. Salah satu pendekatan AI yang paling menonjol adalah *Deep Learning* (DL), yang memungkinkan ekstraksi informasi visual secara otomatis dan lebih mendalam. *Visual Geometry Group Network* (VGG) merupakan salah satu arsitektur populer dalam DL untuk tugas pengolahan citra, dengan beberapa varian seperti VGG-11, VGG-13, VGG-16, dan VGG-19 (Kaya & Akgül, 2022). Di antara varian tersebut, VGG-11 Net dipilih karena memiliki arsitektur yang lebih sederhana namun tetap efektif dalam melakukan ekstraksi fitur dan analisis citra (Rahman et al., 2019).

Penelitian ini berfokus pada analisis data citra kerusakan bangunan pasca bencana alam menggunakan metode *VGG-11 Net* untuk ekstraksi fitur. Citra bangunan yang mengalami kerusakan diolah untuk menghasilkan representasi numerik yang menggambarkan karakteristik visual dari kerusakan tersebut (Souza et al., 2024). Setelah proses ekstraksi, fitur yang diperoleh dianalisis menggunakan *Principal Component Analysis* (PCA) untuk mereduksi dimensi dan memvisualisasikan distribusi data, dengan tujuan mengidentifikasi pola atau

kelompok dalam data berdasarkan karakteristik kerusakannya. Pendekatan ini tidak secara langsung mengklasifikasikan kerusakan, tetapi memberikan wawasan awal terhadap struktur data visual yang terekstraksi (Hasnain et al., 2020). Hasil dari penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan pemanfaatan teknologi kecerdasan buatan (AI), khususnya dalam bidang analisis citra pasca bencana. Selain itu, metode ini menunjukkan bahwa *VGG-11 Net* dapat digunakan sebagai alat bantu dalam memahami informasi kerusakan bangunan secara visual melalui teknik ekstraksi fitur (Bibi et al., 2021).

1.2 Rumusan Masalah

Berdasarkan latar belakang di atas, beberapa permasalahan yang akan dikaji dalam penelitian ini adalah:

1. Bagaimana cara *VGG-11 Net* untuk mengekstraksi fitur gambar bangunan pasca bencana alam ?
2. Bagaimana mengetahui performa arsitektur *VGG-11 Net* dalam mengekstraksi fitur gambar bangunan pasca bencana alam?

1.3 Batasan Masalah

Agar penelitian ini lebih terfokus dan terarah, beberapa Batasan yang diterapkan dalam penelitian ini adalah sebagai berikut:

1. Penelitian ini hanya akan menggunakan model *VGG-11 Net* untuk ekstraksi fitur gambar kerusakan bangunan pasca bencana alam, tanpa membandingkannya dengan arsitektur *deep learning* lainnya.

2. Dataset yang digunakan terdiri dari gambar kerusakan bangunan dari situs data terbuka, *namely Kaggle*, atau dari data langsung dari foto kamera, hasil pencarian mesin pencari *Google*, dan dari BPBD Kota Malang.
3. Penelitian ini hanya fokus pada tahap ekstraksi fitur dan tidak mencakup pengembangan sistem deteksi secara *end-to-end* atau integrasi dengan sistem tanggap darurat.

1.4 Tujuan Penelitian

Penelitian ini bertujuan untuk:

1. Mengimplementasikan metode *VGG-11 Net* dalam ekstraksi fitur pada gambar bangunan pasca bencana alam.
2. Menganalisis performa model dalam hal akurasi, efisiensi pemrosesan, dan generalisasi pada dataset gambar kerusakan bangunan.

1.5 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat bagi berbagai pihak, di antaranya:

1. Bagi Penulis:
 - a) Menambah wawasan dan pemahaman mengenai penerapan metode deep learning, khususnya *VGG-11 Net*, dalam bidang ekstraksi fitur kerusakan bangunan.
 - b) Mengasah keterampilan dalam analisis data dan evaluasi model kecerdasan buatan.

2. Bagi Pembaca:

- a) Memberikan referensi dan wawasan mengenai metode *deep learning* dalam ekstraksi fitur kerusakan bangunan pasca bencana.
- b) Dapat menjadi bahan acuan bagi penelitian selanjutnya yang berkaitan dengan analisis citra dan kecerdasan buatan dalam bidang mitigasi bencana.

3. Bagi Pemerintah dan Instansi terkait:

- a) Menyediakan informasi yang dapat membantu dalam perencanaan dan pengambilan keputusan terkait mitigasi dan rehabilitasi bangunan pasca bencana.
- b) Meningkatkan efisiensi dalam proses identifikasi kerusakan bangunan sehingga tindakan penanggulangan dapat dilakukan lebih cepat dan tepat sasaran.
- c) Memberikan rekomendasi teknologi berbasis AI yang dapat digunakan untuk meningkatkan ketahanan dan respons terhadap bencana alam.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terkait

Pada penelitian yang dilakukan oleh (Haksoro & Setiawan, 2021) bertujuan untuk mengenali jamur tidak beracun atau beracun dengan pendekatan *Convolutional Neural network*. Menggunakan 4 Model yaitu MobileNetV2, MobileNets, VGG19, dan ResNet50. Hasil pengujian memperlihatkan bahwa metode *Transfer Learning Convolutional Neural network* dapat mengenali jamur yang bisa dikonsumsi dengan akurasi lebih dari 86%. Hasil nilai akurasi terbaik ialah 92.19% yang didapatkan dari penerapan *base* model MobileNetsV2 dengan nilai *learning rate* 0,00001 pada tahap *pre-training* dan 0,0001 pada tahap *fine-tuning*.

Pada Penelitian yang dilakukan oleh (Najib & Mohamad Khoirun, 2022) menerapkan serta melakukan evaluasi komparatif antara dua arsitektur CNN, yakni AlexNet dan VGG, dalam tugas identifikasi ekspresi wajah. Berdasarkan hasil eksperimen, ketiga arsitektur mampu mengenali ekspresi wajah dengan performa tinggi, dibuktikan oleh rata-rata akurasi pada data pelatihan dan pengujian yang melampaui angka 94%. Dalam mencapai nilai loss cross-entropy sebesar 0.1, model VGG-11 Net menunjukkan efisiensi pelatihan terbaik dengan jumlah epoch paling sedikit dibandingkan model lainnya. Sebaliknya, arsitektur AlexNet tercatat sebagai model dengan waktu pelatihan tercepat secara keseluruhan. Durasi pelatihan secara umum berkorelasi dengan kompleksitas parameter dalam masing-

masing arsitektur, meskipun jumlah epoch yang lebih sedikit tidak selalu menjamin waktu komputasi yang lebih singkat. Selain itu, metrik evaluasi lain seperti recall, precision, dan F1-score pada skenario klasifikasi multi-kelas juga menunjukkan kinerja unggul, dengan nilai yang konsisten di atas 94%.

Pada Penelitian yang dilakukan oleh (Zhou et al., 2021) Berdasarkan model *VGG-11 Net* tradisional, Penelitian ini mengusulkan jaringan saraf konvolusi dalam yang ditingkatkan yang dapat secara akurat mendeteksi keaktifan wajah dari gambar wajah tunggal. Hasil eksperimen terhadap metode-metode mutakhir pada basis data keaktifan wajah NUAA dan CASIA menunjukkan bahwa, metode yang diusulkan dapat mencapai akurasi yang lebih tinggi dan tingkat kesalahan pengenalan yang lebih rendah pada deteksi keaktifan wajah.

Pada penelitian yang dilakukan oleh (Melinda et al., 2023) Penelitian ini dikembangkan untuk membantu mengenali wajah anak autisme menggunakan model *Convolutional Neural network* (CNN) dengan dua arsitektur: *shuffle Net*, yang menggunakan saluran acak, dan VGG-19, yang memiliki 19 lapisan untuk proses klasifikasi. Data yang digunakan merupakan data sekunder dari *Kaggle*, terdiri dari 2.940 gambar wajah anak autisme dan non-autisme. Data dibagi menjadi 2.540 data pelatihan dan 300 data uji, dengan 100 data validasi (50 autisme dan 50 non-autisme). Hasil eksperimen menunjukkan bahwa model VGG-19 mencapai akurasi tinggi sebesar 98%, sementara *shuffle Net* memperoleh akurasi 88%.

Pada penelitian yang dilakukan oleh (Seandrio et al., 2021) mengklasifikasi pengolahan berupa citra menggunakan *convolutional neural network*. Pengujian terhadap 3.589 data citra ekspresi wajah menghasilkan tingkat akurasi sebesar

70,46%, dengan nilai presisi mencapai 71% dan recall sebesar 70%. Hasil ini menunjukkan bahwa sistem mampu mengenali ekspresi dasar manusia dengan performa yang cukup baik, meskipun masih terdapat ruang untuk peningkatan akurasi. Pada penelitian ini emosi pada wajah diidentifikasi melalui citra yang diambil secara *real-time* menggunakan kamera dan dengan menerapkan metode *Convolutional Neural network* dengan arsitektur *visual group geometry* (VGG) dengan 11, 13, 16 dan 19 lapisan yang akan menghasilkan probabilitas ekspresi dalam 7 ekspresi dasar manusia beserta kategorinya.

Penelitian yang dilakukan oleh (Raja et al., 2021) mengembangkan sistem deteksi glaukoma berbasis analisis citra fundus menggunakan pendekatan pembelajaran mendalam. Glaukoma, yaitu kondisi kerusakan saraf optik yang dapat menyebabkan gangguan penglihatan, dinilai melalui parameter tekanan intraokular dan *rasio cup-to-disc* (CDR). Dalam penelitian ini, digunakan arsitektur jaringan VGG-19 yang dikombinasikan dengan metode klasifikasi *Support Vector Machine* (SVM) untuk mengenali glaukoma secara otomatis. Citra fundus diklasifikasikan sebagai glaukoma apabila nilai CDR-nya melebihi ambang batas 0,41. Dengan menggunakan dataset berisi 175 gambar fundus, sistem yang dikembangkan berhasil mencapai akurasi klasifikasi sebesar 94%. Hasil ini menunjukkan bahwa kombinasi antara VGG-19 dan SVM dapat digunakan secara efektif dalam membantu deteksi dini glaukoma melalui analisis citra medis.

Penelitian yang dilakukan oleh (Kumar & Kumar, 2023) memanfaatkan citra sinar-X dada untuk mendeteksi COVID-19 secara efektif, menggunakan dataset COVID-Xray-5k yang terdiri dari data tidak seimbang antara pasien positif

dan normal. Beberapa pendekatan diterapkan, termasuk metode konvensional seperti *Local Binary Pattern* (LBP) untuk ekstraksi fitur dan *Support Vector Machine* (SVM) untuk klasifikasi. Selain itu, diterapkan *transfer learning* menggunakan model VGG16 dan VGG19, serta dikembangkan arsitektur CNN baru untuk klasifikasi otomatis. Salah satu model CNN yang diusulkan berhasil mencapai akurasi hingga 99,45% dan skor F1 sebesar 91%, menunjukkan potensi besar dalam klasifikasi COVID-19 meskipun data tidak seimbang.

Penelitian yang dilakukan oleh (Ali et al., 2024) Klasifikasi manual terhadap pola sirkulasi kolateral menggunakan teknik pencitraan tradisional masih bersifat padat karya dan rawan subjektivitas. Untuk mengatasi hal tersebut, penelitian ini mengusulkan pendekatan klasifikasi otomatis menggunakan arsitektur VGG-11 pada *citra cone-beam CT* (CBCT) pasien stroke iskemik. Sebelum pelatihan model, gambar terlebih dahulu melalui tahap normalisasi guna menyamakan skala nilai piksel, serta dilakukan augmentasi untuk memperkaya variasi data pelatihan. Model VGG-11 kemudian dilatih untuk mengklasifikasikan pola sirkulasi kolateral. Hasil pengujian menunjukkan bahwa model ini mampu mencapai akurasi sebesar 58,32%, sensitivitas 75,50%, spesifisitas 44,10%, presisi 52,70%, dan skor F1 sebesar 62,10%. Pendekatan ini menunjukkan potensi besar dalam mengotomatiskan proses klasifikasi sirkulasi kolateral, sehingga dapat mempercepat diagnosis dan memberikan dukungan yang lebih akurat bagi pengambilan keputusan klinis. Penelitian ini juga membuka peluang untuk pengembangan lebih lanjut dalam penerapan deep learning dalam diagnosis dan manajemen stroke secara efisien.

Tabel 2.1 Penelitian Terkait

Referensi	Topik	Metode	Hasil
(Haksoro & Setiawan, 2021)	Pengenalan Jamur yang dapat Dikonsumsi Menggunakan Metode <i>Transfer Learning</i> Pada <i>Convolutional Neural network</i>	MobileNets, MobileNetsV2, ResNet50, dan VGG-19 Net	Akurasi tertinggi, yaitu sebesar 92,19%, diperoleh melalui implementasi model dasar MobileNetV2, yang menunjukkan kinerja optimal dibandingkan pendekatan lainnya. Dan hasil untuk VGG-19 Net di tahap <i>pre-training</i> ialah 86,46% dengan learning rate 0,00001.
(Najib & Mohamad Khoirun, 2022)	Perbandingan AlexNet dan VGG Net untuk pengenalan Ekspresi Wajah pada Dataset Kelas Komputasi Lanjut	AlexNet dan VGG Net	hasil dari ketiga metode tersebut alexnet memiliki akurasi <i>data training</i> 99.3%, VGG-11 dengan akurasi 99.3%, dan VGG-16 dengan akurasi 98.5%.
(Zhou et al., 2021)	Algoritma Deteksi keaktifan Wajah yang Ditingkatkan Berdasarkan Jaringan Syaraf Tiruan Konvolusi Mendalam	VGG-11 Net	Hasil eksperimen terhadap metode-metode mutakhir pada basis data keaktifan wajah NUAA dan CASIA menunjukkan bahwa metode yang diusulkan atau VGG-11 Net mencapai akurasi yang lebih tinggi dan tingkat kesalahan pengenalan yang lebih rendah pada deteksi pengenalan wajah.
(Melinda et al., 2023)	Kinerja Model Klasifikasi Arsitektur <i>shuffle Net Net</i> dan VGG-19 Net untuk Pengenalan Wajah pada Anak Autis	VGG-19 Net	Hasilnya eksperimen menunjukkan bahwa model VGG-19 mencapai akurasi tinggi sebesar 98%, sementara <i>shuffle Net Net</i> memperoleh akurasi 88%.
(Seandrio et al., 2021)	Implementasi <i>Convolutional Neural network</i> (CNN) Pada Pengenalan Ekspresi Wajah	VGG-11 Net	Evaluasi sistem terhadap 3.589 sampel ekspresi wajah dasar menunjukkan performa klasifikasi dengan

Referensi	Topik	Metode	Hasil
			akurasi sebesar 70,46%, presisi 71%, dan recall 70%. Capaian ini mencerminkan tingkat efektivitas model dalam mengidentifikasi ekspresi, meskipun masih terdapat potensi peningkatan di beberapa aspek evaluasi.
(Raja et al., 2021)	Deteksi Dini Glaukoma Secara Otomatis Menggunakan Jaringan Syaraf Tiruan Berbasis Support Vector Machine Visual Geometry Group 19 (VGG-19) Convolutional Neural Network	VGG-19 Net	Hasil dari kombinasi dari VGG-19 dan SVM menggunakan dataset berisi 175 gambar fundus, sistem yang dikembangkan berhasil mencapai akurasi klasifikasi sebesar 94%. Hal ini menunjukkan bahwa kombinasi antara kedua ini dapat digunakan secara efektif dalam membantu deteksi dini glaukoma melalui analisis citra medis.
(Kumar & Kumar, 2023)	Klasifikasi citra sinar-X COVID-19 menggunakan pembelajaran transfer dengan kelompok geometris visual dan jaringan saraf konvolusi berurutan yang baru	Local Binary Pattern (LBP), Support Vector Machine (SVM), VGG16 dan VGG19	Salah satu model CNN yang diusulkan berhasil mencapai akurasi hingga 99,45% dan skor F1 sebesar 91%, menunjukkan potensi besar dalam klasifikasi COVID-19 meskipun data tidak seimbang.

