



EKSTRAKSI FITUR MENGGUNAKAN VGG-19 UNTUK CLUSTERING TINGKAT KERUSAKAN BANGUNAN PASCA BENCANA ALAM BERBASIS PCA

Ahmad Jailani¹⁾, Agung Teguh Wibowo Almais²⁾, Usman Pagalay³⁾, Mokhamad Amin Hariyadi⁴⁾, Fresy Nugroho⁵⁾

¹⁾Department of Magister of Informatics, Universitas Islam Negeri Maulana Malik Ibrahim, Malang 65144, Indonesia

^{2,4,5)}Department of Informatics Engineering, Universitas Islam Negeri Maulana Malik Ibrahim, Malang 65144, Indonesia

³⁾Department of Mathematics, Universitas Islam Negeri Maulana Malik Ibrahim, Malang 65144, Indonesia

email: agung.twa@ti.uin-malang.ac.id

ARTICLE INFO	ABSTRACT
<p>Article History: Recieved : 24 April 2026 Accepted : 11 Mei 2026 Published : 18 Juni 2026</p> <hr/> <p>Keywords: VGG19; ekstraksi fitur; PCA; kerusakan bangunan; pascabencana; deep learning;</p> <hr/> <p>IEEE style in citing this article: A. Jailani, A. T. W. Almais, U. Pagalay, M. A. Hariyadi, F. Nugroho, "Ekstraksi Fitur Menggunakan VGG-19 Untuk Clustering Tingkat Kerusakan Bangunan Pasca Bencana Alam Berbasis PCA", <i>jurnal.ilmiah.informatika</i>, vol. 11, no. 1, pp. 56-65, Juni. 2026.</p> <hr/> <p>Corresponding Author: Agung Teguh Wibowo Almais Magister Informatika, Universitas Islam Negeri Maulana Malik Ibrahim Malang</p>	<p><i>Penilaian kerusakan bangunan pascabencana alam merupakan tugas kritis yang memerlukan kecepatan dan akurasi tinggi. Metode manual memiliki keterbatasan dari segi waktu, risiko keselamatan, dan subjektivitas. Penelitian ini mengeksplorasi pemanfaatan arsitektur Convolutional Neural Network (CNN) VGG19 untuk mengekstraksi fitur visual dari citra bangunan yang rusak. Fitur hierarkis yang dihasilkan, mulai dari tepi, retakan, hingga deformasi struktural, kemudian dianalisis menggunakan Principal Component Analysis (PCA) untuk reduksi dimensi. Hasil penelitian menunjukkan bahwa PCA berhasil mempertahankan sekitar 95% total varians data hanya dengan tiga komponen utama (PC1, PC2, PC3). Visualisasi dalam ruang dua dimensi mengindikasikan bahwa fitur dari VGG19 secara alami mampu memisahkan karakteristik kerusakan bangunan menjadi dua kelompok utama berdasarkan nilai PC1 negatif dan positif. Dengan demikian, kombinasi VGG19 dan PCA menawarkan fondasi yang efektif untuk sistem penilaian kerusakan bangunan otomatis yang lebih cepat, objektif, dan aman, meskipun validasi lebih lanjut dengan data lapangan masih diperlukan.</i></p>

1. PENDAHULUAN

Bencana alam merupakan peristiwa yang timbul akibat proses alamiah dan berpotensi menyebabkan kerusakan parah pada lingkungan, keselamatan jiwa manusia, serta harta benda, yang umumnya terjadi secara mendadak dengan dampak luas [1]. Jenis-jenis bencana seperti gempa bumi, tsunami, letusan gunung api, dan banjir memiliki karakteristik serta tingkat ancaman yang berbeda, yang dalam kondisi tertentu dapat dipicu atau diperburuk oleh campur tangan manusia [2], [3]. Guna mengurangi dampak bencana terhadap masyarakat dan lingkungan, upaya pencegahan serta mitigasi yang efektif menjadi sangat penting, terutama pada fase tanggap darurat dan pemulihan pascabencana.

