

***CLUSTERING TINGKAT KERUSAKAN BANGUNAN PASCABENCANA
MENGUNAKAN *GABOR FILTERS* DAN *PRINCIPAL COMPONENT
ANALYSIS****

SKRIPSI

**Oleh :
ANNISA AYU PERMADANI
NIM. 210605110139**



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

***CLUSTERING TINGKAT KERUSAKAN BANGUNAN PASCABENCANA
MENGUNAKAN GABOR FILTERS DAN PRINCIPAL COMPONENT
ANALYSIS***

SKRIPSI

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

Oleh :
ANNISA AYU PERMADANI
NIM. 210605110139

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

HALAMAN PERSETUJUAN


**CLUSTERING TINGKAT KERUSAKAN BANGUNAN PASCABENCANA
MENGUNAKAN *GABOR FILTERS* DAN *PRINCIPAL COMPONENT
ANALYSIS***

SKRIPSI

Oleh :
ANNISA AYU PERMADANI
NIM. 210605110139

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 15 Oktober 2025

Pembimbing I,



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

Pembimbing II,



Dr. M. Imamudin, Lc., M.A
NIP. 19740602 200901 1 010

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



Supriyono, M.Kom
NIP. 19841010 201903 1 012

HALAMAN PENGESAHAN

CLUSTERING TINGKAT KERUSAKAN BANGUNAN PASCABENCANA MENGUNAKAN *GABOR FILTERS* DAN *PRINCIPAL COMPONENT ANALYSIS*

SKRIPSI

Oleh :
ANNISA AYU PERMADANI
NIM. 210605110139


Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 11 November 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>Dr. M. Imamudin, Lc., M.A</u> NIP. 19740602 200901 1 010

()
()
()
()

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



Supriyono, M.Kom
NIP. 19841010 201903 1 012

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Annisa Ayu Permadani
NIM : 210605110139
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : *Clustering Tingkat Kerusakan Bangunan Pascabencana Menggunakan Gabor filters dan Principal Component Analysis.*

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, 15 Oktober 2025
Yang membuat pernyataan,



Annisa Ayu Permadani
NIM. 210605110139

MOTTO

“Jangan biarkan rasa takut menghentikan langkahmu. Beranilah melangkah, karena keberanian lahir dari perjuangan, bukan dari kenyamanan.”

“Teruslah melangkah, meski ragu dan takut datang silih berganti. Sebab diam tak akan pernah membawamu ke mana pun.”

HALAMAN PERSEMBAHAN

Segala puji dan syukur penulis panjatkan ke hadirat Allah SWT atas limpahan rahmat, taufik, serta hidayah-Nya. Berkat pertolongan dan kemudahan dari-Nya, penulis dapat menyelesaikan skripsi ini dengan baik. Dengan penuh ketulusan dan rasa syukur, karya ini penulis persembahkan kepada:

Ayah tercinta, Edy Supriyanto, dan Ibu tercinta, Khusnul Qotimah, atas segala kasih sayang yang tak pernah pudar, doa yang tak pernah putus, serta dukungan yang selalu menguatkan di setiap langkah. Terima kasih atas kesabaran, pengorbanan, dan ketulusan yang menjadi sumber kekuatan terbesar dalam hidup penulis.

Keluarga besar penulis, yang tidak pernah berhenti memberikan doa, perhatian, dan semangat. Setiap dukungan yang kalian berikan menjadi penguat tersendiri di tengah perjalanan panjang menuju terselesaikannya karya ini.

Dan untuk diri penulis sendiri, Terima kasih telah kuat menghadapi setiap ujian, tetap berusaha ketika hampir menyerah, dan terus melangkah hingga akhir. Semoga perjuangan ini menjadi awal dari perjalanan panjang yang penuh makna dan keberhasilan.

KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh

Puji syukur kehadiran Allah SWT atas segala limpahan rahmat, taufik, dan hidayah-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul “*Clustering* Tingkat Kerusakan Bangunan Pascabencana Menggunakan *Gabor filters* dan *Principal Component Analysis*” dengan baik. Shalawat serta salam semoga senantiasa tercurah kepada junjungan Nabi Muhammad SAW yang telah membawa umat manusia dari zaman kegelapan menuju zaman yang terang benderang dengan ilmu pengetahuan.