Referensi	Topik	Metode	Hasil
(Ali et al., 2024)	Klasifikasi Otomatis Sirkulasi Kolateral untuk Stroke Iskemik pada Citra Cone-Beam CT Menggunakan VGG11: Pendekatan Pembelajaran Mendalam	VGG-11 Net	Hasil pengujian menunjukkan bahwa model ini mampu mencapai akurasi sebesar 58,32%, sensitivitas 75,50%, spesifisitas 44,10%, presisi 52,70%, dan skor F1 sebesar 62,10%.

2.2 Kajian Teoritis

2.2.1 Pengolahan Citra

Pengolahan citra digital (*digital image processing*) adalah suatu teknik untuk memanipulasi citra dengan bantuan komputer agar citra tersebut menjadi lebih baik untuk tujuan tertentu, seperti analisis, deteksi, segmentasi, atau klasifikasi (Aulia, n.d.). Citra digital merupakan representasi dua dimensi dari suatu objek yang disimpan dalam bentuk matriks nilai piksel, di mana setiap piksel merepresentasikan intensitas cahaya pada posisi tertentu.

Tujuan utama pengolahan citra adalah untuk meningkatkan kualitas visual citra (*image enhancement*) atau untuk mengekstrak informasi yang berguna dari citra (*feature extraction*) (Nurhayati, 2020). Dalam konteks penelitian ini, pengolahan citra digunakan untuk mempersiapkan data citra bangunan pasca bencana sebelum dilakukan ekstraksi fitur. Tahapan umum dalam pengolahan citra meliputi *pre-processing*, segmentasi, transformasi citra, dan ekstraksi fitur (Noviana & Madenda, 2014).

Pre-processing dilakukan untuk menyesuaikan kualitas gambar, seperti mengubah ukuran (*resizing*), normalisasi intensitas piksel, hingga augmentasi gambar guna memperbesar variasi data tanpa menambah jumlah data asli (Fachrezzy, n.d.). Proses ini penting agar fitur yang dihasilkan dari model lebih stabil dan representatif. Ekstraksi fitur merupakan tahap lanjutan dari pengolahan citra, yaitu proses mengambil informasi penting dari citra dalam bentuk numerik yang dapat digunakan untuk analisis lebih lanjut. Dalam penelitian ini, pengolahan citra digital memegang peranan penting karena kualitas fitur yang diperoleh sangat dipengaruhi oleh tahapan ini. Oleh karena itu, metode *deep learning* seperti *VGG-11 Net* digunakan sebagai pendekatan modern dalam ekstraksi fitur dari citra kerusakan bangunan pasca bencana.

2.2.2 Image Preprocessing

Image preprocessing adalah tahap awal dalam sistem pengolahan citra yang bertujuan untuk meningkatkan kualitas citra serta mempersiapkan citra agar lebih sesuai untuk tahap analisis selanjutnya seperti ekstraksi fitur, segmentasi, atau klasifikasi (Sujjada et al., 2025). Tahap ini penting karena citra yang diambil dari berbagai sumber sering kali mengandung *noise*, memiliki ukuran yang tidak seragam, atau intensitas cahaya yang tidak konsisten. Beberapa teknik umum dalam image preprocessing meliputi:

1. Reizing

Citra diubah ukurannya ke dimensi tertentu agar seragam dan sesuai dengan masukan model. Dalam penelitian ini, semua gambar diubah ukurannya

menjadi 224x224 piksel untuk menyesuaikan arsitektur *VGG-11 Net* yang digunakan dalam tahap ekstraksi fitur.

2. *Grayscale Conversion*

Citra diubah menjadi skala abu-abu (*grayscale*) untuk mengurangi kompleksitas data dan fokus pada intensitas cahaya tanpa mempertimbangkan warna. Hal ini juga sesuai dengan karakteristik model yang diadaptasi untuk input satu channel.

3. *Normalisasi (Normalization)*

Proses ini mengubah rentang nilai piksel menjadi skala tertentu, biasanya antara 0 hingga 1, untuk mempercepat proses pelatihan model dan menjaga stabilitas perhitungan dalam jaringan saraf. Normalisasi juga membantu mengurangi pengaruh variasi pencahayaan dalam citra.

4. *Augmentasi (Augmentation)*

Teknik augmentasi digunakan untuk meningkatkan variasi data latih dengan cara menghasilkan citra baru dari citra yang ada melalui rotasi, *flipping*, pengubahan kecerahan, dan sebagainya. Langkah ini bertujuan untuk mengurangi *overfitting* dan membuat model lebih generalisasi terhadap data baru.

Melalui tahap *preprocessing* ini, citra yang semula memiliki beragam karakteristik akan menjadi data yang seragam, bersih, dan lebih representatif untuk dianalisis lebih lanjut. Proses ini juga memastikan bahwa fitur yang diekstraksi dari citra memiliki konsistensi struktur dan kualitas, sehingga hasil analisis atau klasifikasi menjadi lebih akurat.

2.2.3 Convolutional Neural networks

Convolutional Neural networks (CNN) adalah jenis jaringan saraf tiruan yang dirancang khusus untuk memproses data berbentuk *grid*, seperti gambar dan video (Huang et al., 2021). CNN bekerja dengan menerapkan operasi konvolusi pada input, yang memungkinkan jaringan untuk menangkap pola lokal dalam data, seperti tepi, tekstur, dan bentuk (Kattenborn et al., 2021). Operasi konvolusi dua dimensi pada gambar dapat dijelaskan secara matematis dengan rumus:

$$S(i, j) = (I * K)(i, j) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} I(i + m, j + n) \cdot K(m, n) \quad (2.1)$$

Dimana I adalah citra input, K adalah kernel/filter berukuran $M \times N$, dan $S(i, j)$ adalah hasil konvolusi pada posisi (i, j) . Hasil dari konvolusi kemudian dilewatkan ke fungsi aktivasi, seperti ReLU, yang secara matematis dinyatakan sebagai $f(x) = \max(0, x)$, untuk menambahkan non-linearitas dalam jaringan. Selanjutnya, dilakukan proses *pooling* untuk mereduksi dimensi data, misalnya melalui max pooling yang mengambil nilai maksimum dari setiap area lokal. Setelah melalui beberapa lapisan konvolusi dan *pooling*, fitur yang diperoleh akan diteruskan ke lapisan fully connected untuk klasifikasi. CNN lebih efisien dalam memproses gambar karena jumlah parameter yang lebih sedikit, sehingga mengurangi kebutuhan komputasi dan risiko *overfitting* (Akbar et al., 2024). CNN banyak digunakan dalam berbagai aplikasi, seperti pengenalan wajah, deteksi objek, segmentasi gambar, dan analisis medis (Yang & Yu, 2021). Dengan

kemampuan untuk mengekstrak fitur secara otomatis dan akurat, CNN telah menjadi metode utama dalam pemrosesan citra digital (Dastres & Soori, n.d.).

2.2.4 *Transfer Learning*

Transfer learning adalah teknik dalam pembelajaran mesin di mana model yang telah dilatih sebelumnya pada satu tugas digunakan kembali atau disesuaikan untuk tugas yang berbeda tetapi serupa (Susanty et al., 2021). Pendekatan ini sangat berguna dalam *deep learning*, terutama ketika ketersediaan data pelatihan terbatas. Alih-alih melatih model dari nol, *transfer learning* memanfaatkan model yang sudah memiliki pemahaman awal terhadap pola umum dalam data, sehingga proses pelatihan menjadi lebih cepat dan efisien (Zhuang et al., 2020).

Proses *transfer learning* biasanya melibatkan dua tahap utama: *feature extraction* dan *fine-tuning*. Dalam tahap *feature extraction*, lapisan awal model yang telah dilatih sebelumnya digunakan untuk mengekstrak fitur dari data baru, sementara lapisan akhir yang bertanggung jawab atas klasifikasi dapat diganti dan dilatih ulang sesuai dengan kebutuhan spesifik. Pada tahap *fine-tuning*, beberapa atau semua lapisan model dapat disesuaikan dengan data baru untuk meningkatkan kinerja model pada tugas tertentu. Teknik ini memungkinkan model untuk beradaptasi dengan lingkungan atau domain yang berbeda tanpa harus belajar dari awal.

Transfer learning banyak digunakan dalam berbagai aplikasi kecerdasan buatan, seperti pengenalan gambar, pemrosesan bahasa alami, dan analisis suara. Dalam bidang medis, model yang telah dilatih pada dataset besar dapat disesuaikan untuk mendeteksi penyakit tertentu berdasarkan gambar medis yang lebih spesifik.

Dalam pemrosesan bahasa alami, model bahasa seperti BERT atau GPT dapat disesuaikan untuk berbagai tugas seperti penerjemahan atau analisis sentimen. Dengan memanfaatkan *transfer learning*, organisasi dan peneliti dapat mengembangkan solusi berbasis AI dengan lebih efisien, mengurangi kebutuhan data pelatihan besar, dan meningkatkan akurasi dalam berbagai tugas pemrosesan data (Singh, 2023).

2.2.5 VGG-11 Net

VGG-11 Net adalah salah satu arsitektur jaringan saraf konvolusional (CNN) yang dikembangkan oleh *Visual Geometry Group* (VGG) di Universitas Oxford (*Arrhythmia Classification Using the Deep Learning Visual Geometry Group*, n.d.). Model ini merupakan bagian dari keluarga VGG yang dirancang untuk tugas pengenalan gambar dan pertama kali diperkenalkan dalam kompetisi *Image Challenge* tahun 2014. Arsitektur VGG-11 Net memiliki 11 lapisan yang dapat dilatih, terdiri dari lapisan konvolusi dan lapisan *fully connected*. Keunggulan utama VGG-11 Net adalah kesederhanaannya dalam desain, dengan penggunaan kernel konvolusi kecil berukuran 3×3 , yang memungkinkan model untuk menangkap fitur kompleks tanpa meningkatkan jumlah parameter secara signifikan.

Struktur VGG-11 Net terdiri dari 8 lapisan konvolusi, di mana setiap lapisan diikuti oleh fungsi aktivasi ReLU untuk meningkatkan non-linearitas, serta beberapa lapisan pooling untuk mengurangi dimensi data dan meningkatkan efisiensi komputasi. Setelah melalui lapisan konvolusi, fitur yang diekstrak umumnya dikirim ke tiga lapisan *fully connected* yang berfungsi untuk klasifikasi. Namun, dalam penelitian ini, proses hanya difokuskan pada ekstraksi fitur tanpa

dilanjutkan ke tahap klasifikasi, sehingga bagian fully connected tidak digunakan. Hal ini sesuai dengan tujuan penelitian yang lebih menitikberatkan pada analisis representasi visual fitur menggunakan PCA, bukan pada prediksi kelas. Model ini memiliki sekitar 132 juta parameter, menjadikannya lebih ringan dibandingkan varian yang lebih besar seperti VGG-16 dan VGG-19. Namun, meskipun lebih ringan, VGG-11 Net masih membutuhkan daya komputasi yang cukup besar, terutama saat dilatih dengan dataset berskala besar seperti ImageNet (Zhu et al., 2024).

VGG-11 Net banyak digunakan sebagai model dasar dalam berbagai aplikasi pengenalan gambar dan *transfer learning* (Alshazly et al., 2019). Karena strukturnya yang sederhana dan modular, model ini sering digunakan dalam penelitian serta sebagai dasar untuk model yang lebih kompleks. Dalam tugas-tugas klasifikasi gambar, VGG-11 Net dapat memberikan hasil yang baik, meskipun arsitektur yang lebih baru seperti *ResNet* telah menggantikannya dalam banyak aplikasi karena efisiensi dan kemampuannya dalam menangani masalah *vanishing gradient*. Meskipun demikian, VGG-11 Net tetap menjadi pilihan yang baik dalam berbagai skenario dimana interpretabilitas dan kesederhanaan model menjadi pertimbangan utama.

2.2.6 Ekstraksi Fitur

Ekstraksi fitur adalah proses dalam pembelajaran mesin dan pemrosesan data yang bertujuan untuk mengambil informasi penting dari data mentah sehingga dapat digunakan dalam analisis atau klasifikasi (Sarhan et al., 2024). Dalam konteks pengolahan gambar, ekstraksi fitur berarti mengidentifikasi karakteristik penting

seperti tepi, tekstur, bentuk, dan warna yang dapat digunakan oleh model kecerdasan buatan untuk membedakan satu objek dari yang lain. Dalam pemrosesan teks, ekstraksi fitur melibatkan pengambilan kata kunci, analisis frekuensi kata, atau representasi teks dalam bentuk vektor numerik agar dapat dipahami oleh algoritma komputer.

Proses ekstraksi fitur dapat dilakukan dengan berbagai metode, tergantung pada jenis data yang diolah. Dalam pengolahan citra, beberapa teknik yang umum digunakan termasuk *Histogram of Oriented Gradients* (HOG) untuk mendeteksi tepi dan tekstur, *Scale-Invariant Feature Transform* (SIFT) untuk menangkap fitur yang tidak terpengaruh oleh rotasi atau skala, serta penggunaan jaringan saraf konvolusional (CNN) yang secara otomatis dapat mengekstrak fitur tingkat tinggi dari gambar. Dalam pemrosesan bahasa alami (NLP), metode seperti *Term Frequency-Inverse Document Frequency* (TF-IDF) dan *Word Embeddings* (Word2Vec, GloVe, BERT) digunakan untuk mengubah teks menjadi representasi numerik yang lebih bermakna bagi model pembelajaran mesin (Naeem et al., 2022).

Ekstraksi fitur sangat penting karena dapat meningkatkan efisiensi dan akurasi model kecerdasan buatan dengan mengurangi dimensi data dan menghilangkan informasi yang tidak relevan (Zebari et al., 2020). Dengan memilih fitur yang paling informatif, model dapat belajar lebih cepat dan menghasilkan prediksi yang lebih akurat. Dalam berbagai aplikasi seperti pengenalan wajah, deteksi objek, analisis sentimen, dan diagnosis medis berbasis AI, ekstraksi fitur menjadi langkah utama yang menentukan keberhasilan sistem (Tariq et al., 2024). Oleh karena itu, memilih metode ekstraksi fitur yang tepat sesuai dengan

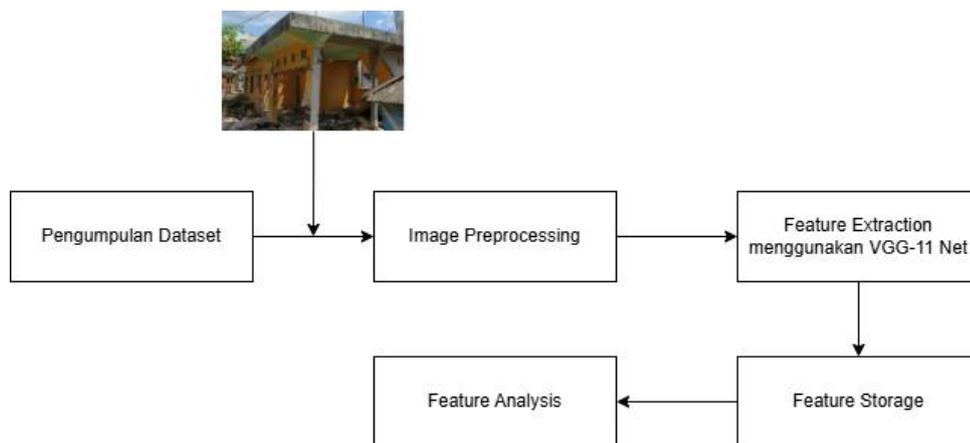
karakteristik data sangat penting dalam membangun model kecerdasan buatan yang efektif.

BAB III

METODE PENELITIAN

3.1 Desain Sistem

Proses ekstraksi fitur pada kerusakan bangunan pasca bencana alam menggunakan VGG-11 Net dimulai dengan pengumpulan dataset, yang dimana gambar yang dikumpulkan dari situs data terbuka, *namely Kaggle*, hasil pencarian mesin pencari *Google*, dan BPBD Kota Malang. Setelah dataset dikumpulkan, langkah selanjutnya adalah melakukan *preprocessing* pada gambar, yang mencakup *resizing*, normalisasi, dan augmentasi untuk meningkatkan variasi data dan mengurangi *overfitting*.