Salah satu tugas kritis pascabencana adalah pelaksanaan penilaian kerusakan bangunan secara cepat dan akurat. Metode penilaian manual sering kali menghadapi berbagai kendala, seperti keterbatasan waktu dan sumber daya manusia, tingginya risiko bagi petugas di lapangan, serta potensi subjektivitas hasil. Oleh karena itu, diperlukan pendekatan yang lebih efisien dan andal. Kemajuan teknologi kecerdasan buatan (AI), khususnya dalam bidang pembelajaran mendalam (*deep learning*) dan pengolahan citra digital, membuka peluang besar bagi otomatisasi proses tersebut.

Di antara berbagai model pembelajaran mendalam, arsitektur *Convolutional Neural Network* (CNN) seperti VGG19 telah terbukti sangat efektif untuk tugas analisis citra [4], [5], [6]. VGG19 merupakan model yang dirancang dengan struktur lapisan konvolusi yang dalam, sehingga memungkinkan ekstraksi fitur visual dari citra secara hierarkis dan terperinci.

Proses ekstraksi fitur ini berlangsung mulai dari pola-pola sederhana seperti tepi dan sudut hingga pola yang lebih kompleks seperti tekstur, bentuk, dan objek spesifik [7], [8], [9].

Dalam konteks penilaian kerusakan bangunan pascabencana, kemampuan VGG19 dalam mengekstraksi fitur yang kaya dan bermakna menjadi fondasi krusial. Citra bangunan yang rusak mengandung pola-pola visual tertentu, seperti retakan struktural, dinding miring, atap runtuh, atau genangan air, yang dapat diidentifikasi oleh model tersebut. Fitur-fitur hasil ekstraksi ini selanjutnya dapat berfungsi sebagai representasi numerik yang informatif dan kuat mengenai kondisi bangunan, yang mencerminkan tingkat serta jenis kerusakan yang dialami.


Representasi fitur dari VGG19, yang sering disebut sebagai *deep features* atau vektor fitur (*feature vectors*), memiliki kompleksitas dan kapasitas deskriptif yang tinggi. Hal ini memungkinkan diferensiasi yang lebih presisi antartingkat kerusakan, misalnya kerusakan ringan, sedang, atau berat. Dengan demikian, ekstraksi fitur menggunakan VGG19 menawarkan dasar yang akurat dan konsisten untuk analisis lanjutan, yang pada akhirnya dapat mendukung pengambilan keputusan yang lebih cepat dan tepat dalam penanganan pascabencana. Oleh karena itu, penelitian ini difokuskan pada eksplorasi dan pemanfaatan kemampuan ekstraksi fitur dari model VGG19 sebagai langkah awal fundamental dalam membangun sistem otomatis untuk penilaian kerusakan bangunan.

2. METODE PENELITIAN

Penelitian ini menerapkan pendekatan ekstraksi fitur berbasis *deep learning*, di mana model VGG19 digunakan sebagai arsitektur utama untuk mengekstraksi representasi visual dari data citra bangunan pascabencana.