Skripsi ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer (S.Kom) pada Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang. Dalam proses penyusunan skripsi ini, penulis banyak menerima bimbingan, bantuan, dan doa dari berbagai pihak. Oleh karena itu, dengan segala kerendahan hati penulis menyampaikan terima kasih kepada:

1. Prof. Dr. Hj. Ilfi Nur Diana, M.Si, selaku Rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Dr. Agus Mulyono, M.Kes, selaku Dekan Fakultas Sains dan Teknologi.
3. Supriyono, M.Kom, selaku Ketua Program Studi Teknik Informatika.
4. Dr. Agung Teguh Wibowo Almais, M.T, selaku Dosen Pembimbing I yang dengan penuh kesabaran dan ketelitian telah memberikan bimbingan, arahan, serta motivasi kepada penulis selama penyusunan skripsi ini.

5. Dr. M. Imamudin, Lc., M.A, selaku Dosen Pembimbing II yang telah memberikan masukan dan pandangan berharga dalam penyempurnaan penelitian ini.
6. Dr. Totok Chamidy, M.Kom, selaku Dosen Penguji I, dan Ashri Shabrina Afrah, M.T, selaku Dosen Penguji II, atas saran, kritik, serta masukan yang membangun dalam penyempurnaan hasil penelitian ini.
7. Seluruh Dosen dan Staf Fakultas Sains dan Teknologi, khususnya Program Studi Teknik Informatika, yang telah memberikan ilmu, bimbingan, dan pelayanan terbaik selama masa perkuliahan.
8. Kedua orang tua tercinta, atas segala kasih sayang, doa, serta dukungan moral dan material yang tiada henti. Terima kasih atas setiap pengorbanan, kesabaran, dan kerja keras yang telah diberikan dengan penuh keikhlasan. Dukungan dan doa dari orang tua menjadi kekuatan utama bagi penulis untuk terus berjuang dan tidak menyerah dalam menghadapi berbagai kesulitan selama proses perkuliahan hingga penyusunan skripsi ini. Semangat dan doa dari orang tua senantiasa menjadi pengingat agar penulis tetap berusaha memberikan yang terbaik. Semoga Allah SWT membalas segala kasih sayang dan pengorbanan dengan kesehatan, kebahagiaan, dan keberkahan yang tiada henti.
9. Sahabat-sahabat seperjuangan, yang selalu memberikan semangat, bantuan, dan kebersamaan selama masa perkuliahan hingga penyusunan skripsi ini. Ucapan terima kasih khusus penulis sampaikan kepada Nurul Aziza Kusuma Dewi, Salsabila Ramadanti Nuraini, Jinan Naurah, Ferina Putri

Soedjono, dan Vinka Rosalia Fatimah Devi, atas doa, dukungan, serta canda tawa yang menjadi penyemangat di setiap proses perjuangan. Terima kasih atas kerja sama, diskusi, serta waktu yang dihabiskan bersama dalam menghadapi berbagai tantangan akademik. Semoga persahabatan ini senantiasa terjaga dan menjadi kenangan indah yang tak terlupakan.

10. Sahabat-sahabat “Tidak Boleh Ngelu”, yang selalu hadir memberikan dukungan, semangat, serta menjadi tempat berbagi cerita di setiap proses perjuangan. Terima kasih kepada Aura Salsabila Achya, Bunga Jasmine Nur Sabrina, Tabriza Zerlina Arys Syafa’ati, dan Yessi Aulia Kristiyady, atas doa, perhatian, dan kebersamaan yang menjadi penguat bagi penulis hingga skripsi ini terselesaikan dengan baik.
11. Teman-teman seperbimbingan, terima kasih atas kebersamaan, dukungan, dan semangat yang selalu diberikan selama proses bimbingan. Ucapan terima kasih khusus penulis sampaikan kepada Iqlima Rahmafritri Karindah, yang selalu saling membantu, berdiskusi, dan memberikan motivasi hingga skripsi ini dapat terselesaikan dengan baik.
12. Teman-teman Teknik Informatika angkatan 2021 (ASTER), terima kasih atas kebersamaan, semangat, dan dukungan selama menempuh perjalanan perkuliahan. Semoga seluruh anggota ASTER senantiasa diberikan kesuksesan dan keberkahan dalam setiap langkah ke depan.
13. Seluruh pihak yang telah terlibat secara langsung maupun tidak langsung dalam proses penyusunan skripsi sejauh ini.