Gambar 3.1 Desain Sistem

3.1.1 Pengumpulan Data

Pengumpulan data dimulai dengan mengidentifikasi sumber gambar bangunan yang mengalami kerusakan akibat bencana alam. Sumber data dapat berasal dari situs data terbuka, *namely Kaggle*, hasil pencarian mesin pencari *Google*, dan BPBD Kota Malang. Dari BPBD Kota Malang dikumpulkan data pada

tanggal 9 Mei 2025, dari *Kaggle* dikumpulkan data pada tanggal 4 Mei 2025. Dalam tahap ini, penting untuk mengumpulkan gambar yang mencakup berbagai jenis kerusakan, seperti retakan, runtuh, dan kerusakan struktural lainnya. Selain itu, variasi dalam kondisi pencahayaan, sudut pengambilan gambar, dan jenis bangunan juga harus diperhatikan untuk memastikan bahwa dataset mencakup representasi yang luas dari berbagai situasi. Gambar-gambar ini kemudian disimpan dalam format yang sesuai, seperti JPEG atau PNG, untuk analisis lebih lanjut.



Gambar 3.2 Data Gambar Kerusakan Bangunan

3.1.2 *Image Preprocessing*

Tahap *preprocessing* merupakan proses penting dalam pemrosesan citra yang bertujuan untuk mempersiapkan gambar agar dapat digunakan secara optimal dalam pelatihan model *machine learning*. Langkah pertama dalam tahap ini adalah *resizing* gambar, yaitu penyesuaian ukuran semua citra menjadi dimensi yang seragam, yaitu 224x224 piksel, sesuai dengan arsitektur VGG-11 Net. Proses ini biasanya menggunakan metode interpolasi, yang secara matematis dapat dinyatakan sebagai:

$$I'(x', y') = I\left(\frac{x \cdot W_{in}}{W_{out}}, \frac{y \cdot H_{in}}{H_{out}}\right) \quad (3.1)$$

Dengan I' merupakan citra hasil perubahan ukuran, dan $W_{in}, H_{in}, W_{out}, H_{out}$ masing-masing mewakili lebar dan tinggi gambar sebelum dan sesudah diubah ukurannya. Selanjutnya, dilakukan normalisasi nilai piksel guna menyamakan skala data dan mempercepat proses konvergensi saat pelatihan model. Nilai piksel citra yang semula berada dalam rentang $[0, 255]$ diubah menjadi rentang $[0, 1]$ menggunakan rumus:

$$X_{norm} = \frac{x}{255} \quad (3.2)$$

atau ke dalam rentang $[-1, 1]$ menggunakan rumus:

$$X_{norm} = \frac{x - 127.5}{127.5} \quad (3.3)$$

Tahap berikutnya adalah augmentasi data, yaitu teknik untuk memperluas dan memperkaya *dataset* secara artifisial melalui transformasi citra. Beberapa teknik augmentasi umum yang digunakan meliputi rotasi, yang secara matematis dinyatakan sebagai:

$$\begin{bmatrix} x^1 \\ y^1 \end{bmatrix} = \begin{bmatrix} \cos 0 & -\sin 0 \\ \sin 0 & \cos 0 \end{bmatrix} \cdot \begin{bmatrix} x \\ y \end{bmatrix} \quad (3.4)$$

kemudian *flipping* horizontal, yang direpresentasikan dengan:

$$x' = W - 1 - x, y' = y \quad (3.5)$$

serta *zooming*, yaitu:

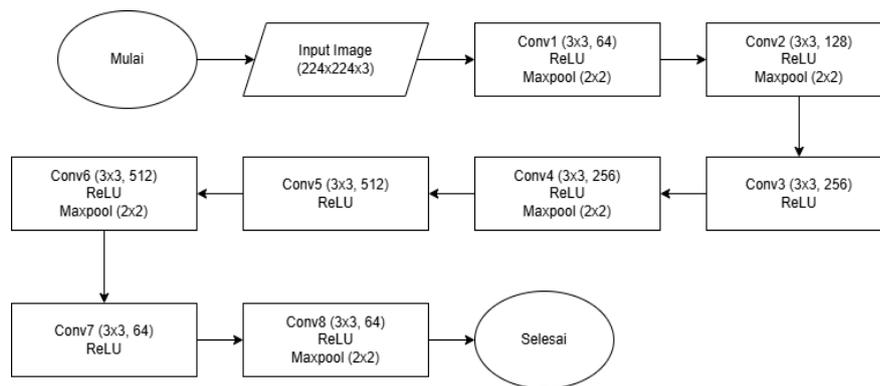
$$I'(x, y) = I\left(\frac{x}{z}, \frac{y}{z}\right) \quad (3.6)$$

dan penyesuaian kecerahan:

$$I'(x, y) = I(x, y) + \Delta b \quad (3.8)$$

Seluruh proses *preprocessing* ini bertujuan untuk memastikan model memiliki kemampuan dalam mengenali pola-pola kerusakan bangunan secara lebih robust dan akurat, meskipun citra yang digunakan memiliki variasi dalam hal pencahayaan, rotasi, skala, maupun orientasi.

3.1.3 Feature Extraction menggunakan VGG-11 Net



Gambar 3.3 Arsitektur VGG-11 Net

Gambar diatas merupakan alur dari proses metode VGG-11 Net yang digunakan untuk *feature extraction*. pada tahap ini, citra yang telah diproses sebelumnya dimasukkan ke dalam model *Convolutional Neural network* (CNN)

dengan arsitektur VGG-11 Net untuk melakukan ekstraksi fitur. VGG-11 Net merupakan arsitektur deep learning yang terdiri dari 8 lapisan, yaitu lapisan konvolusi. Model ini dirancang untuk mengekstraksi fitur visual penting dari gambar, seperti tepi, tekstur, dan bentuk struktur bangunan yang rusak. Proses ekstraksi dilakukan dengan cara menghilangkan lapisan klasifikasi akhir dan mengambil keluaran dari lapisan sebelum klasifikasi sebagai representasi fitur. Hasil ekstraksi ini berupa vektor numerik yang merepresentasikan karakteristik visual dari gambar bangunan, yang nantinya digunakan dalam proses penyimpanan dan analisis.

Satu sampel citra grayscale berukuran 224×224 piksel dijadikan input awal dalam proses ekstraksi fitur menggunakan arsitektur VGG-11 yang telah dimodifikasi. Input image 224×224 :

Tabel 3.1 Input Image 224×224

140	133	123	141	133	...	200
149	138	124	141	134	...	203
152	134	111	125	126	...	177
137	123	106	125	129	...	135
121	119	117	144	143	...	133
...
94	79	72	66	99	...	82

Citra ini dimasukkan ke dalam layer *Conv1*, yaitu konvolusi pertama dengan kernel 3×3 dan padding 1, yang menghasilkan output sebanyak 64 channel. Setiap channel memiliki ukuran spasial tetap yaitu 224×224 piksel, dan nilai piksel pada layer ini merepresentasikan hasil perhitungan konvolusi. Input conv1:

Tabel 3.1 Hasil Conv1

0.002514	-0.26688	-0.2504	-0.22778	-0.26121	...	-0.38645
0.09577	-0.02397	0.006702	0.011256	0.016194	...	-0.22129
0.083195	-0.02305	0.014488	0.033139	0.050488	...	-0.19248
0.064763	-0.00802	0.019481	0.02705	0.040353	...	-0.20169
0.064111	0.001787	0.020633	0.010359	0.010689	...	-0.23538

...
-0.05807	-0.05309	-0.07503	-0.03928	-0.01689	...	-0.18975

Setelah itu, hasil *Conv1* melewati fungsi aktivasi *ReLU1*, yang akan mengubah semua nilai negatif menjadi nol.

Tabel 3.2 Hasil ReLU1

0.002514	0	0	0	0	...	0
0.09577	0	0.006702	0.011256	0.016194	...	0
0.083195	0	0.014488	0.033139	0.050488	...	0
0.064763	0	0.019481	0.02705	0.040353	...	0
0.064111	0.001787	0.020633	0.010359	0.010689	...	0
...
0	0	0	0	0	...	0

Selanjutnya, hasil dari *ReLU1* dimasukkan ke dalam *MaxPooling1* dengan kernel 2×2 dan *stride* 2, sehingga ukuran spasial berubah dari 224×224 menjadi 112×112 piksel per *channel*, dan hanya nilai maksimum dari tiap blok 2×2 yang dipertahankan. Input *MaxPooling* menjadi 112×112 :

Tabel 3.3 Hasil Max Pooling1

0.09577	0.011256	0.020426	0.037827	0	...	0.092815
0.083195	0.033139	0.05534	0.078836	0.058101	...	0.151046
0.068198	0.026323	0.046878	0.087296	0.09298	...	0
0.060169	0.025457	0.064585	0.098359	0.06997	...	0.099329
0.064134	0.028753	0.058612	0.079599	0.07985	...	0.132775
...
0	0	0	0	0	...	0

Tahapan berikutnya, hasil dari *MaxPooling1* masuk ke *Conv2* yang memiliki 128 filter. Output dari *Conv2* menghasilkan 128 channel dengan ukuran spasial tetap 112×112 piksel. Input *conv2*:

Tabel 3.4 Hasil Conv2

-0.13287	-0.16761	-0.19345	-0.20464	-0.20923	...	-0.12578
-0.01844	-0.13998	-0.14945	-0.15741	-0.17214	...	-0.27197
-0.03594	-0.13813	-0.14327	-0.16224	-0.17714	...	-0.27105
-0.03046	-0.13202	-0.13779	-0.15045	-0.1771	...	-0.27513
-0.03558	-0.13756	-0.13336	-0.15449	-0.18618	...	-0.29416
...

0.042353	-0.00477	0.008685	0.014391	0.027244	...	-0.06013
----------	----------	----------	----------	----------	-----	----------

Setelah itu, hasil *Conv2* melewati fungsi aktivasi *ReLU2*, yang akan mengubah semua nilai negatif menjadi nol.

Tabel 3.5 Hasil ReLU2

0	0	0	0	0	...	0
0	0	0	0	0	...	0
0	0	0	0	0	...	0
0	0	0	0	0	...	0
0	0	0	0	0	...	0
...
0.042353	0	0.008685	0.014391	0.027244	...	-0.06013

Selanjutnya, hasil dari *ReLU2* dimasukkan ke dalam *MaxPooling2* dengan kernel 2×2 dan *stride* 2, sehingga ukuran spasial berubah dari 112×112 menjadi 56×56 piksel per *channel*, dan hanya nilai maksimum dari tiap blok 2×2 yang dipertahankan.

Tabel 3.6 Hasil Max Pooling2

0	0	0	0	0	...	0
0	0	0	0	0	...	0
0	0	0	0	0	...	0
0	0	0	0	0	...	0
0.024756	0	0	0	0	...	0
...
0.042353	0.014391	0.027244	0.013003	0.011497	...	0.0259224

Tahap selanjutnya, hasil dari *MaxPooling2* masuk ke *Conv3* yang memiliki 256 filter. Output dari *Conv3* menghasilkan 256 channel dengan ukuran spasial tetap 56×56 piksel. Input *conv3*:

Tabel 3.7 Hasil Conv3

-0.01728	0.003682	-0.00933	-0.00823	-0.00789	...	-0.03616
-0.02241	-0.04167	-0.04457	-0.04543	-0.04669	...	-0.07055
-0.0392	-0.03779	-0.02964	-0.0245	-0.02526	...	-0.05988
-0.0252	-0.04441	-0.03583	-0.03821	-0.03608	...	-0.05846
-0.02783	-0.0438	-0.03961	-0.03217	-0.02797	...	-0.05153
...
-0.02972	-0.03727	-0.0276	-0.02619	-0.03467	...	-0.02153

Setelah itu, hasil *Conv3* melewati fungsi aktivasi *ReLU3*, yang akan mengubah semua nilai negatif menjadi nol.

Tabel 3.8 Hasil ReLU3

0	0.003682	0	0	0	...	0
0	0	0	0	0	...	0
0	0	0	0	0	...	0
0	0	0	0	0	...	0
0	0	0	0	0	...	0
...
0	0	0	0	0	...	0

Tahap selanjutnya, hasil dari *ReLU3* masuk ke *Conv4* yang memiliki 256 filter. Output dari *Conv4* menghasilkan 256 channel dengan ukuran spasial tetap 56×56 piksel. Input conv4:

Tabel 3.9 Hasil Conv4

-0.00101	0.006374	0.013262	0.013737	0.013488	...	0.023751
-0.00315	-0.00287	0.00051	8.47E-05	-0.00098	...	0.010624
-0.0194	-0.01789	-0.0182	-0.01792	-0.01671	...	0.002442
-0.01167	-0.01222	-0.00494	-0.00841	-0.00742	...	0.003405
-0.00721	-0.01045	-0.00314	-0.00701	-0.00997	...	0.007977
...
-0.01516	-0.02691	-0.02636	-0.02182	-0.02077	...	-0.0166

Setelah itu, hasil *Conv4* melewati fungsi aktivasi *ReLU4*, yang akan mengubah semua nilai negatif menjadi nol.

Tabel 3. 10 Hasil ReLU4

0	0.006374	0.013262	0.013737	0.013488	...	0.023751
0	0	0.00051	0.0000846	0	...	0.010624
0	0	0	0	0	...	0.002442
0	0	0	0	0	...	0.003405
0	0	0	0	0	...	0.007977
...
0	0	0	0	0	...	0

Selanjutnya, hasil dari *ReLU4* dimasukkan ke dalam *MaxPooling4* dengan kernel 2×2 dan *stride* 2, sehingga ukuran spasial berubah dari 56×56 menjadi 28×28

piksel per *channel*, dan hanya nilai maksimum dari tiap blok 2×2 yang dipertahankan.

Tabel 3.11 Hasil Max Pooling4

0.006374	0.013737	0.014192	0.014276	0.015864	...	0.023751
0	0	0	0	0	...	0.003405
0	0	0	0	0	...	0.007977
0	0	0	0	0	...	0.005111
0	0	0	0	0	...	0.007724
...
0	0	0	0	0	...	0

Tahap selanjutnya, hasil dari *MaxPooling4* masuk ke *Conv5* yang memiliki 512 filter. Output dari *Conv5* menghasilkan 512 channel dengan ukuran spasial tetap 28×28 piksel. Input conv5:

Tabel 3.12 Hasil Conv5

0.006374	0.013737	0.014192	0.014276	0.015864	...	0.017021
0.010115	0.020291	0.019706	0.021364	0.020472	...	0.014262
0.006387	0.017505	0.014565	0.015637	0.014845	...	0.011784
0.003576	0.013363	0.012055	0.012038	0.011581	...	0.012778
0.003848	0.014299	0.012235	0.011709	0.012608	...	0.013386
...
0.008242	0.010736	0.010034	0.012761	0.012126	...	0.007384

Setelah itu, hasil *Conv5* melewati fungsi aktivasi *ReLU5*, yang akan mengubah semua nilai negatif menjadi nol.

Tabel 3.13 Hasil ReLU5

0.010115	0.020291	0.019706	0.021364	0.020472	...	0.017021
0.006387	0.017505	0.014565	0.015637	0.014845	...	0.014262
0.003576	0.013363	0.012055	0.012038	0.011581	...	0.011784
0.003848	0.014299	0.012235	0.011709	0.012608	...	0.012778
0.003043	0.013562	0.012682	0.013228	0.013087	...	0.013386
...
0.008242	0.010736	0.010034	0.012761	0.012126	...	0.007384

Tahap selanjutnya, hasil dari *ReLU5* masuk ke *Conv6* yang memiliki 512 filter. Output dari *Conv6* menghasilkan 512 channel dengan ukuran spasial tetap 28×28 piksel. Input conv6:

Tabel 3.14 Hasil Conv6

-0.01043	-0.00791	-0.01075	-0.01064	-0.01118	...	-0.01093
-0.01107	-0.01102	-0.01399	-0.01443	-0.01411	...	-0.01452
-0.0126	-0.01232	-0.01425	-0.01564	-0.01504	...	-0.01717
-0.01176	-0.01322	-0.01492	-0.015	-0.01484	...	-0.01647
-0.01107	-0.01252	-0.01371	-0.01428	-0.01399	...	-0.01486
...
-0.01037	-0.01139	-0.01388	-0.0131	-0.01343	...	-0.01203

Setelah itu, hasil *Conv6* melewati fungsi aktivasi *ReLU6*, yang akan mengubah semua nilai negatif menjadi nol.