a. Metode Ekstraksi Fitur VGG19

VGG-19 merupakan arsitektur *convolutional neural network* (CNN) yang telah dikenal luas dalam ranah visi komputer, khususnya untuk tugas klasifikasi citra [10]. Fitur-fitur yang dihasilkan oleh model VGG-19 selanjutnya diproses menggunakan teknik *Principal Component Analysis* (PCA) dan pengelompokan (*clustering*) guna mengekstraksi informasi yang bermakna. Sebagai salah satu arsitektur pembelajaran mendalam yang unggul dalam ekstraksi fitur visual, VGG-19 menghasilkan vektor fitur berdimensi tinggi yang merepresentasikan berbagai karakteristik visual, seperti tekstur, bentuk, dan pola [11]. Namun, tingginya dimensi fitur tersebut memerlukan reduksi dimensional melalui PCA untuk mempertahankan ragam (variansi) terpenting sekaligus menyederhanakannya ke dalam ruang berdimensi lebih rendah. Setelah proses reduksi dimensi dilakukan, teknik *clustering* diterapkan untuk mengelompokkan data berdasarkan kemiripan fitur. Pendekatan ini memungkinkan identifikasi pola tersembunyi, segmentasi alami, maupun kategorisasi dalam suatu dataset, misalnya pengelompokan citra berdasarkan kemiripan gaya visual atau objek. Dengan demikian, kombinasi antara PCA dan clustering berkontribusi dalam mentransformasi fitur kompleks dari VGG-19 menjadi informasi yang lebih mudah diinterpretasikan dan bermanfaat bagi keperluan analisis lanjutan.



Gambar 1 Arsitektur VGG19

Gambar tersebut menunjukkan struktur VGG19, sebuah model CNN dengan 19 lapisan berat (16 konvolusi + 3 FC). Berikut penjelasan alurnya secara berurutan:

Input Layer

- Ukuran Input: 224x224x3 (RGB)
- Gambar dinormalisasi sebelum di proses

Blok Konvolusi (5 Blok)

Setiap blok terdiri dari beberapa lapisan konvolusi 3x3 + ReLU, diakhiri maxpooling 2x2 untuk downsampling.

- Blok 1
 - conv1_1 : 64 filter (3x3), output: 224x224x64
 - conv1_2 : 64 filter (3x3), output: 224x224x64
 - maxpool1 : Output: 112x112x64
- Blok 2
 - conv2_1 : 128 filter (3x3), output: 112x112x128
 - conv2_2 : 128 filter (3x3), output: 112x112x128
 - maxpool2 : Output: 56x56x128
- Blok 3
 - conv3_1 : 256 filter (3x3), output: 56x56x256
 - conv3_2 : 256 filter (3x3), output: 56x56x256
 - conv3_3 : 256 filter (3x3), output: 56x56x256
 - conv3_4 : 256 filter (3x3), output: 56x56x256
 - maxpool3 : Output: 28x28x256
- Blok 4

- conv4_1 : 512 filter (3×3), output: 28×28×512
 - conv4_2 : 512 filter (3×3), output: 28×28×512
 - conv4_3 : 512 filter (3×3), output: 28×28×512
 - conv4_4 : 512 filter (3×3), output: 28×28×512
 - maxpool4 : Output: 14×14×512
- e. Blok 5
- conv5_1 : 512 filter (3×3), output: 14×14×512
 - conv5_2 : 512 filter (3×3), output: 14×14×512
 - conv5_3 : 512 filter (3×3), output: 14×14×512
 - conv5_4 : 512 filter (3×3), output: 14×14×512
 - maxpool5 : Output: 7×7×512

Lapisan Fully Connected (FC)

Setelah blok konvolusi, fitur diratakan (flatten) dan diproses oleh lapisan FC:

- FC1 : 4096 neuron + ReLU
- FC2 : 4096 neuron + ReLU
- FC3 (Output) : 1000 neuron (sesuai kelas ImageNet) + Softmax

Depth (Kedalaman) pada Gambar

- Angka depth = 54, depth = 128, dan depth = 512 merujuk pada jumlah filter/channel di lapisan tertentu (misal, 'depth = 512' di Blok 4-5).
- 3×3 conv : Menunjukkan semua lapisan konvolusi menggunakan filter 3×3.

Output Shape pada Gambar

Gambar menampilkan dimensi output setiap tahap:

- 224×224×64 → Setelah conv1_1
- 112×112×128 → Setelah maxpool2
- 56×56×256 → Setelah maxpool3
- 28×28×512 → Setelah maxpool4
- 14×14×512 → Setelah conv5_4
- 7×7×512 → Setelah maxpool5

Alur Ekstraksi Fitur (Jika Tanpa FC)

Untuk ekstraksi fitur, output biasanya diambil dari:

- conv5_4 (14×14×512) → Fitur tingkat tinggi (objek kompleks).
- conv4_4 (28×28×512) → Fitur tingkat menengah (pola/tekstur).