Penulis menyadari bahwa dalam penyusunan skripsi ini masih terdapat kekurangan, baik dari segi penulisan maupun isi. Oleh karena itu, penulis mengharapkan kritik dan saran yang membangun demi perbaikan di masa mendatang. Semoga skripsi ini dapat memberikan manfaat bagi pembaca dan menjadi kontribusi kecil dalam pengembangan ilmu pengetahuan, khususnya di bidang pengolahan citra digital dan mitigasi bencana.

Wassalamualaikum Warahmatullahi Wabarakatuh.

Malang, 15 Oktober 2025

Penulis

DAFTAR ISI

HALAMAN PENGAJUAN.....	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN.....	iv
PERNYATAAN KEASLIAN TULISAN.....	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR.....	viii
DAFTAR ISI	xii
DAFTAR GAMBAR.....	xiv
DAFTAR TABEL	xv
ABSTRAK	xvi
ABSTRACT.....	xvii
الملخص.....	xviii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	5
1.3 Batasan Masalah	6
1.4 Tujuan Penelitian	6
1.5 Manfaat Penelitian	6
BAB II STUDI PUSTAKA.....	8
2.1 Penelitian Terkait.....	8
2.2 Bencana Alam.....	11
2.3 <i>Preprocessing</i>	12
2.4 <i>Gabor filters</i>	14
2.5 Ekstraksi Fitur.....	17
2.6 <i>Clustering</i>	19
2.7 <i>Principal Component Analysis (PCA)</i>	22
BAB III METODE PENELITIAN	25
3.1 Desain Sistem	25
3.1.1 <i>Preprocessing</i>	26
3.1.2 <i>Gabor filters</i>	27
3.1.3 Konversi ke <i>Spreadsheet</i>	30
3.1.4 PCA	30
3.2 Data Preparation	33
3.3 Skenario Pengujian	34
BAB IV HASIL DAN PEMBAHASAN	36
4.1 Uji Coba Sistem.....	36
4.2 Hasil Uji Coba	36
4.2.1 <i>Preprocessing</i> Data.....	36
4.2.2 Proses <i>Gabor Filter</i>	38
4.2.3 Proses PCA <i>Clustering</i>	46
4.2.4 Evaluasi Sistem.....	58
4.3 Pembahasan	60
4.4 Integrasi Islam.....	64
4.4.1 <i>Muamalah Ma'a Allah</i>	65
4.4.2 <i>Muamalah Ma'a An-Nas</i>	66

4.4.3 <i>Muamalah Ma'a Al-Alam</i>	68
BAB V KESIMPULAN DAN SARAN	70
5.1 Kesimpulan	70
5.2 Saran	71
DAFTAR PUSTAKA	
LAMPIRAN	

DAFTAR GAMBAR

Gambar 2. 1 <i>Gaussian Envelope</i>	14
Gambar 2. 2 Bagian riil (a) dan imajiner (b) dari sinusoidal kompleks.....	15
Gambar 3. 1 Desain Sistem.....	26
Gambar 3. 2 Perbedaan Gambar <i>Preprocessing</i>	27
Gambar 3. 3 Contoh Hasil <i>Gabor filters</i> 8 Orientasi dan 2 Skala Frekuensi.....	29
Gambar 3. 4 Contoh Dataset Bangunan Rusak.....	33
Gambar 4. 1 Data Sebelum dan Sesudah di- <i>Crop</i>	37
Gambar 4. 2 Hasil <i>Resize</i> (kiri) dan <i>Grayscale</i> (kanan)	38
Gambar 4. 3 Hasil Konvolusi <i>Gabor filters Real</i>	40
Gambar 4. 4 Hasil Konvolusi <i>Gabor filters Imaginer</i>	41
Gambar 4. 5 Hasil Normalisasi <i>Gabor filters</i>	43
Gambar 4. 6 Visualisasi 2D dan 3D.....	50
Gambar 4. 7 Visualisasi <i>Clustering</i> Data.....	51
Gambar 4. 8 Visualisasi 2D dengan Label u dan v	52
Gambar 4. 9 Visualisasi 2D pada 2 <i>Cluster</i>	54
Gambar 4. 10 Visualisasi 2D pada 4 <i>Cluster</i>	55
Gambar 4. 11 Visualisasi 2D pada 5 <i>Cluster</i>	56