Tabel 3.15 Hasil ReLU6

0	0	0	0	0	...	0
0	0	0	0	0	...	0
0	0	0	0	0	...	0
0	0	0	0	0	...	0
0	0	0	0	0	...	0
...
0	0	0	0	0	...	0

Selanjutnya, hasil dari *ReLU6* dimasukkan ke dalam *MaxPooling6* dengan kernel 2×2 dan *stride* 2, sehingga ukuran spasial berubah dari 28×28 menjadi 14×14 piksel per *channel*, dan hanya nilai maksimum dari tiap blok 2×2 yang dipertahankan.

Tabel 3.16 Hasil Max Pooling6

0	0	0	0	0	...	0
0	0	0	0	0	...	0
0	0	0	0	0	...	0
0	0	0	0	0	...	0
0	0	0	0	0	...	0
...
0	0	0	0	0	...	0

Tahap selanjutnya, hasil dari *MaxPooling6* masuk ke *Conv7* yang memiliki 64 filter. Output dari *Conv7* menghasilkan 64 channel dengan ukuran spasial tetap 14×14 piksel. Input conv7:

Tabel 3.17 Hasil Conv7

-0.00765	-0.01017	-0.01001	-0.00971	-0.00993	...	-0.01017
----------	----------	----------	----------	----------	-----	----------

-0.00978	-0.01324	-0.01274	-0.01275	-0.0126	...	-0.01303
-0.00786	-0.01029	-0.0103	-0.01019	-0.01034	...	-0.01115
-0.00813	-0.01081	-0.01036	-0.0104	-0.01013	...	-0.0108
-0.00829	-0.01074	-0.01056	-0.01019	-0.01015	...	-0.01062
...
-0.006	-0.00907	-0.00934	-0.00968	-0.0098	...	-0.01223

Setelah itu, hasil *Conv7* melewati fungsi aktivasi *ReLU7*, yang akan mengubah semua nilai negatif menjadi nol.

Tabel 3.18 Hasil Conv8

0	0	0	0	0	...	0
0	0	0	0	0	...	0
0	0	0	0	0	...	0
0	0	0	0	0	...	0
0	0	0	0	0	...	0
...
0	0	0	0	0	...	0

Tahap selanjutnya, hasil dari *ReLU7* masuk ke *Conv8* yang memiliki 64 filter. Output dari *Conv8* menghasilkan 64 channel dengan ukuran spasial tetap 14×14 piksel.

Tabel 3. 19 Hasil ReLU8

0.010135	0.008747	0.008961	0.008893	0.008869	...	0.007468
0.009073	0.006089	0.005547	0.005587	0.005708	...	0.00559
0.00976	0.007566	0.006952	0.007023	0.007032	...	0.006082
0.009613	0.007232	0.006589	0.006719	0.006869	...	0.006241
0.009397	0.007156	0.006659	0.006581	0.006801	...	0.006135
...
0.006936	0.005614	0.004743	0.004996	0.005074	...	0.005906

Setelah itu, hasil *Conv8* melewati fungsi aktivasi *ReLU8*, yang akan mengubah semua nilai negatif menjadi nol.

Tabel 3.20 Hasil ReLU8

0.010135	0.008747	0.008961	0.008893	0.008869	...	0.007468
0.009073	0.006089	0.005547	0.005587	0.005708	...	0.00559
0.00976	0.007566	0.006952	0.007023	0.007032	...	0.006082
0.009613	0.007232	0.006589	0.006719	0.006869	...	0.006241
0.009397	0.007156	0.006659	0.006581	0.006801	...	0.006135
...
0.006936	0.005614	0.004743	0.004996	0.005074	...	0.005906

Selanjutnya, hasil dari *ReLU8* dimasukkan ke dalam *MaxPooling8* dengan kernel 2×2 dan *stride* 2, sehingga ukuran spasial berubah dari 14×14 menjadi 7×7 piksel per *channel*, dan hanya nilai maksimum dari tiap blok 2×2 yang dipertahankan.

Tabel 3. 21 Hasil Max Pooling8

0.010135	0.008961	0.008869	0.008869	0.008889	0.008864	0.008278
0.00976	0.007023	0.007032	0.00697	0.007042	0.007143	0.006546
0.009532	0.006724	0.006867	0.006682	0.006867	0.006942	0.006471
0.009575	0.006838	0.007037	0.006816	0.006991	0.006853	0.006509
0.009481	0.00682	0.00701	0.006791	0.007166	0.006914	0.006474
0.009506	0.006691	0.006949	0.00696	0.00713	0.007042	0.006477
0.008815	0.006313	0.00652	0.006342	0.006598	0.006412	0.006484

Dengan demikian, output akhir dari proses ekstraksi fitur adalah tensor berdimensi ($64 \text{ channel} \times 7 \times 7$ piksel), di mana setiap piksel pada masing-masing channel merepresentasikan fitur penting dari citra masukan. Nilai-nilai piksel pada hasil akhir inilah yang disimpan dalam bentuk matriks di Excel untuk proses analisis lebih lanjut atau sebagai input bagi tahap klasifikasi.

3.1.4 *Feature Storage*

Setelah fitur berhasil diekstrak dari setiap gambar menggunakan VGG-11 Net, langkah berikutnya adalah menyimpan fitur-fitur tersebut dalam format yang terstruktur. Penyimpanan dapat dilakukan dalam bentuk file vektor seperti *xlsx*, atau dalam basis data yang mendukung penyimpanan matriks numerik. Penyimpanan yang sistematis penting untuk memastikan kemudahan dalam pemanggilan kembali data saat proses analisis.

3.1.6 Feature Analysis

Tahap analisis fitur dilakukan untuk mengevaluasi sejauh mana fitur yang telah diekstraksi menggunakan VGG-11 Net mampu merepresentasikan data secara komputasional. Evaluasi dilakukan menggunakan metode Principal Component Analysis (PCA) yang bertujuan mereduksi dimensi fitur dan memvisualisasikan distribusi data dalam ruang dua dimensi. Melalui proyeksi ke dua komponen utama, PCA membantu mengidentifikasi pola tersembunyi serta kemungkinan pengelompokan alami dalam data. Hasil visualisasi scatterplot menunjukkan bahwa fitur yang dihasilkan memiliki kemampuan dalam membedakan representasi gambar, meskipun belum mengarah langsung pada klasifikasi tingkat kerusakan bangunan. Evaluasi ini memberikan gambaran awal terhadap kualitas fitur sebelum melangkah ke tahap analisis atau klasifikasi yang lebih kompleks.

3.2 Data Preparation

Dengan menggunakan data gambar kerusakan sektor pasca bencana alam di situs data terbuka, *namely Kaggle*, Anda dapat menggunakan data langsung dari foto kamera, hasil pencarian mesin pencari *Google*, dan dari BPBD Kota Malang. Dan terdapat data kurang dari 100 data kerusakan bangunan pasca bencana alam. Tidak berfokus pada korban bencana alam dan sektor selain bangunan yang terkena dampak bencana alam.

3.3 Feature Analysis/Feature Evaluation

Evaluasi representasi fitur bertujuan untuk menganalisis kualitas fitur yang dihasilkan oleh arsitektur VGG-11 dari citra kerusakan bangunan pascabencana.

Proses ini tidak menggunakan pendekatan klasifikasi karena tidak ada label kelas eksplisit yang disediakan. Oleh karena itu, evaluasi dilakukan menggunakan metode *Principal Component Analysis* (PCA) yang bersifat *unsupervised* untuk melihat struktur dan distribusi data fitur secara alami.

PCA digunakan untuk mereduksi dimensi dari vektor fitur berdimensi tinggi menjadi dua komponen utama, yaitu PC1 dan PC2, yang menjelaskan sebagian besar variasi data. Dengan mereduksi dimensi ke ruang dua dimensi, pola-pola distribusi dari fitur dapat divisualisasikan dan diamati secara lebih jelas. Proyeksi hasil PCA divisualisasikan dalam bentuk *scatter plot* untuk mengetahui apakah data fitur menunjukkan kecenderungan pengelompokan tertentu berdasarkan karakteristik visual dari gambar.

Melalui visualisasi ini, dapat diamati sejauh mana fitur yang dihasilkan oleh VGG-11 mampu membedakan citra berdasarkan tingkat kerusakannya, meskipun tanpa label eksplisit. Jika citra dengan karakteristik serupa cenderung berkelompok secara alami dalam ruang PCA, maka dapat disimpulkan bahwa representasi fitur memiliki kualitas yang baik dalam menangkap informasi penting dari citra masukan.

3.3.1 *Principal Component Analysis* (PCA)

Principal Component Analysis (PCA) merupakan teknik statistik yang digunakan untuk mereduksi dimensi data sambil mempertahankan informasi yang paling signifikan. Dalam penelitian ini, PCA diterapkan untuk menyederhanakan representasi fitur yang dihasilkan oleh VGG-11 Net menjadi bentuk dua dimensi, sehingga memungkinkan visualisasi pola dan pengelompokan data secara lebih

jelas. 31 Secara matematis, PCA menghitung *eigenvalue* dan *eigenvector* dari matriks kovarians

$$\Sigma = \frac{1}{n} \sum_{\{i=1\}}^{\{n\}} (x_i - \mu)(x_i - \mu)^T \quad (3.9)$$

Dimana:

- a) x_i : vektor fitur ke-i
- b) μ : rata-rata semua vektor fitur
- c) Σ : matriks kovarians
- d) v : *eigenvector* (*principal component*)
- e) λ : *eigenvalue* (besarnya variasi yang dijelaskan)

Komponen utama dipilih berdasarkan nilai *explained variance ratio* tertinggi untuk menghasilkan representasi data yang tetap informatif meskipun dimensinya dikurangi.

3.3.2 Proses Evaluasi

Proses evaluasi dilakukan melalui gabungan antara PCA. Langkah-langkah evaluasi fitur yang dilakukan dalam penelitian ini adalah sebagai berikut:

1. Ekstraksi Fitur

Dataset gambar kerusakan bangunan diproses melalui VGG-11 Net untuk menghasilkan vektor fitur. Vektor ini disimpan dalam bentuk numerik sebagai representasi karakteristik dari masing-masing gambar.

2. Reduksi Dimensi dengan PCA

Vektor fitur hasil ekstraksi kemudian diproses menggunakan PCA untuk direduksi menjadi dua komponen utama. Reduksi ini dilakukan agar pola distribusi data dapat divisualisasikan secara lebih jelas dan dianalisis secara efisien.

BAB IV

UJI DAN PEMBAHASAN

4.1 Data Pengujian

Langkah pertama sebelum melakukan pengujian adalah mempersiapkan data yang akan digunakan dalam penelitian. Seperti yang telah dijelaskan pada Sub bab 3.2, dataset yang digunakan dalam penelitian ini bersumber dari situs data terbuka, *namely Kaggle*, hasil pencarian mesin pencari *Google*, dan dari BPBD Kota Malang. Jumlah data yang digunakan adalah 75 gambar bangunan yang mengalami kerusakan. Data citra ini kemudian masuk ke dalam tahap *preprocessing*, yaitu *resizing*, normalisasi, dan augmentasi data. Setelah melewati tahap *preprocessing*, setiap gambar akan dilakukan ekstraksi fitur menggunakan metode VGG-11 Net. VGG-11 Net digunakan untuk mengekstraksi fitur visual penting dari gambar, seperti tepi, tekstur, dan bentuk struktur pada gambar. arsitektur itu terdiri dari 8 lapisan, termasuk beberapa lapisan konvolusi. Hasil ekstraksi fitur yang dilakukan pada 1 data gambar berupa matriks data dengan total 7 kolom dan 448 baris, di mana setiap baris mewakili sebuah data gambar dan setiap kolom merepresentasikan fitur yang dihasilkan dari model. Untuk mempermudah pemahaman dan analisis data fitur hasil ekstraksi, digunakan metode PCA. Teknik ini mereduksi dimensi data menjadi beberapa komponen utama yang paling berkontribusi, sehingga memperjelas pola dalam data dan menyederhanakan proses visualisasi maupun pengolahan selanjutnya.

Tabel 4.1 Hasil 1 Sample Ekstraksi Fitur

Fitur 1	Fitur 2	Fitur 3	Fitur 4	Fitur 5	Fitur 6	Fitur 7
0.010135	0.008961	0.008869	0.008869	0.008889	0.008864	0.008278
0.00976	0.007023	0.007032	0.00697	0.007042	0.007143	0.006546
0.009532	0.006724	0.006867	0.006682	0.006867	0.006942	0.006471
0.009575	0.006838	0.007037	0.006816	0.006991	0.006853	0.006509
0.009481	0.00682	0.00701	0.006791	0.007166	0.006914	0.006474
0.009506	0.006691	0.006949	0.00696	0.00713	0.007042	0.006477
0.008815	0.006313	0.00652	0.006342	0.006598	0.006412	0.006484

Tabel 4.1 diatas adalah 7 baris pertama hasil ekstraksi fitur dari total 3.136 fitur, yang terdiri dari 7 kolom dan 448 baris. Dan salah satu channel dari 64 channel hasil ekstraksi fitur.

4.2 Skenario Pengujian

Skenario pengujian dalam penelitian ini dilakukan untuk mengevaluasi efektivitas pendekatan representasi fitur menggunakan kombinasi antara ekstraksi fitur oleh VGG-11 dan reduksi dimensi melalui *Principal Component Analysis* (PCA). Tujuan dari pengujian ini adalah untuk memahami sejauh mana vektor fitur yang dihasilkan mampu membedakan citra kerusakan bangunan berdasarkan kemiripan visual, tanpa menggunakan label atau metode klasifikasi.

PCA digunakan sebagai metode utama untuk mereduksi dimensi dari fitur yang dihasilkan oleh VGG-11 Net agar pola distribusi data menjadi lebih mudah dipahami dan divisualisasikan. Meskipun jumlah fitur tidak terlalu tinggi, reduksi dimensi tetap penting untuk menyederhanakan analisis dan meningkatkan interpretabilitas data. Dalam penelitian ini, PCA dengan dua komponen utama

digunakan untuk memproyeksikan data ke dalam ruang dua dimensi. Proyeksi ini memungkinkan visualisasi distribusi fitur secara lebih jelas dan membantu dalam mengevaluasi kualitas representasi fitur yang dihasilkan oleh model.

Tabel 4.2 Skenario dan Komponen

No	Skenario	Komponen yang Digunakan
1.	Skenario 1	PC1 dan PC2

Skenario pengujian dilakukan dengan memproyeksikan data ke dalam ruang dua dimensi berdasarkan dua komponen utama hasil PCA, yaitu PC1 dan PC2. PC1 dan PC2 adalah dua komponen utama yang menangkap variasi terbesar dalam data. PC1 memiliki kontribusi paling besar, diikuti oleh PC2 yang bersifat ortogonal terhadap PC1. Dengan menggunakan PC1 dan PC2, data dapat diproyeksikan ke dalam ruang dua dimensi tanpa kehilangan terlalu banyak informasi penting. Hal ini sangat membantu dalam proses visualisasi dan identifikasi pola tersembunyi pada data hasil ekstraksi fitur. Hanya dua komponen ini yang digunakan karena komponen utama ketiga (PC3) memiliki nilai *eigenvalue* dan *explained variance ratio* sebesar nol, yang menunjukkan bahwa tidak ada informasi tambahan yang signifikan yang dapat dijelaskan oleh komponen tersebut. *Scatter plot* dari hasil proyeksi PC1 dan PC2 digunakan untuk mengamati sejauh mana kedua komponen ini mampu memisahkan data. Visualisasi ini membantu mengidentifikasi pola distribusi fitur yang paling jelas dan bermakna, serta menjadi dasar dalam pemilihan representasi visual terbaik untuk dianalisis lebih lanjut pada tahap pembahasan.