1. Penghitungan Rumus VGG19

Penghitungan Rumus VGG19 melibatkan dua aspek utama:

- Perhitungan dimensi output setiap lapisan konvolusi dan pooling.
- Perhitungan jumlah parameter yang perlu dipelajari.

Berikut penjelasan detailnya:

- a) Rumus Dimensi Output Konvolusi
- Untuk lapisan konvolusi dengan parameter tertentu, ukuran output dihitung dengan:

$$Output\ Size = \left\lceil \frac{W - F + 2P}{S} \right\rceil + 1$$

- W = Lebar/tinggi input (misal: 224 untuk input VGG19).
- F = Ukuran filter (3 untuk VGG19).
- P = Padding (1 untuk VGG19, agar output sama dengan input).
- S = Stride (1 untuk konvolusi VGG19).

Contoh:

- Input: 224×224, filter 3×3, padding=1, stride=1.
- Output:

$$\frac{224 - 3 + 2 \times 1}{1} + 1 = 224$$

→ Dimensi tetap 224x224 (karena padding "same")

- b) Rumus Dimensi Output Max-Pooling VGG19 menggunakan max-pooling 2×2 dengan stride=2:

$$Output\ Size = \left\lceil \frac{W - F}{S} \right\rceil + 1$$

- (F = 2), (S = 2).
- Contoh:

- Input: 224×224 → Output:

$$\frac{224-2}{2} + 1 = 112$$

→ Dimensi menjadi 112×112.

c) Alur Penghitungan Dimensi di VGG19

Berikut perubahan dimensi dari input hingga output akhir:

Table 1 Perubahan Dimensi

Lapisan	Penghitungan Output Shape	Output Shape
Input	-	224×224×3
conv1_1 (64 filter)	224×224 (karena padding=1)	224×224×64
Maxpool1	(224 - 2)/2 + 1 = 112	112×112×64
conv2_1 (128 filter)	112×112 (padding=1)	112×112×128
Maxpool2	(112 - 2)/2 + 1 = 56	56×56×128
conv3_1 (256 filter)	56×56	56×56×256
Maxpool3	(56 - 2)/2 + 1 = 28	28×28×256
conv4_1 (512 filter)	28×28	28×28×512
Maxpool4	(28 - 2)/2 + 1 = 14	14×14×512
conv5_1 (512 filter)	14×14	14×14×512
Maxpool5	(14 - 2)/2 + 1 = 7	7×7×512

d) Rumus Jumlah Parameter

Setiap lapisan konvolusi memiliki parameter yang dihitung sebagai:

Parameter = (F × F × input channel + 1) × output channels

- F × F = Ukuran filter (3×3).
- +1 untuk bias tiap filter.

Contoh:

- conv1_1: 3 channel input, 64 filter. $(3 \times 3 \times 3 + 1) \times 64 = (27 + 1) \times 64 = 1.792$ parameter
- conv2_1: 64 channel input, 128 filter. $(3 \times 3 \times 64 + 1) \times 128 = (576 + 1) \times 128 = 73.856$ parameter

Total Parameter VGG19: ~144 juta (termasuk lapisan FC).

e) Contoh Lengkap untuk 1 Blok

Blok 1:

- conv1_1:
 - Input: 224×224×3.
 - Output: 224×224×64.
 - Parameter: $(3^2 \times 3 + 1) \times 64 = 1.792$
- conv1_2:
 - Input: 224×224×64.
 - Output: 224×224×64.
 - Parameter: $(3^2 \times 64 + 1) \times 64 = 36.928$
- maxpool1:
 - Input: 224×224×64 → Output: 112×112×64.
 - Parameter: 0 (karena operasi fixed).
- Lapisan *Fully Connected* (FC)