DAFTAR TABEL

Tabel 2. 1 Penelitian Terkait	8
Tabel 4. 1 <i>Array</i> 3D Hasil Pembuatan Kernel Gabor	39
Tabel 4. 2 Hasil Konvolusi Gabor pada V0 dan U0	42
Tabel 4. 3 Hasil <i>Magnitude</i> V0 dan U0	43
Tabel 4. 4 Hasil Normalisasi V0 dan U0	44
Tabel 4. 5 Hasil Ekstraksi Fitur Gabor.....	45
Tabel 4. 6 Hasil Normalisasi Data	46
Tabel 4. 7 Persentase Nilai <i>Variance ratio</i> dan <i>Eigen value</i>	47
Tabel 4. 8 Nilai <i>Eigenvector</i>	48
Tabel 4. 9 Hasil Pembuatan Komponen Utama PCA	49
Tabel 4. 10 Rentang Nilai <i>Clustering</i> Data.....	51
Tabel 4. 11 Hasil <i>Cluster</i> Terhadap Nilai Fitur.....	52
Tabel 4. 12 Rentang Nilai pada 2 <i>Cluster</i>	55
Tabel 4. 13 Rentang Nilai pada 4 <i>Cluster</i>	56
Tabel 4. 14 Rentang Nilai pada 5 <i>Cluster</i>	57
Tabel 4. 15 Hasil <i>Silhouette score</i> Masing-masing Jumlah <i>Cluster</i>	59

ABSTRAK

Permadani, Annisa Ayu. 2025. ***Clustering Tingkat Kerusakan Bangunan Pascabencana Menggunakan Gabor filters dan Principal Component Analysis***. 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) Dr. M. Imamudin Lc, MA.

Kata kunci: *Clustering, Gabor filters, Principal Component Analysis (PCA), Tekstur Citra, Kerusakan Bangunan.*

Indonesia merupakan negara dengan tingkat risiko bencana yang tinggi karena letaknya di pertemuan tiga lempeng tektonik dunia. Dampak bencana alam seperti gempa bumi dan banjir sering mengakibatkan kerusakan bangunan yang membutuhkan proses identifikasi cepat dan akurat. Penelitian ini bertujuan untuk mengidentifikasi tingkat kerusakan bangunan pascabencana menggunakan metode *Gabor filters* untuk ekstraksi fitur tekstur dan Principal Component Analysis (PCA) untuk proses *clustering*. Data yang digunakan berupa citra bangunan rusak yang diperoleh dari BPBD Kota Malang dan dataset publik Kaggle. Proses penelitian meliputi tahap preprocessing citra (grayscale dan resize), ekstraksi fitur menggunakan *Gabor filters* dengan tiga parameter frekuensi dan lima orientasi, perhitungan fitur statistik (kontras, *mean*, dan energi), serta pengelompokan menggunakan PCA berdasarkan nilai komponen utama (PC1). Hasil penelitian menunjukkan bahwa metode Gabor-PCA mampu memisahkan data ke dalam tiga kelompok tingkat kerusakan dengan baik. Nilai explained variance tertinggi berada pada komponen utama pertama (PC1) sebesar 99,26%, menandakan bahwa sebagian besar informasi tekstur tercakup dalam satu komponen utama. Evaluasi menggunakan *Silhouette score* menunjukkan nilai 0,8491 yang berarti hasil *clustering* cukup baik. Dengan demikian, metode ini dapat dijadikan alternatif untuk membantu proses identifikasi tingkat kerusakan bangunan secara otomatis, efisien, dan objektif.

ABSTRACT

Permadani, Annisa Ayu. 2025. ***Clustering Tingkat Kerusakan Bangunan Pascabencana Menggunakan Gabor filters dan Principal Component Analysis***. 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) Dr. M. Imamudin Lc, MA.