4.3 Hasil Uji Coba

Setelah dilakukan proses ekstraksi fitur dengan VGG-11 Net dan reduksi dimensi menggunakan PCA, tahap selanjutnya adalah melakukan pengujian terhadap hasil representasi data untuk mengevaluasi sejauh mana komponen utama mampu menggambarkan distribusi fitur secara jelas. Pengujian ini bertujuan untuk mengetahui kombinasi komponen utama yang dapat memberikan visualisasi terbaik terhadap fitur yang dihasilkan, sehingga pola atau kelompok data yang serupa dapat diamati dengan lebih mudah.

4.3.1 Dua Komponen Utama Hasil PCA

Dari proses PCA yang dilakukan terhadap 1 data gambar berupa matriks hasil ekstraksi fitur, diperoleh dua komponen utama dengan nilai *Explained Variance Ratio* tertinggi. Komponen ini menjadi dasar representasi fitur dalam dimensi yang lebih rendah untuk memudahkan visualisasi dan pengelompokan.

Tabel 4.3 Hasil PCA

No.	Komponen Utama	<i>Eigenvalue</i>	<i>Explained Variance Ratio</i> (%)
1.	PC1	1844.6322	86.54%
2.	PC2	286.8678	13.46%

```

Eigenvalues:
PC1: 1844.6322
PC2: 286.8678

Explained Variance Ratio:
PC1: 86.54%
PC2: 13.46%

```

Gambar 4.1 Hasil *Eigenvalues* dan *Explained* PCA

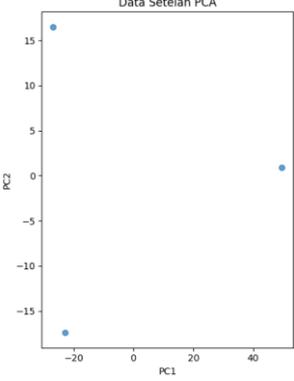
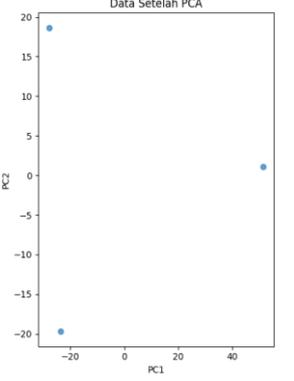
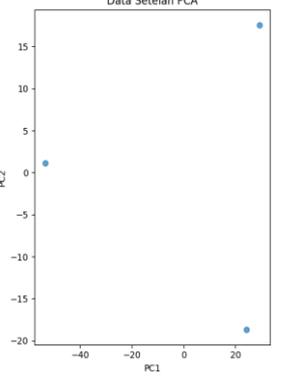
Berdasarkan tabel di atas, terlihat bahwa PC1 memberikan kontribusi terbesar terhadap representasi data dengan nilai *Explained Variance Ratio* sebesar 86,31%, disusul oleh PC2 sebesar 13,69%. Total kontribusi kumulatif dari kedua komponen utama ini mencapai 100%, yang menunjukkan bahwa hampir seluruh informasi dalam data fitur dapat direpresentasikan secara efektif hanya dengan dua dimensi utama tersebut.

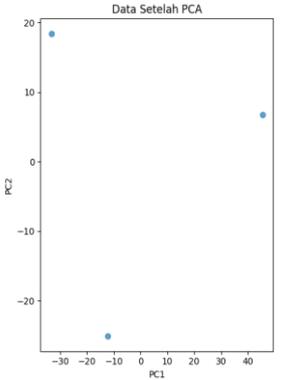
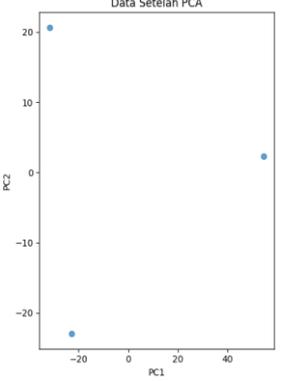
4.4 Pembahasan

Visualisasi hasil proyeksi ke dalam ruang dua dimensi (PC1 vs PC2) menunjukkan bahwa data citra terbagi secara alami ke dalam tiga kelompok yang terpisah. Ketiga kelompok ini mengindikasikan adanya perbedaan pola dalam fitur visual yang ditangkap oleh model VGG-11, meskipun tidak dilakukan pelabelan sebelumnya.

Pemisahan antar kelompok yang tampak jelas ini menunjukkan bahwa kombinasi antara ekstraksi fitur VGG-11 dan reduksi dimensi PCA berhasil merepresentasikan informasi penting dari citra dengan baik. Pola-pola distribusi fitur dari gambar yang memiliki karakteristik visual serupa cenderung dikelompokkan berdekatan dalam ruang PCA. Hal ini menunjukkan bahwa model VGG-11 mampu menangkap struktur visual mendalam dari citra kerusakan bangunan, dan PCA berhasil mengekstraksi struktur tersebut ke dalam ruang fitur berdimensi rendah yang informatif. Tabel 4.4 menampilkan 5 hasil evaluasi PCA atau grafik *scatter plot* yang membentuk tiga kelompok utama yang terpisah secara visual.

Tabel 4.4 Hasil Scatter Plot PCA

No.	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio</i> %	Hasil Evaluasi PCA (<i>Scatter plot</i>)
1.		<p>Eigenvalues: PC1: 1844.6322 PC2: 286.8678</p> <p>Explained Variance Ratio: PC1: 86.54% PC2: 13.46%</p>	
2.		<p>Eigenvalues: PC1: 1984.7206 PC2: 367.2794</p> <p>Explained Variance Ratio: PC1: 84.38% PC2: 15.62%</p>	
3.		<p>Eigenvalues: PC1: 2151.0028 PC2: 328.4972</p> <p>Explained Variance Ratio: PC1: 86.75% PC2: 13.25%</p>	

No.	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio</i> %	Hasil Evaluasi PCA (<i>Scatter plot</i>)
4.		<p>Eigenvalues: PC1: 1665.7038 PC2: 506.2962</p> <p>Explained Variance Ratio: PC1: 76.69% PC2: 23.31%</p>	
5.		<p>Eigenvalues: PC1: 2240.7496 PC2: 478.7504</p> <p>Explained Variance Ratio: PC1: 82.40% PC2: 17.60%</p>	

Berdasarkan tabel diatas yang menampilkan 5 perbandingan antara gambar asli bangunan pasca bencana dan hasil visualisasi PCA dalam bentuk *scatter plot*, terlihat adanya pembentukan tiga kelompok utama pada ruang proyeksi dua dimensi. Meskipun tidak secara eksplisit merepresentasikan jenis kerusakan bangunan, distribusi ini menunjukkan bahwa fitur yang diekstraksi menggunakan VGG-11 memiliki kemampuan untuk membedakan pola visual yang berbeda. Proyeksi menggunakan PCA membantu menyederhanakan dimensi data, sehingga struktur atau pola laten dalam data dapat diamati secara lebih jelas, meskipun belum dilakukan proses klasifikasi lebih lanjut.

4.5 Integrasi Islam

Dalam penelitian ini, proses ekstraksi fitur, dilakukan identifikasi terhadap bagian-bagian penting dari suatu gambar yang merepresentasikan karakteristik visual utamanya. Hal ini sejalan dengan prinsip dalam Islam mengenai pentingnya mengambil pelajaran dan makna dari segala ciptaan Allah SWT. Dalam Al-Qur'an, Allah berfirman pada QS. Fussilat Ayat 53:

سُرِّيهِمْ آيَاتِنَا فِي الْأَفَاقِ وَبِآنْفُسِهِمْ حَتَّىٰ يَتَبَيَّنَ لَهُمْ أَنَّهُ الْحَقُّ أَوَلَمْ يَكْفِ بِرَبِّكَ أَنَّهُ عَلَىٰ كُلِّ شَيْءٍ شَهِيدٌ

“Kami akan memperlihatkan kepada mereka tanda-tanda (kebesaran) Kami di segenap penjuru dan pada diri mereka sendiri sehingga jelaslah bagi mereka bahwa (Al-Qur'an) itu adalah benar. Tidak cukupkah (bagi kamu) bahwa sesungguhnya Tuhanmu menjadi saksi atas segala sesuatu?. (QS. Fussilat: 53)”

Ayat tersebut menunjukkan bahwa manusia dituntut untuk melakukan proses “ekstraksi makna” dari tanda-tanda (ayat-ayat kauniyah) yang Allah sebar di alam semesta. Dalam konteks ini, proses ekstraksi fitur pada gambar dapat dimaknai sebagai upaya manusia dalam membaca, memahami, dan menyaring informasi yang tersembunyi di balik data visual (As-Suyuthi & Al-Mahalli, 2003). Sama halnya seperti seorang mukmin yang diperintahkan untuk menggunakan akalinya agar dapat menangkap hikmah dari setiap kejadian di dunia.

Proses evaluasi dari pengelompokan dalam Islam terdapat pada prinsip dasar bahwa setiap amal perbuatan akan dipertanggungjawabkan dan dikelompokkan berdasarkan niat dan kualitasnya. Dalam konteks ini, evaluasi pengelompokan tidak hanya melihat hasil dari amal tersebut, tetapi juga pada niat

yang menjadi dasar dari setiap tindakan. Sebagaimana diterangkan dalam hadis berikut yang diriwayatkan Bukhari dan Muslim.

إِنَّمَا الْأَعْمَالُ بِالنِّيَّاتِ وَإِنَّمَا لِكُلِّ امْرِئٍ مَّا نَوَىٰ فَمَنْ كَانَتْ هِجْرَتُهُ إِلَى اللَّهِ وَرَسُولِهِ فَهِجْرَتُهُ إِلَى اللَّهِ وَرَسُولِهِ وَمَنْ كَانَتْ هِجْرَتُهُ لِدُنْيَا يُصَيِّبُهَا أَوْ امْرَأَةٍ يَنْكِحُهَا فَهِجْرَتُهُ إِلَى مَا هَاجَرَ إِلَيْهِ

“Sesungguhnya setiap amalan tergantung pada niatnya. Setiap orang akan mendapatkan apa yang ia niatkan. Siapa yang hijrahnya karena Allah dan Rasul-Nya, maka hijrahnya untuk Allah dan Rasul-Nya. Siapa yang hijrahnya karena mencari dunia atau karena wanita yang dinikahinya, maka hijrahnya kepada yang ia tuju. (HR. Bukhari dan Muslim)”

Hadis ini menegaskan bahwa niat menjadi faktor penentu dalam penilaian amal (Mahfuz et al., 2020). Oleh karena itu, dalam evaluasi pengelompokan, tidak hanya hasil atau tindakan yang terlihat yang dipertimbangkan, tetapi juga tujuan dan motivasi di balik tindakan tersebut. Dalam Islam, amal yang dilakukan dengan niat yang baik dan tulus akan dikelompokkan dalam kategori yang baik, sementara amal yang dilakukan dengan niat yang buruk akan dikelompokkan secara berbeda. Proses ini mengajarkan bahwa kualitas setiap individu tidak hanya diukur dari apa yang mereka lakukan, tetapi juga dari bagaimana mereka melakukannya, yang sangat bergantung pada niat dan tujuan mereka.

Berdasarkan hasil penelitian ini, Dalam ajaran Islam, setiap individu akan dikelompokkan berdasarkan amal dan niatnya, sebagaimana disebutkan dalam Al-Qur'an dan hadis. Evaluasi pengelompokan dalam Islam tidak hanya mempertimbangkan hasil perbuatan, tetapi juga menilai niat yang melatarbelakangi tindakan tersebut. Prinsip ini sejalan dengan proses evaluasi dalam klusterisasi, di mana setiap kelompok dianalisis berdasarkan karakteristik khusus yang membedakannya dari kelompok lain. Dengan demikian, evaluasi dalam Islam

maupun dalam penelitian sama-sama menekankan pentingnya pemahaman yang mendalam terhadap dasar tindakan dan ciri khas masing-masing individu atau kelompok.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan yang telah dilakukan, diperoleh kesimpulan sebagai berikut:

1. Metode VGG-11 Net berhasil digunakan untuk mengekstraksi fitur visual penting dari gambar bangunan yang mengalami kerusakan, menghasilkan representasi numerik yang dapat diolah dan dianalisis lebih lanjut.
2. Principal Component Analysis (PCA) mampu mereduksi dimensi fitur menjadi dua komponen utama (PC1 dan PC2) yang secara kumulatif menjelaskan 100% variasi data, dengan kontribusi sebesar 86,31% pada PC1 dan 13,69% pada PC2.
3. Visualisasi hasil PCA menunjukkan adanya tiga kelompok utama dalam ruang dua dimensi, yang mengindikasikan bahwa fitur yang dihasilkan mampu membedakan pola visual meskipun tanpa pelabelan eksplisit. Hal ini menunjukkan kualitas representasi fitur dari model VGG-11 yang baik.

5.2 Saran

Dalam penelitian ini, peneliti menyadari bahwa meskipun penelitian yang dilakukan telah memberikan hasil yang signifikan, masih ada beberapa aspek yang perlu ditingkatkan untuk memperbaiki akurasi dan efektivitas sistem. Berdasarkan temuan yang diperoleh, berikut beberapa saran yang dapat dipertimbangkan untuk penelitian selanjutnya:

1. Pengembangan selanjutnya dapat mempertimbangkan penggunaan metode klasifikasi untuk mengidentifikasi tingkat kerusakan bangunan secara eksplisit berdasarkan hasil ekstraksi fitur yang telah diperoleh.
2. Jumlah dataset perlu diperluas agar hasil representasi dan analisis fitur menjadi lebih general dan robust dalam berbagai kondisi gambar.
3. Penelitian lanjutan dapat melakukan perbandingan arsitektur deep learning lain seperti ResNet, DenseNet, atau EfficientNet untuk mengetahui efektivitas model terhadap jenis data yang berbeda.
4. Integrasi dengan sistem tanggap darurat atau decision support system berbasis AI dapat dipertimbangkan agar hasil penelitian ini memiliki dampak lebih luas secara praktis.