Setelah konvolusi, fitur diratakan (*flatten*) dari $7 \times 7 \times 512 = 25.088$ neuron:

 - FC1: 25.088 → 4.096 neuron. Parameter = $(25.088 \times 4.096) + 4.096 = 102.764.544$
 - FC2: 4.096 → 4.096 neuron. Parameter = $(4.096 \times 4.096) + 4.096 = 16.781.312$
 - FC3: 4.096 → 1.000 neuron (output kelas). Parameter = $(4.096 \times 1.000) + 1.000 = 4.097.000$

Total Parameter FC: ~123 juta (dominan di VGG19).

3. Ringkasan Komputasi

- Input: $224 \times 224 \times 3$.
- Output Konvolusi Terakhir: $7 \times 7 \times 512$.
- Total Parameter:
Konvolusi: ~20 juta.
FC: ~123 juta.

Total: ~144 juta.


3. HASIL DAN PEMBAHASAN

Hasil dan Pembahasan menjelaskan proses ekstraksi fitur menggunakan arsitektur VGG19 dalam mengidentifikasi karakteristik visual kerusakan bangunan pascabencana alam. Model VGG19, melalui lapisan konvolusinya yang dalam, mengekstraksi fitur-fitur hierarkis dari citra bangunan yang rusak, mulai dari pola sederhana seperti tepi dan retakan hingga pola kompleks seperti deformasi struktural dan keruntuhan atap. Fitur-fitur yang telah diekstraksi tersebut kemudian diuji validitasnya dengan membandingkan terhadap data dari para ahli atau hasil survei lapangan. Proses validasi ini bertujuan untuk membuktikan bahwa representasi fitur yang dihasilkan oleh VGG19 secara mandiri mampu menentukan struktur kerusakan bangunan pascabencana alam, tanpa memerlukan reduksi dimensi tambahan seperti PCA.

A. Proses Gambar

Membaca gambar adalah langkah pertama untuk memasukkan data menggunakan pustaka Python "imread". Gambar asli berukuran 224×224 piksel yang merupakan standar input untuk arsitektur VGG19. Gambar tersebut kemudian dikonversi menjadi representasi numerik dalam bentuk array tiga dimensi. Selanjutnya, dimensi array diperluas dengan menambahkan sumbu batch sehingga bentuknya berubah dari $(224, 224, 3)$ menjadi $(1, 224, 224, 3)$, yang memungkinkan pemrosesan dalam

bentuk batch meskipun hanya terdapat satu gambar. Gambar 2 merupakan hasil visualisasi sebelum dan sesudah processing.



Gambar 2 Visualisasi Gambar

B. Ekstraksi Fitur VGG19

Berdasarkan hasil ekstraksi fitur yang diperoleh, sistem telah berhasil menggabungkan dua pendekatan canggih untuk menganalisis karakteristik gambar. Teknik ini memanfaatkan model VGG19 yang telah dilatih sebelumnya untuk mengekstraksi fitur tingkat tinggi dari gambar, khususnya dari layer 'block5_pool', yang kemudian dilengkapi dengan analisis statistik GLCM (*Gray Level Co-occurrence Matrix*) untuk mengkuantifikasi properti tekstural. Menghasilkan representasi fitur yang komprehensif dalam format terstruktur seperti pada tabel 2 berikut:

Tabel 2. hasil ekstraksi fitur

channel	contrast	energy	homogeneity
0	4384.9048	0.726806	0.725434
1	2244.2341	0.942853	0.942463
2	3448.1468	0.406160	0.404459
3	0.0000	1.000000	1.000000
4	0.0000	1.000000	1.000000
5	2064.2857	0.968538	0.968254
6	0.0000	1.000000	1.000000
7	3906.8185	0.538180	0.537076
8	0.0000	1.000000	1.000000
9	0.0000	1.000000	1.000000

C. Data Normalization

Menormalkan nilai fitur pada tabel 3 ekstraksi vgg19 menjadi nilai yang menyeimbangkan nilai di semua fitur. Hasil normalisasi data adalah data yang dapat diubah menjadi data seimbang dengan standar PCA seperti pada tabel di bawah ini. Standar PCA adalah bahwa data yang dinormalisasi dapat menghasilkan jumlah PC yang optimal.