Indonesia is one of the countries with a high risk of natural disasters due to its position at the convergence of three major tectonic plates. The impact of natural disasters such as earthquakes and floods often causes significant building damage that requires rapid and accurate identification. This study aims to identify post-disaster building damage levels using *Gabor filters* for texture feature extraction and Principal Component Analysis (PCA) for *clustering*. The dataset consists of damaged building images obtained from BPBD Malang City and public data from Kaggle. The research process includes image preprocessing (grayscale and resizing), feature extraction using *Gabor filters* with three frequency scales and five orientations, calculation of statistical features (*contrast*, *mean*, and *energy*), and *clustering* based on PCA's first principal component (PC1). The results show that the Gabor–PCA method can effectively separate images into three damage-level *clusters*. The highest explained variance is found in PC1 at 99.26%, indicating that most texture information is contained within a single principal component. The *clustering* evaluation using the *Silhouette score* achieved a value of 0.8491, indicating good *cluster* separation. Therefore, this method can serve as an effective, automatic, and objective approach for identifying building damage levels after disasters.

Key words: *Clustering*, *Gabor filters*, Principal Component Analysis (PCA), Image Texture, Building Damage.

الملخص

برماداني، أنيسا آيو. ٢٠٢٥. تجميع مستويات ضرر المباني بعد الكوارث باستخدام مرشحات غابور وتحليل المكونات الرئيسية (PCA). رسالة جامعية، قسم هندسة المعلومات، كلية العلوم والتكنولوجيا، الجامعة الإسلامية الحكومية مولانا مالك إبراهيم مالانغ. بإشراف: (١) الدكتور أغونغ تغوه ويوو ألاميس، ماجستير في الهندسة، (٢) الدكتور محمد إمام الدين، ليسانس، ماجستير في الآداب.

الكلمات المفتاحية: التجميع (Clustering)، مرشحات غابور (Gabor filters)، تحليل المكونات الرئيسية (PCA)، نسيج الصورة، ضرر المباني.

تُعدُّ إندونيسيا من الدول ذات المخاطر العالية للكوارث الطبيعية بسبب موقعها عند التقاء ثلاث صفائح تكتونية رئيسية في العالم. إنّ آثار الكوارث الطبيعية مثل الزلازل والفيضانات كثيراً ما تُسبب أضراراً في المباني تتطلب عملية تحديد سريعة ودقيقة لمستوى الضرر. يهدف هذا البحث إلى تحديد مستوى ضرر المباني بعد الكوارث باستخدام طريقة مرشحات غابور (Gabor filters) لاستخراج ميزات النسيج، وتحليل المكونات الرئيسية (Principal Component Analysis – PCA) لعملية التجميع (Clustering). تم استخدام بيانات على شكل صور لمبانٍ متضررة تم الحصول عليها من وكالة إدارة الكوارث في مدينة مالانغ (BPBD) ومن مجموعة بيانات عامة في موقع Kaggle. تشمل مراحل البحث المعالجة المسبقة للصور (تحويلها إلى تدرج رمادي وتغيير الحجم)، واستخراج الميزات باستخدام مرشحات غابور بثلاث ترددات وخمس زوايا مختلفة، وحساب الخصائص الإحصائية (التباين، التجانس، والطاقة)، ثم تجميع البيانات باستخدام تحليل المكونات الرئيسية استناداً إلى القيم في المكون الرئيسي الأول (PC1). أظهرت النتائج أن طريقة غابور-PCA قادرة على تقسيم البيانات إلى ثلاث مجموعات تمثل مستويات مختلفة من الضرر بدقة جيدة. بلغت نسبة التباين المفسّر في المكون الرئيسي الأول 99.26٪، مما يشير إلى أن معظم معلومات النسيج متركزة في هذا المكون الواحد. كما أظهر التقييم باستخدام مؤشر Silhouette score قيمة قدرها 0.8491، مما يدل على جودة التجميع. وبناءً على ذلك، يمكن اعتماد هذه الطريقة كأداة فعالة وآلية للمساعدة في تحديد مستوى ضرر المباني بعد الكوارث بطريقة سريعة وكفوءة وموضوعية.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Indonesia termasuk dalam salah satu negara dengan risiko bencana yang tinggi. Letak geografis Indonesia lah penyebabnya. Indonesia terletak di pertemuan tiga lempeng tektonik utama dunia, yaitu Lempeng Indo-Australia, Lempeng Eurasia, dan Lempeng Pasifik (Imelda dkk., 2024). Pertemuan tiga lempeng tektonik dunia ini dapat menyebabkan berbagai aktivitas tektonik, seperti gempa bumi, tsunami, dan letusan gunung berapi (Taufan Maulana & Andriansyah, 2024). Selain itu, karena letak geografis dan iklim tropisnya, Indonesia menjadi lebih rentan terhadap berbagai bencana alam, seperti banjir, tanah longsor, serta badai tropis yang dapat menyebabkan kerusakan bangunan masyarakat.