DAFTAR PUSTAKA

- Ali, N. H., Abdullah, A. R., Saad, N. M., Muda, A. S., & Noor, E. E. M. (2024). Automated Classification of Collateral Circulation for Ischemic Stroke in Cone-Beam CT Images Using VGG11: A Deep Learning Approach. *BioMedInformatics*, 4(3), 1692–1702. <https://doi.org/10.3390/biomedinformatics4030091>
- As-Suyuthi, J., & Al-Mahalli, J. (2003). Tafsir jalalain. *Surabaya: Imaratullah*.
- Fachrezzy, I. (n.d.). *IMPLEMENTASI ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM (ANFIS) UNTUK DETEKSI OTOMATIS JENIS BUAH BERDASARKAN CITRA WARNA DAN BENTUK MENGGUNAKAN MATLAB TUGAS AKHIR*.
- Kumar, S., & Kumar, H. (2023). Classification of COVID-19 X-ray images using transfer learning with visual geometrical groups and novel sequential convolutional neural networks. *MethodsX*, 11, 102295. <https://doi.org/10.1016/j.mex.2023.102295>
- Mahfuz, A., Husti, I., & Alfiah, A. (2020). HADIS TENTANG NIAT DAN KORELASINYA TERHADAP MOTIVASI BAGI PESERTA DIDIK. *PERADA*, 3(2), 101. <https://doi.org/10.35961/perada.v3i2.230>
- Noviana, R., & Madenda, S. (2014). *TRANSFORMASI WATERSHED UNTUK EKSTRAKSI FITUR NODUL KANKER CITRA CT-SCAN PARU*.
- Nurhayati, O. D. (2020). Pengolahan Citra untuk Identifikasi Jenis Telur Ayam Lehorn dan Omega-3 Menggunakan K-Mean Clustering dan Principal Component Analysis. *JURNAL SISTEM INFORMASI BISNIS*, 10(1), 84–93. <https://doi.org/10.21456/vol10iss1pp84-93>
- Raja, J., Shanmugam, P., & Pitchai, R. (2021). An Automated Early Detection of Glaucoma using Support Vector Machine Based Visual Geometry Group 19 (VGG-19) Convolutional Neural Network. *Wireless Personal Communications*, 118(1), 523–534. <https://doi.org/10.1007/s11277-020-08029-z>
- Sujjada, A., Yudono, M. A. S., Ridha, F. F., Kuspranoto, A. H., & Saraswati, I. (2025). *Ekstraksi Ciri Berbasis GLRLM untuk Klasifikasi Katarak pada Pembuluh Darah dan OpticDisc pada Citra Fundus Smartphone*. 7(1).
- Akbar, A. T., Saifullah, S., & Prapcoyo, H. (2024). Klasifikasi Ekspresi Wajah Menggunakan Convolutional Neural network. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 11(6), 1399–1412. <https://doi.org/10.25126/jtiik.1168888>
- Almais, A. T. W., Susilo, A., Naba, A., Sarosa, M., Crysdiyan, C., Tazi, I., Hariyadi, M. A., Muslim, M. A., Basid, P. M. N. S. A., Arif, Y. M., Purwanto, M. S., Parwatiningsy, D., Supriyono, & Wicaksono, H. (2023). Principal Component

Analysis-Based Data Clustering for Labeling of Level Damage Sector in Post-Natural Disasters. *IEEE Access*, 11, 74590–74601. <https://doi.org/10.1109/ACCESS.2023.3275852>

Almais, A. T. W., Susilo, A., Naba, A., Sarosa, M., Juwono, A. M., Crysdiyan, C., Muslim, M. A., & Wicaksono, H. (2024). Characterization of Structural Building Damage in Post-Disaster Using GLCM-PCA Analysis Integration. *IEEE Access*, 12, 146190–146201. <https://doi.org/10.1109/ACCESS.2024.3469637>

Alshazly, H., Linse, C., Barth, E., & Martinetz, T. (2019). Ensembles of Deep Learning Models and Transfer Learning for Ear Recognition. *Sensors*, 19(19), 4139. <https://doi.org/10.3390/s19194139>

Arrhythmia Classification Using the Deep Learning Visual Geometry Group. (n.d.).

Bibi, R., Saeed, Y., Zeb, A., Ghazal, T. M., Rahman, T., Said, R. A., Abbas, S., Ahmad, M., & Khan, M. A. (2021). Edge AI-Based Automated Detection and Classification of Road Anomalies in VANET Using Deep Learning. *Computational Intelligence and Neuroscience*, 2021(1), 6262194. <https://doi.org/10.1155/2021/6262194>

Dastres, R., & Soori, M. (n.d.). *Advanced Image Processing Systems*.

Haksoro, E. I., & Setiawan, A. (2021). Pengenalan Jamur Yang Dapat Dikonsumsi Menggunakan Metode Transfer Learning Pada Convolutional Neural network. *Jurnal ELTIKOM*, 5(2), 81–91. <https://doi.org/10.31961/eltikom.v5i2.428>

Hasnain, M., Pasha, M. F., Ghani, I., Imran, M., Alzahrani, M. Y., & Budiarto, R. (2020). Evaluating Trust Prediction and Confusion Matrix Measures for Web Services Ranking. *IEEE Access*, 8, 90847–90861. <https://doi.org/10.1109/ACCESS.2020.2994222>

Huang, Z., Shen, X., Tian, X., Li, H., Huang, J., & Hua, X.-S. (2021). Spatio-Temporal Inception Graph Convolutional networks for Skeleton-Based Action Recognition (No. arXiv:2011.13322). *arXiv*. <https://doi.org/10.48550/arXiv.2011.13322>

Kattenborn, T., Leitloff, J., Schiefer, F., & Hinz, S. (2021). Review on Convolutional Neural networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 24–49. <https://doi.org/10.1016/j.isprsjprs.2020.12.010>

Kaya, V., & Akgül, İ. (2022). Classification of skin cancer using VGG model structures. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. <https://doi.org/10.17714/gumusfenbil.1069894>

Khan, A., Sohail, A., Zahoor, U., & Qureshi, A. S. (2020). A Survey of the Recent Architectures of Deep Convolutional Neural networks. *Artificial Intelligence Review*, 53(8), 5455–5516. <https://doi.org/10.1007/s10462-020-09825-6>

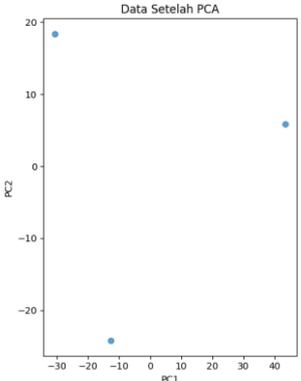
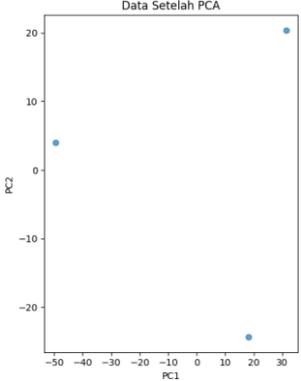
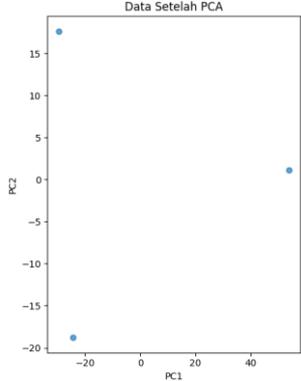
- Melinda, M., Oktiana, M., Nurdin, Y., Pujiati, I., Irhamsyah, M., & Basir, N. (2023). Performance of shuffle Net and VGG-19 Architectural Classification Models for Face Recognition in Autistic Children. *International Journal on Advanced Science, Engineering and Information Technology*, 13(2), 674–680. <https://doi.org/10.18517/ijaseit.13.2.18274>
- Naeem, M. Z., Rustam, F., Mehmood, A., Mui-zzud-din, Ashraf, I., & Choi, G. S. (2022). Classification of movie reviews using term frequency-inverse document frequency and optimized machine learning algorithms. *PeerJ Computer Science*, 8, e914. <https://doi.org/10.7717/peerj-cs.914>
- Rahman, Md. M., Islam, Md. S., Sassi, R., & Aktaruzzaman, Md. (2019). Convolutional neural networks performance comparison for handwritten Bengali numerals recognition. *SN Applied Sciences*, 1(12), 1660. <https://doi.org/10.1007/s42452-019-1682-y>
- Sarhan, M., Layeghy, S., Moustafa, N., Gallagher, M., & Portmann, M. (2024). Feature extraction for machine learning-based intrusion detection in IoT networks. *Digital Communications and networks*, 10(1), 205–216. <https://doi.org/10.1016/j.dcan.2022.08.012>
- Seandrio, A. L., Pratomo, A. H., & Florestiyanto, M. Y. (2021). Implementation of Convolutional Neural network (CNN) in Facial Expression Recognition. *Telematika*, 18(2), 211. <https://doi.org/10.31315/telematika.v18i2.4823>
- Singh, P. (2023). Systematic review of data-centric approaches in artificial intelligence and machine learning. *Data Science and Management*, 6(3), 144–157. <https://doi.org/10.1016/j.dsm.2023.06.001>
- Souza, M. D., Prabhu, G. A., Kumara, V., & Chaithra, K. M. (2024). Early: A novel transfer learning approach with VGG11 and Efficient for early-stage breast cancer detection. *International Journal of System Assurance Engineering and Management*, 15(8), 4018–4031. <https://doi.org/10.1007/s13198-024-02408-6>
- Susanty, M., Fadillah, R. Z., & Irawan, A. (2021). Model Penerjemah Bahasa Isyarat Indonesia (BISINDO) Menggunakan Pendekatan Transfer Learning. *PETIR*, 15(1), 1–9. <https://doi.org/10.33322/petir.v15i1.1289>
- Tariq, M., Hayat, Y., Hussain, A., Tariq, A., & Rasool, S. (2024). Principles and Perspectives in Medical Diagnostic Systems Employing Artificial Intelligence (AI) Algorithms.
- Yang, R., & Yu, Y. (2021). Artificial Convolutional Neural network in Object Detection and Semantic Segmentation for Medical Imaging Analysis. *Frontiers in Oncology*, 11, 638182. <https://doi.org/10.3389/fonc.2021.638182>

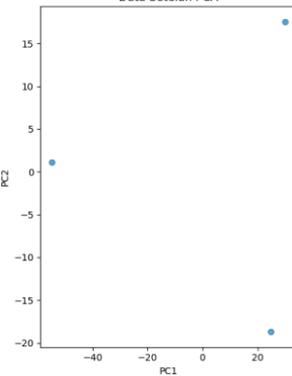
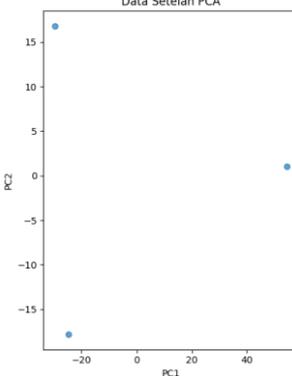
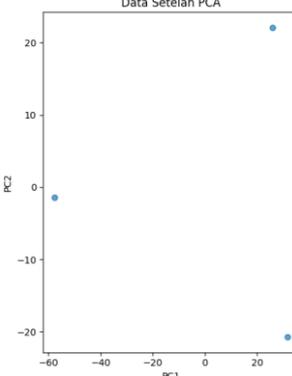
- Zebari, R., Abdulazeez, A., Zeebaree, D., Zebari, D., & Saeed, J. (2020). A Comprehensive Review of Dimensionality Reduction Techniques for Feature Selection and Feature Extraction. *Journal of Applied Science and Technology Trends*, 1(1), 56–70. <https://doi.org/10.38094/jastt1224>
- Zhou, Y., Wei, X., & Wei, J. (2021). An Improved Face Liveness Detection Algorithm Based on Deep Convolution Neural network. 2021 33rd Chinese Control and Decision Conference (CCDC), 1839–1844. <https://doi.org/10.1109/CCDC52312.2021.9601431>
- Zhu, S., Voigt, T., Ko, J., & Rahimian, F. (2024). On-device Training: A First Overview on Existing Systems. *ACM Transactions on Sensor networks*, 20(6), 1–39. <https://doi.org/10.1145/3696003>
- Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H., & He, Q. (2020). A Comprehensive Survey on Transfer Learning (No. arXiv:1911.02685). arXiv. <https://doi.org/10.48550/arXiv.1911.02685>

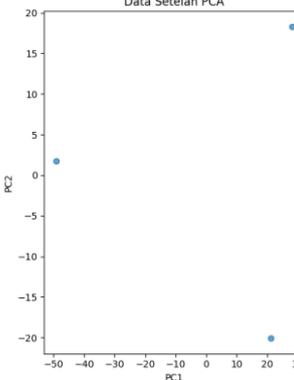
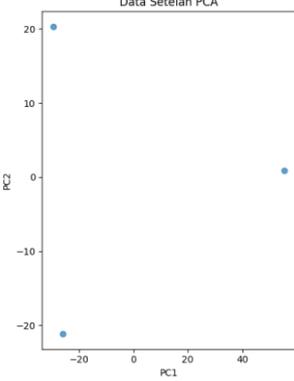
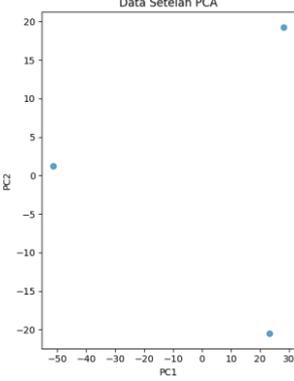
LAMPIRAN

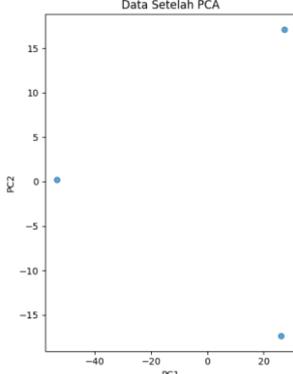
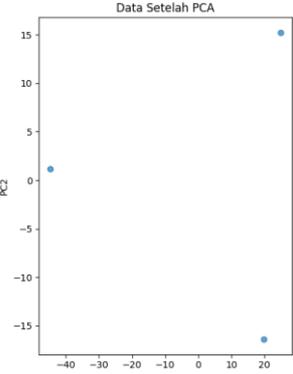
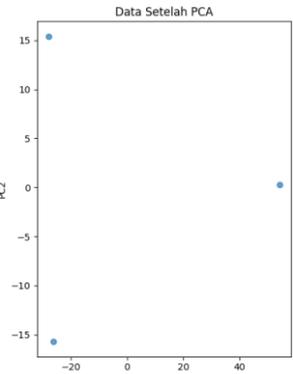
Lampiran 1

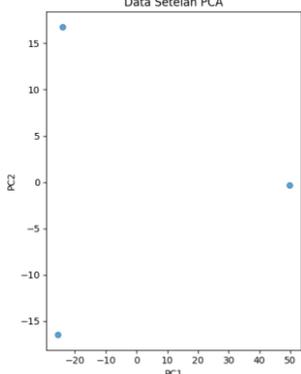
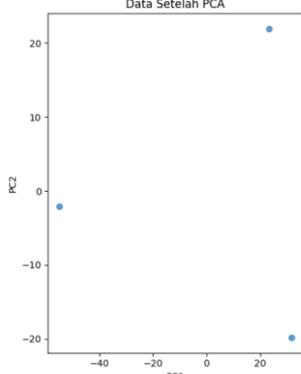
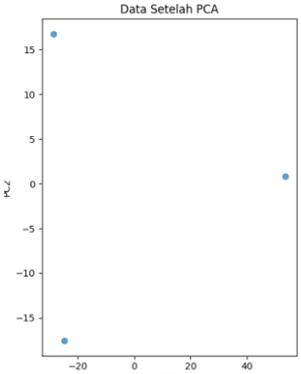
Data hasil Eigenvalues dan Explained Variance Ratio (EVR) pada setiap dataset.