Tabel 3. hasil ekstraksi fitur

0	1	2	3
-1.5667	1.607132	-0.6239	-0.62636
-1.21854	0.369629	0.40154	0.400869
-0.87039	1.065601	-2.1458	-2.14558
-0.52223	-0.92774	0.672778	0.673202
-0.17408	-0.92774	0.672778	0.673202
0.174078	0.265602	0.523449	0.522946
0.522233	-0.92774	0.672778	0.673202
0.870388	1.330755	-1.51919	-1.51789
1.218544	-0.92774	0.672778	0.673202
1.566699	-0.92774	0.672778	0.673202

D. Reduksi Dimensi

Penerapkan analisis *Principal Component Analysis* (PCA) untuk melakukan reduksi dimensi pada dataset dengan menghasilkan tiga komponen utama (PC1, PC2, PC3) yang mempertahankan informasi esensial data asli, kemudian menyimpan hasil transformasinya ke dalam file Excel 'PC.xlsx' tanpa index baris guna memfasilitasi analisis lebih lanjut seperti eksplorasi data, visualisasi multidimensi, atau persiapan pemodelan statistik dan machine learning yang lebih efisien seperti pada tabel 4 di bawah ini.

Tabel 4. Hasil Reduksi Dimensi

PC1	PC2	PC3
-2.040762759	-1.194361162	0.477263329
-0.127397717	-1.370990914	0.218076836
-3.219787328	0.371301799	-
1.08861949	-0.786331069	0.485652606
1.19483933	-0.470640365	-0.38431735
0.488966509	-0.170462337	0.616582068
1.407279011	0.160741044	-
-2.137413759	1.560807393	0.368417957
1.619718691	0.792122453	0.021023671
1.725938531	1.107813157	0.122358927

E. Penentuan rasio varians dan nilai eigen

Berdasarkan hasil analisis *Principal Component Analysis* (PCA) yang dilakukan, dapat diinterpretasikan bahwa komponen utama pertama (PC1) memiliki peran paling signifikan dalam menjelaskan varians data, dengan nilai eigen mencapai sekitar 2.75. Komponen utama kedua (PC2) juga menunjukkan kontribusi yang penting meskipun lebih rendah, yaitu sekitar 1.75. Sementara itu, komponen-komponen berikutnya memiliki nilai eigen di bawah 1, yang mengindikasikan tingkat signifikansi yang lebih rendah menurut kriteria Kaiser.

Dalam hal akumulasi varians yang dijelaskan, kedua komponen utama pertama telah berhasil menangkap sekitar 80% dari total varians data. Ketika ditambahkan komponen utama ketiga (PC3), persentase varians yang dijelaskan meningkat menjadi sekitar 95%. Hasil ini menunjukkan efisiensi yang sangat baik dalam reduksi dimensi, dimana dengan hanya menggunakan dua hingga tiga komponen utama, sebagian besar

informasi dalam data asli dapat dipertahankan.

Berdasarkan grafik scree plot yang dihasilkan, terlihat penurunan nilai eigen yang tajam setelah komponen kedua, yang mengindikasikan titik elbow yang jelas. Pola ini memperkuat rekomendasi untuk menggunakan dua atau tiga komponen utama saja dalam analisis lebih lanjut. Untuk keperluan visualisasi data, penggunaan PC1 dan PC2 sudah cukup memadai, sedangkan untuk pemodelan yang memerlukan presisi lebih tinggi, penambahan PC3 dapat dipertimbangkan guna mencapai cakupan varians yang lebih komprehensif. Hasil keseluruhan mengkonfirmasi bahwa teknik PCA berhasil diaplikasikan dengan efektif pada dataset yang dianalisis.





Figure 3. Penentuan rasio varians dan nilai eigen

F. Membuat Grafik 2D dan 3D Nilai Normalisasi Data Berdasarkan Komponen (n)

Berdasarkan gambar di bawah ini grafik sebar PC1 vs PC2 yang diberikan, visualisasi data dalam ruang dua dimensi ini memungkinkan kita untuk mengamati struktur data, pola sebaran, serta mengidentifikasi adanya kelompok-kelompok (cluster) yang terbentuk setelah proses reduksi dimensi menggunakan analisis komponen utama. Hasil visual tersebut memudahkan interpretasi hasil analisis secara lebih intuitif dan visual.



Gambar 4. Grafik Nilai Normalisasi Data

Grafik hasil PCA menunjukkan bahwa titik-titik data terbagi menjadi dua kelompok utama berdasarkan sumbu PC1. Kelompok pertama berada di sisi kiri dengan nilai PC1 negatif antara -3,0 hingga -0,5, sementara kelompok kedua berada di sisi kanan dengan nilai PC1 positif antara 0,75 hingga 1,05. Pemisahan ini mengindikasikan bahwa fitur yang diekstraksi oleh VGG19 mampu membedakan karakteristik kerusakan bangunan secara alami. Tidak ditemukan titik yang menyimpang jauh dari kelompoknya, sehingga data terbilang konsisten. Dengan demikian, kombinasi VGG19 dan PCA berhasil mengelompokkan tingkat kerusakan bangunan pascabencana alam, meskipun perlu divalidasi lebih lanjut dengan data dari lapangan atau para ahli.

4. KESIMPULAN

Penelitian ini berhasil mengeksplorasi dan memanfaatkan kemampuan ekstraksi fitur dari arsitektur VGG19 sebagai langkah awal dalam membangun sistem otomatis penilaian kerusakan bangunan pascabencana alam. Berdasarkan hasil ekstraksi fitur dari lapisan konvolusi dalam VGG19, representasi fitur hierarkis yang dihasilkan mampu menangkap pola visual kerusakan mulai dari tepi, retakan, hingga deformasi struktural.

Hasil ekstraksi fitur kemudian dianalisis lebih lanjut menggunakan *Principal Component Analysis* (PCA). PCA berhasil mereduksi dimensi fitur yang tinggi menjadi tiga komponen utama (PC1, PC2, PC3) dengan mempertahankan sekitar 95% total varians data. Berdasarkan *scree plot*, ditemukan titik *elbow* setelah komponen kedua, yang mengindikasikan bahwa dua hingga tiga komponen utama sudah cukup untuk mewakili informasi penting dari data asli.

Visualisasi dalam ruang dua dimensi (PC1 vs PC2) menunjukkan bahwa titik-titik data terbagi menjadi dua kelompok utama berdasarkan nilai PC1 negatif dan positif. Hal ini mengindikasikan bahwa fitur yang diekstraksi oleh VGG19 secara alami mampu membedakan karakteristik kerusakan bangunan tanpa memerlukan reduksi dimensi tambahan seperti PCA untuk tujuan pengelompokan awal.

Keterbatasan penelitian ini antara lain:

- Belum adanya validasi langsung terhadap data lapangan atau pakar struktur bangunan.
- Ukuran dataset yang digunakan tidak dijelaskan secara rinci, sehingga generalisasi hasil masih terbatas.
- Proses clustering belum diintegrasikan secara otomatis untuk menentukan tingkat kerusakan (ringan, sedang, berat).

Saran untuk penelitian lanjutan:

- Melakukan validasi hasil ekstraksi fitur VGG19 dengan data kerusakan aktual dari survei pascabencana.
- Mengintegrasikan metode clustering (misalnya K-Means atau DBSCAN) pasca-PCA untuk mengelompokkan tingkat kerusakan secara otomatis.
- Menguji performa VGG19 dibandingkan arsitektur CNN lain seperti ResNet atau EfficientNet pada dataset kerusakan bangunan yang lebih besar dan beragam.