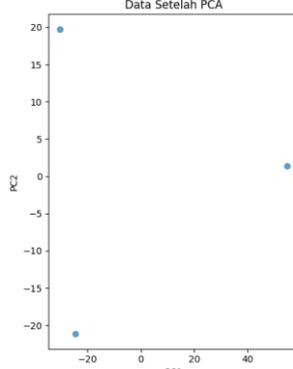
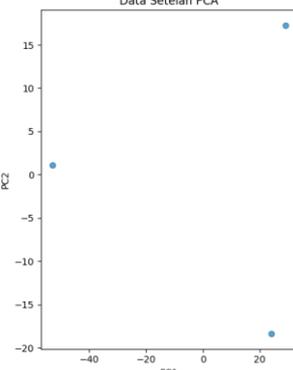
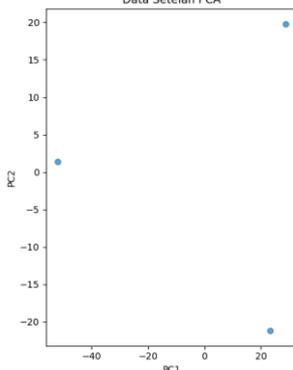
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
1.		<p>Eigenvalues: PC1: 1493.8486 PC2: 477.1514</p> <p>Explained Variance Ratio: PC1: 75.79% PC2: 24.21%</p>	
2.		<p>Eigenvalues: PC1: 1880.4175 PC2: 510.5825</p> <p>Explained Variance Ratio: PC1: 78.65% PC2: 21.35%</p>	
3.		<p>Eigenvalues: PC1: 2188.5833 PC2: 331.4167</p> <p>Explained Variance Ratio: PC1: 86.85% PC2: 13.15%</p>	

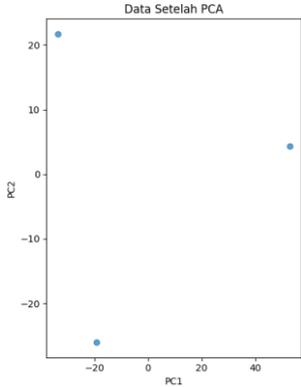
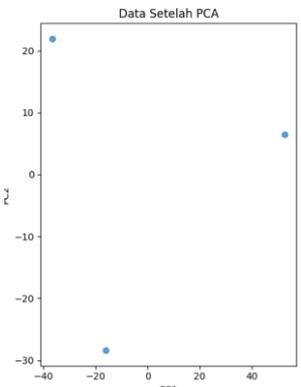
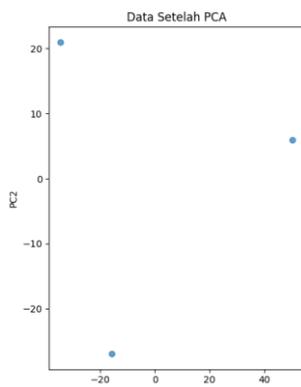
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
4.		<p>Eigenvalues: PC1: 2257.4189 PC2: 328.5811</p> <p>Explained Variance Ratio: PC1: 87.29% PC2: 12.71%</p>	
5.		<p>Eigenvalues: PC1: 2220.4271 PC2: 299.5729</p> <p>Explained Variance Ratio: PC1: 88.11% PC2: 11.89%</p>	
6.		<p>Eigenvalues: PC1: 2495.3511 PC2: 458.1489</p> <p>Explained Variance Ratio: PC1: 84.49% PC2: 15.51%</p>	

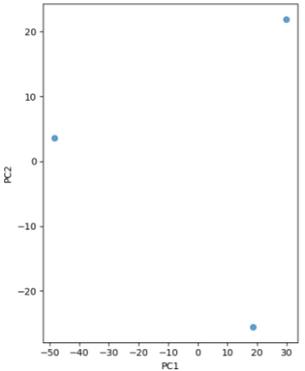
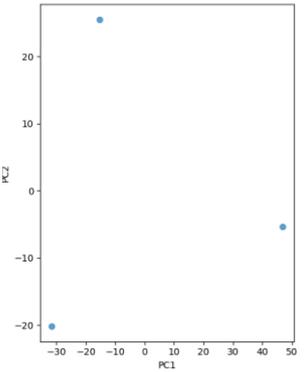
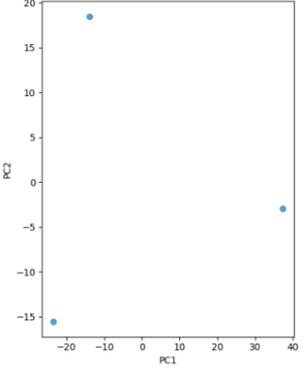
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
7.		<p>Eigenvalues: PC1: 1830.9385 PC2: 369.5615</p> <p>Explained Variance Ratio: PC1: 83.21% PC2: 16.79%</p>	
8.		<p>Eigenvalues: PC1: 2303.8085 PC2: 429.1915</p> <p>Explained Variance Ratio: PC1: 84.30% PC2: 15.70%</p>	
9.		<p>Eigenvalues: PC1: 1988.3910 PC2: 395.1090</p> <p>Explained Variance Ratio: PC1: 83.42% PC2: 16.58%</p>	

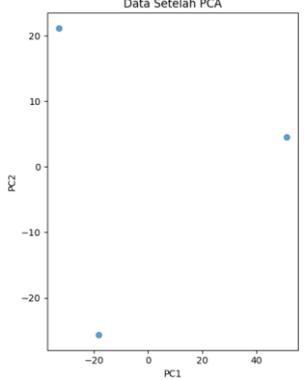
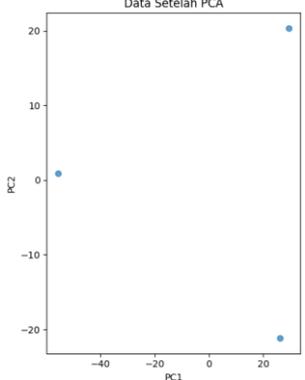
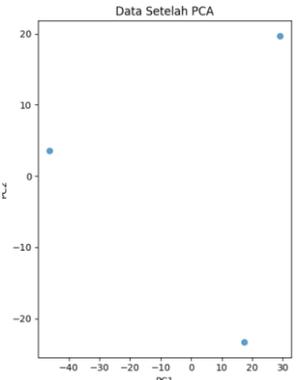
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
10.		<p>Eigenvalues: PC1: 2140.9406 PC2: 296.5594</p> <p>Explained Variance Ratio: PC1: 87.83% PC2: 12.17%</p>	
11.		<p>Eigenvalues: PC1: 1503.3301 PC2: 250.1699</p> <p>Explained Variance Ratio: PC1: 85.73% PC2: 14.27%</p>	
12.		<p>Eigenvalues: PC1: 2210.8942 PC2: 241.6058</p> <p>Explained Variance Ratio: PC1: 90.15% PC2: 9.85%</p>	

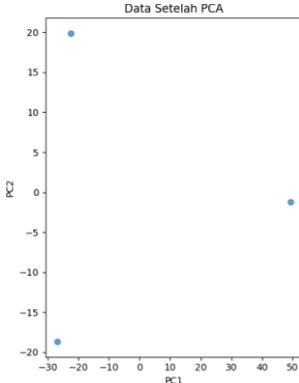
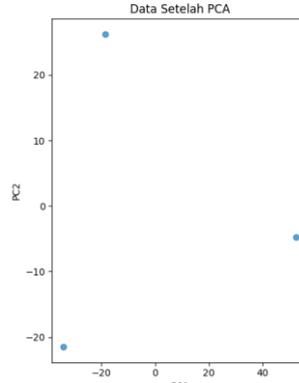
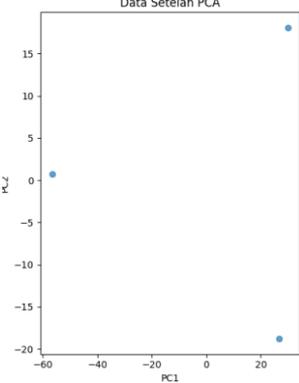
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
13.		<p>Eigenvalues: PC1: 1856.1288 PC2: 275.3712</p> <p>Explained Variance Ratio: PC1: 87.08% PC2: 12.92%</p>	 <p>Data Setelah PCA</p>
14.		<p>Eigenvalues: PC1: 2271.1827 PC2: 439.3173</p> <p>Explained Variance Ratio: PC1: 83.79% PC2: 16.21%</p>	 <p>Data Setelah PCA</p>
15.		<p>Eigenvalues: PC1: 2152.6088 PC2: 293.8912</p> <p>Explained Variance Ratio: PC1: 87.99% PC2: 12.01%</p>	 <p>Data Setelah PCA</p>

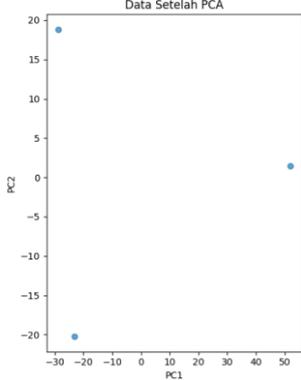
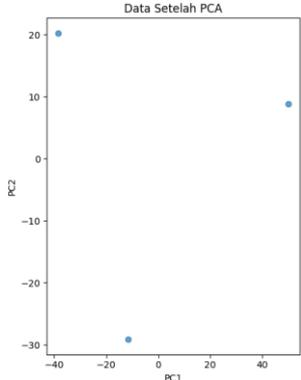
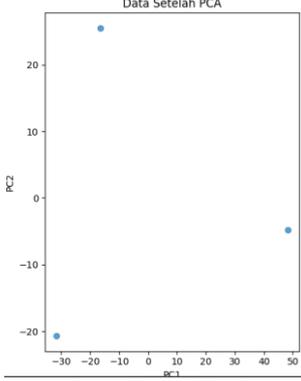
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
16.		<p>Eigenvalues: PC1: 2268.7205 PC2: 417.7795</p> <p>Explained Variance Ratio: PC1: 84.45% PC2: 15.55%</p>	
17.		<p>Eigenvalues: PC1: 2106.5348 PC2: 317.4652</p> <p>Explained Variance Ratio: PC1: 86.90% PC2: 13.10%</p>	
18.		<p>Eigenvalues: PC1: 2036.1310 PC2: 419.3690</p> <p>Explained Variance Ratio: PC1: 82.92% PC2: 17.08%</p>	

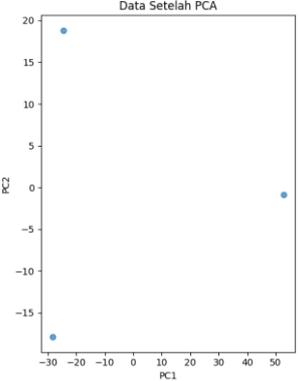
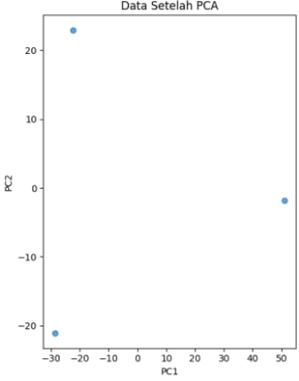
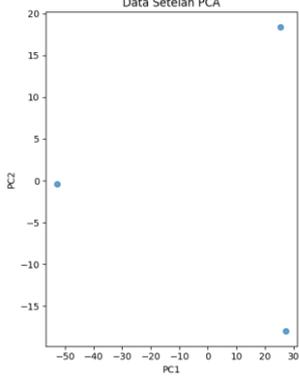
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
19.		<p>Eigenvalues: PC1: 2141.9982 PC2: 582.0018</p> <p>Explained Variance Ratio: PC1: 78.63% PC2: 21.37%</p>	
20.		<p>Eigenvalues: PC1: 2194.4483 PC2: 663.0517</p> <p>Explained Variance Ratio: PC1: 76.80% PC2: 23.20%</p>	
21.		<p>Eigenvalues: PC1: 1994.7794 PC2: 598.7206</p> <p>Explained Variance Ratio: PC1: 76.91% PC2: 23.09%</p>	

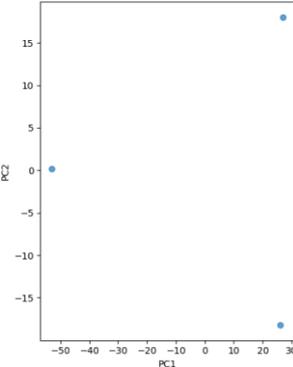
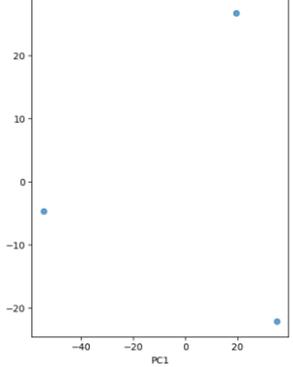
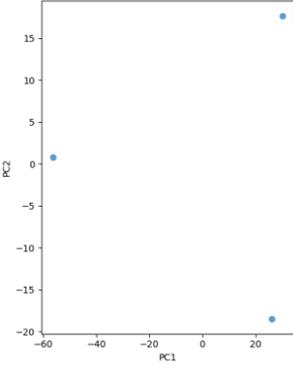
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
22.		<p>Eigenvalues: PC1: 1780.3821 PC2: 571.6179</p> <p>Explained Variance Ratio: PC1: 75.70% PC2: 24.30%</p>	<p>Data Setelah PCA</p> 
23.		<p>Eigenvalues: PC1: 1710.0314 PC2: 541.4686</p> <p>Explained Variance Ratio: PC1: 75.95% PC2: 24.05%</p>	<p>Data Setelah PCA</p> 
24.		<p>Eigenvalues: PC1: 1063.0437 PC2: 294.4563</p> <p>Explained Variance Ratio: PC1: 78.31% PC2: 21.69%</p>	<p>Data Setelah PCA</p> 

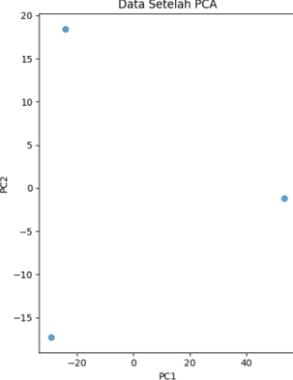
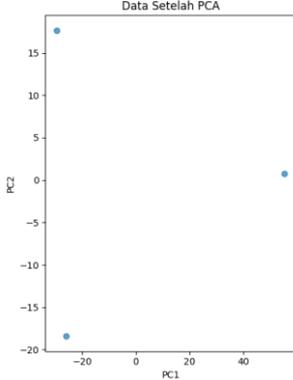
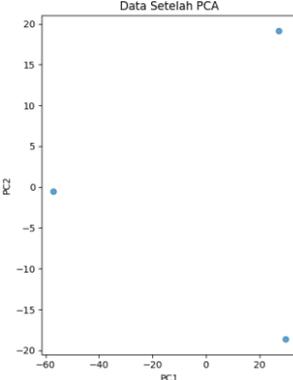
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
25.		<p>Eigenvalues: PC1: 2021.8670 PC2: 561.1330</p> <p>Explained Variance Ratio: PC1: 78.28% PC2: 21.72%</p>	
26.		<p>Eigenvalues: PC1: 2317.6667 PC2: 430.3333</p> <p>Explained Variance Ratio: PC1: 84.34% PC2: 15.66%</p>	
27.		<p>Eigenvalues: PC1: 1636.4926 PC2: 471.0074</p> <p>Explained Variance Ratio: PC1: 77.65% PC2: 22.35%</p>	

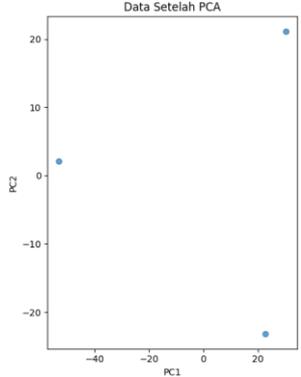
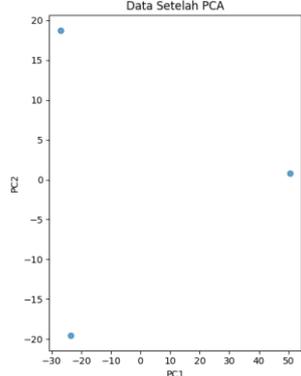
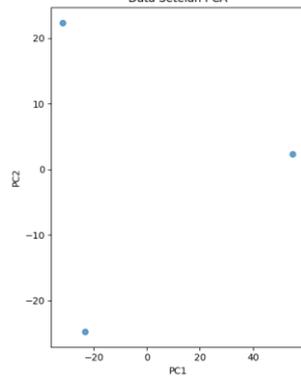
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
28.		<p>Eigenvalues: PC1: 1824.4240 PC2: 371.5760</p> <p>Explained Variance Ratio: PC1: 83.08% PC2: 16.92%</p>	
29.		<p>Eigenvalues: PC1: 2132.8269 PC2: 585.1731</p> <p>Explained Variance Ratio: PC1: 78.47% PC2: 21.53%</p>	
30.		<p>Eigenvalues: PC1: 2402.4897 PC2: 339.5103</p> <p>Explained Variance Ratio: PC1: 87.62% PC2: 12.38%</p>	

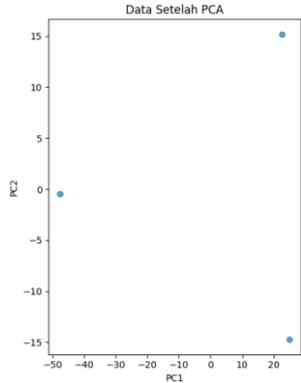
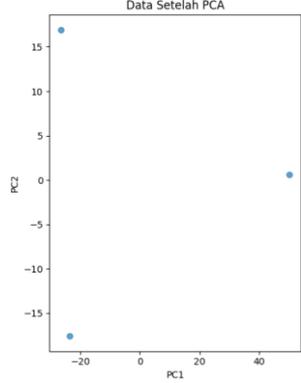
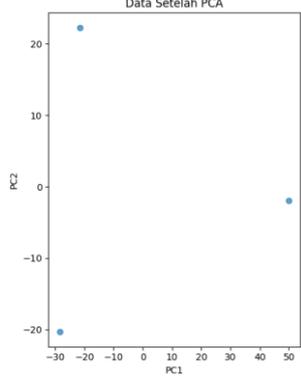
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
31.		<p>Eigenvalues: PC1: 2030.6684 PC2: 381.3316</p> <p>Explained Variance Ratio: PC1: 84.19% PC2: 15.81%</p>	
32.		<p>Eigenvalues: PC1: 2051.6021 PC2: 667.8979</p> <p>Explained Variance Ratio: PC1: 75.44% PC2: 24.56%</p>	
33.		<p>Eigenvalues: PC1: 1799.6314 PC2: 549.3686</p> <p>Explained Variance Ratio: PC1: 76.61% PC2: 23.39%</p>	

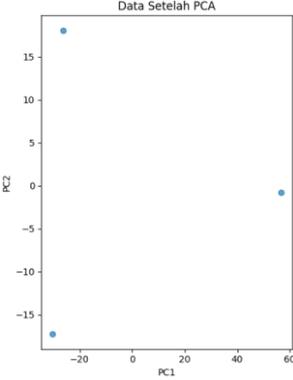
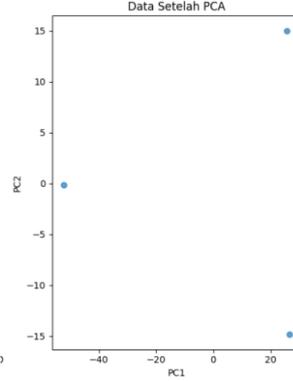
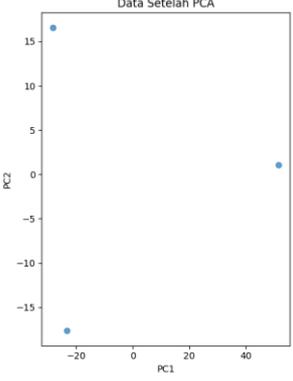
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
34.		<p>Eigenvalues: PC1: 2089.3810 PC2: 336.1190</p> <p>Explained Variance Ratio: PC1: 86.14% PC2: 13.86%</p>	
35.		<p>Eigenvalues: PC1: 1957.1509 PC2: 484.8491</p> <p>Explained Variance Ratio: PC1: 80.15% PC2: 19.85%</p>	
36.		<p>Eigenvalues: PC1: 2084.3328 PC2: 330.6672</p> <p>Explained Variance Ratio: PC1: 86.31% PC2: 13.69%</p>	

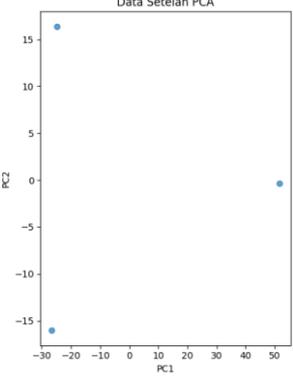
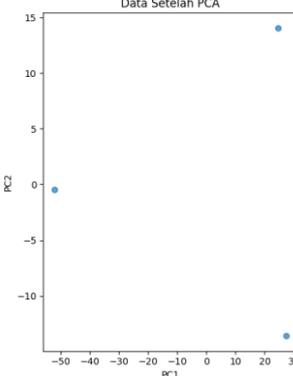
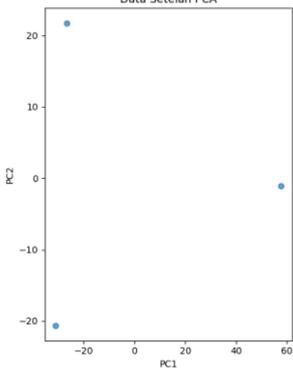
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
37.		<p>Eigenvalues: PC1: 2102.8526 PC2: 327.1474</p> <p>Explained Variance Ratio: PC1: 86.54% PC2: 13.46%</p>	<p>Data Setelah PCA</p> 
38.		<p>Eigenvalues: PC1: 2282.3943 PC2: 611.1057</p> <p>Explained Variance Ratio: PC1: 78.88% PC2: 21.12%</p>	<p>Data Setelah PCA</p> 
39.		<p>Eigenvalues: PC1: 2379.9286 PC2: 326.0714</p> <p>Explained Variance Ratio: PC1: 87.95% PC2: 12.05%</p>	<p>Data Setelah PCA</p> 

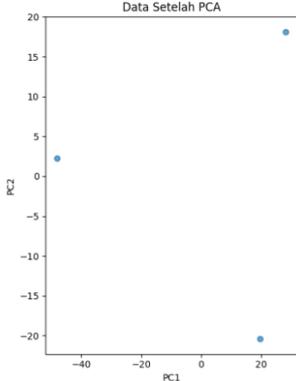
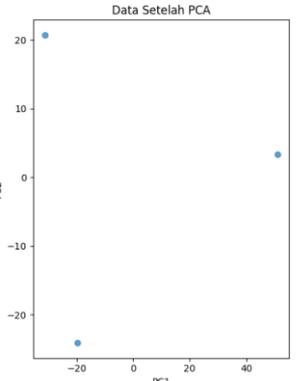
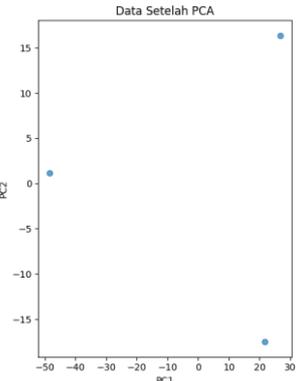
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
40.		<p>Eigenvalues: PC1: 2131.4264 PC2: 319.5736</p> <p>Explained Variance Ratio: PC1: 86.96% PC2: 13.04%</p>	
41.		<p>Eigenvalues: PC1: 2306.5669 PC2: 324.4331</p> <p>Explained Variance Ratio: PC1: 87.67% PC2: 12.33%</p>	
42.		<p>Eigenvalues: PC1: 2439.9699 PC2: 356.0301</p> <p>Explained Variance Ratio: PC1: 87.27% PC2: 12.73%</p>	

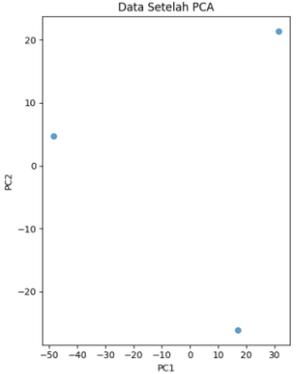
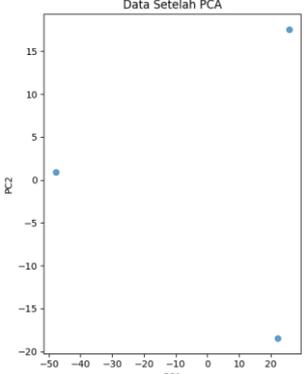
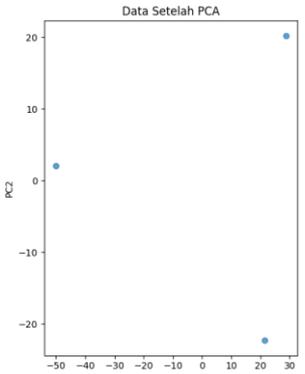
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
43.		<p>Eigenvalues: PC1: 2124.9100 PC2: 492.5900</p> <p>Explained Variance Ratio: PC1: 81.18% PC2: 18.82%</p>	
44.		<p>Eigenvalues: PC1: 1912.0958 PC2: 366.4042</p> <p>Explained Variance Ratio: PC1: 83.92% PC2: 16.08%</p>	
45.		<p>Eigenvalues: PC1: 2276.0623 PC2: 557.4377</p> <p>Explained Variance Ratio: PC1: 80.33% PC2: 19.67%</p>	

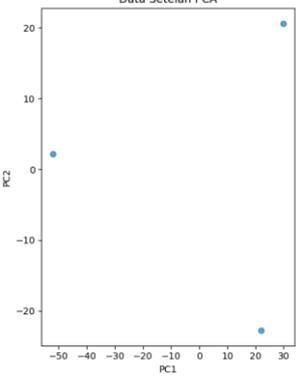
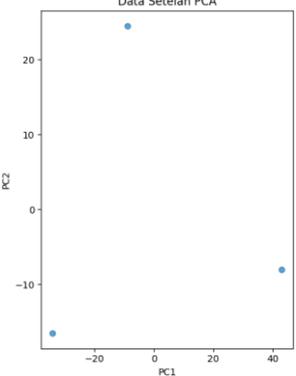
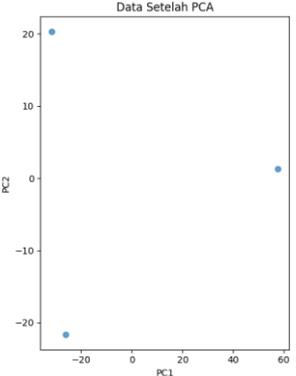
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
46.		<p>Eigenvalues: PC1: 1701.5994 PC2: 222.9006</p> <p>Explained Variance Ratio: PC1: 88.42% PC2: 11.58%</p>	
47.		<p>Eigenvalues: PC1: 1891.7156 PC2: 296.7844</p> <p>Explained Variance Ratio: PC1: 86.44% PC2: 13.56%</p>	
48.		<p>Eigenvalues: PC1: 1877.9935 PC2: 454.5065</p> <p>Explained Variance Ratio: PC1: 80.51% PC2: 19.49%</p>	

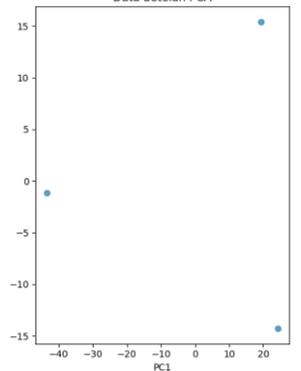
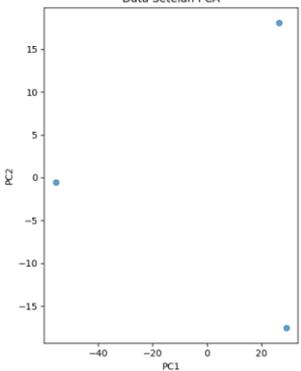
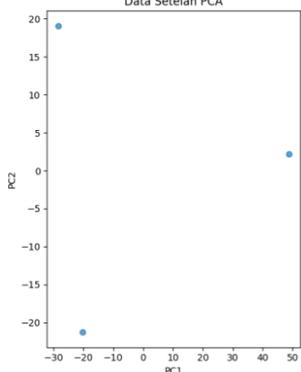
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
49.		<p>Eigenvalues: PC1: 2404.1208 PC2: 310.8792</p> <p>Explained Variance Ratio: PC1: 88.55% PC2: 11.45%</p>	
50.		<p>Eigenvalues: PC1: 2058.3443 PC2: 221.6557</p> <p>Explained Variance Ratio: PC1: 90.28% PC2: 9.72%</p>	
51.		<p>Eigenvalues: PC1: 2007.1753 PC2: 292.3247</p> <p>Explained Variance Ratio: PC1: 87.29% PC2: 12.71%</p>	

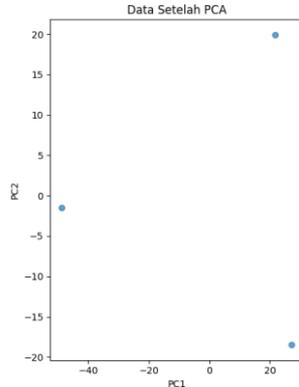
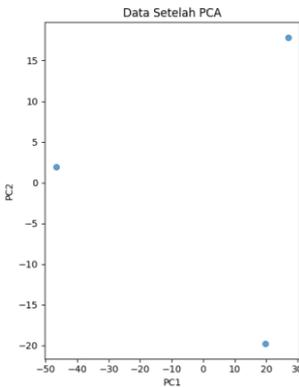
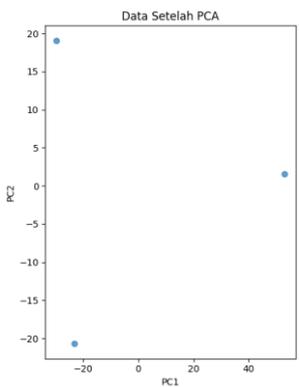
No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
52.		<pre data-bbox="703 506 970 696">Eigenvalues: PC1: 1992.4429 PC2: 262.0571 Explained Variance Ratio: PC1: 88.38% PC2: 11.62%</pre>	
53.		<pre data-bbox="703 920 970 1111">Eigenvalues: PC1: 2024.9458 PC2: 190.5542 Explained Variance Ratio: PC1: 91.40% PC2: 8.60%</pre>	
54.		<pre data-bbox="703 1335 970 1525">Eigenvalues: PC1: 2491.3590 PC2: 448.6410 Explained Variance Ratio: PC1: 84.74% PC2: 15.26%</pre>	

No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
55.		<p>Eigenvalues: PC1: 1747.3675 PC2: 373.6325</p> <p>Explained Variance Ratio: PC1: 82.38% PC2: 17.62%</p>	
56.		<p>Eigenvalues: PC1: 1983.3784 PC2: 508.1216</p> <p>Explained Variance Ratio: PC1: 79.61% PC2: 20.39%</p>	
57.		<p>Eigenvalues: PC1: 1763.6239 PC2: 286.8761</p> <p>Explained Variance Ratio: PC1: 86.01% PC2: 13.99%</p>	

No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
58.		<p>Eigenvalues: PC1: 1802.3962 PC2: 579.6038</p> <p>Explained Variance Ratio: PC1: 75.67% PC2: 24.33%</p>	
59.		<p>Eigenvalues: PC1: 1720.6214 PC2: 323.8786</p> <p>Explained Variance Ratio: PC1: 84.16% PC2: 15.84%</p>	
60.		<p>Eigenvalues: PC1: 1899.5638 PC2: 453.9362</p> <p>Explained Variance Ratio: PC1: 80.71% PC2: 19.29%</p>	

No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
61.		<p>Eigenvalues: PC1: 2036.9602 PC2: 472.5398</p> <p>Explained Variance Ratio: PC1: 81.17% PC2: 18.83%</p>	
62.		<p>Eigenvalues: PC1: 1554.0172 PC2: 466.4828</p> <p>Explained Variance Ratio: PC1: 76.91% PC2: 23.09%</p>	
63.		<p>Eigenvalues: PC1: 2499.1590 PC2: 440.8410</p> <p>Explained Variance Ratio: PC1: 85.01% PC2: 14.99%</p>	

No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
64.		<p>Eigenvalues: PC1: 1420.1893 PC2: 220.8107</p> <p>Explained Variance Ratio: PC1: 86.54% PC2: 13.46%</p>	<p>Data Setelah PCA</p> 
65.		<p>Eigenvalues: PC1: 2315.6694 PC2: 316.8306</p> <p>Explained Variance Ratio: PC1: 87.96% PC2: 12.04%</p>	<p>Data Setelah PCA</p> 
66.		<p>Eigenvalues: PC1: 1795.4730 PC2: 409.5270</p> <p>Explained Variance Ratio: PC1: 81.43% PC2: 18.57%</p>	<p>Data Setelah PCA</p> 

No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
67.		<p>Eigenvalues: PC1: 1801.2735 PC2: 369.2265</p> <p>Explained Variance Ratio: PC1: 82.99% PC2: 17.01%</p>	 <p>Data Setelah PCA</p>
68.		<p>Eigenvalues: PC1: 1645.7966 PC2: 355.2034</p> <p>Explained Variance Ratio: PC1: 82.25% PC2: 17.75%</p>	 <p>Data Setelah PCA</p>
69.		<p>Eigenvalues: PC1: 2116.2831 PC2: 396.2169</p> <p>Explained Variance Ratio: PC1: 84.23% PC2: 15.77%</p>	 <p>Data Setelah PCA</p>

No .	Gambar Asli Bangunan Pasca Bencana Alam	Hasil <i>Eigenvalues</i> dan <i>Explained variance ratio%</i>	Hasil Evaluasi PCA (<i>Scatter plot</i>)
70.		<pre data-bbox="707 506 1029 701">Eigenvalues: PC1: 1989.0196 PC2: 206.9804 Explained Variance Ratio: PC1: 90.57% PC2: 9.43%</pre>	