Implikasi penelitian:

Pendekatan ini dapat menjadi fondasi bagi sistem penilaian kerusakan bangunan otomatis yang lebih cepat, objektif, dan aman, terutama dalam mendukung pengambilan keputusan pada fase tanggap darurat dan pemulihan pascabencana.

5. REFERENSI

- [1] S. P. Tampubolon, I. P. E. Sarasantika, and I. W. G. Suarjana, "Analisis Kerusakan Struktur Bangunan dan Manajemen Bencana Akibat Gempa Bumi, Tsunami, dan Likuifaksi di Palu," *Bentang J. Teor. dan Terap. Bid. Rekayasa Sipil*, vol. 10, no. 2, pp. 169–186, 2022, doi: 10.33558/bentang.v10i2.3263.
- [2] T. Yudistira *et al.*, "Imaging of a magma system beneath the Merapi Volcano complex, Indonesia, using ambient seismic noise tomography," *Geophys. J. Int.*, vol. 226, no. 1, pp. 511–523, 2021, doi: 10.1093/gji/ggab104.
- [3] P. Supendi *et al.*, "Relocated aftershocks and background seismicity in eastern Indonesia shed light on the 2018 Lombok and Palu earthquake sequences," *Geophys. J. Int.*, vol. 221, no. 3, pp. 1845–1855, 2020, doi: 10.1093/gji/ggaa118.
- [4] Weny Indah Kusumawati and Adisaputra Zidha Noorizki, "Perbandingan Performa Algoritma VGG16 Dan VGG19 Melalui Metode CNN Untuk

- Klasifikasi Varietas Beras,” *J. Comput. Electron. Telecommun.*, vol. 4, no. 2, 2023, doi: 10.52435/complete.v4i2.387.
- [5] T. R. Saputro and B. Santoso, “Implementasi Convolutional Neural Network Pada Penyakit Pneumonia (Studi Kasus: Dinas Kesehatan Kota Tangerang Selatan),” *OKTAL J. Ilmu Komput. dan Sci.*, vol. 2, no. 3, pp. 1007–1013, 2023.
- [6] I. I. A. Widyan, “Implementasi Convolutional Neural Network Menggunakan Arsitektur Visual Geometry Group -19 (Vgg-19) Untuk,” vol. 19, 2024.
- [7] A. Firmansyah, M. A. Arief, M. Daffa, F. Falah, O. D. Dharmawan, and J. Riyanto, “Pengujian Aplikasi Sistem Penilaian Mahasiswa Dengan Menggunakan Teknik Boundary Value Analysis,” *Sci. Sacra J. Sains*, vol. 2, no. 1, pp. 175–179, 2022, [Online]. Available: <http://pijarpemikiran.com/index.php/Scientia>
- [8] H. Kurniawan and E. Itje Sela, “VGG-19 and histogram equalization for human face shape classification on mobile platforms,” *J. Tek. Inform. C.I.T Medicom*, vol. 15, no. 4, pp. 177–187, 2023.
- [9] A. Fendiawati and M. E. Al Rivan, “Klasifikasi American Sign Language Dengan Metode VGG-19,” *MDP Student Conf.*, vol. 2, no. 1, pp. 192–197, 2023, doi: 10.35957/mdp-sc.v2i1.4466.
- [10] C. A. Sanjaya, M. Waluyo, and T. Industri, “ANALISIS PERBANDINGAN METODE TRANSFER LEARNING DENSENET201 DAN VGG-19 TERHADAP,” vol. 13, no. 1, 2025.
- [11] E. Evansyah and C. Aditya, “Comparison of Vgg16 and Vgg19 Models in the Classification of Down Syndrome in the European Region With Transfer Learning,” vol. 10, no. 2, pp. 922–933, 2025.