Sepanjang tahun 2020 telah terjadi lebih dari 2.900 kejadian bencana di Indonesia (Azzahra & Koesyanto, 2023). Salah satu bencana besar yang pernah terjadi 5 tahun terakhir adalah gempa bumi Cianjur pada tahun 2022 dengan magnitudo sebesar 5,6, yang mengakibatkan lebih dari 53.000 rumah rusak dalam berbagai tingkat keparahan dan ratusan fasilitas umum juga rusak (Zakhra dkk., 2023). Dampak bencana tidak hanya mengancam keselamatan jiwa, tetapi juga merusak infrastruktur.

Fenomena bencana alam ini dapat dikaitkan dengan firman Allah dalam QS. At-Taghabun : 11, yang menyatakan:

مَا أَصَابَ مِنْ مُصِيبَةٍ إِلَّا بِإِذْنِ اللَّهِ وَمَنْ يُؤْمِنْ بِاللَّهِ يَهْدِ اللَّهُ قَلْبَهُ وَاللَّهُ بِكُلِّ شَيْءٍ عَلِيمٌ

“Tidak ada suatu musibah pun yang menimpa (seseorang), kecuali dengan izin Allah. Siapa yang beriman kepada Allah, niscaya Dia akan memberi petunjuk kepada hatinya. Allah Maha Mengetahui segala sesuatu.” (QS. At-Taghabun : 11).

Ayat ini mengingatkan bahwa setiap bencana atau musibah yang terjadi di bumi, termasuk kerusakan akibat bencana alam, terjadi atas izin Allah. Tidak ada satu pun peristiwa yang terjadi tanpa kehendak-Nya. Musibah bukan semata-mata akibat fenomena alam, tetapi bagian dari ketetapan Allah untuk menguji keimanan manusia. Dalam menghadapi ujian tersebut, manusia diperintahkan untuk bersabar, tetap beriman, dan mengambil hikmah dari setiap kejadian. Oleh karena itu, diperlukan upaya ilmiah dan teknologi untuk memperbaiki dampak bencana dan mempercepat proses pemulihan.

Salah satu langkah penting dalam upaya pemulihan pascabencana adalah identifikasi tingkat kerusakan bangunan. Saat ini, metode yang umum digunakan masih bersifat manual, yaitu dengan inspeksi visual oleh tenaga ahli. Meskipun metode ini memiliki akurasi yang baik, namun prosesnya memakan waktu lama, membutuhkan banyak tenaga ahli, dan berpotensi menghasilkan penilaian yang tidak konsisten. Oleh karena itu, diperlukan metode yang lebih efisien, akurat, dan otomatis dalam mengidentifikasi tingkat kerusakan bangunan.

Beberapa penelitian telah dilakukan untuk mengembangkan metode otomatis dalam mengidentifikasi kerusakan bangunan, salah satunya menggunakan *Convolutional Neural Network* (CNN), yang merupakan bagian dari deep learning. Misalnya, penelitian oleh (Rizki & Marina, 2019) menerapkan CNN dengan pre-trained model VGG-16 untuk mengklasifikasikan tingkat kerusakan bangunan sekolah berbasis citra. Model ini dilatih menggunakan 3.000 gambar bangunan

dengan kategori kerusakan ringan, sedang, dan berat. Hasil pengujian menunjukkan bahwa metode ini mampu mencapai akurasi hingga 67,8%, mengindikasikan bahwa CNN memiliki potensi dalam mengidentifikasi tingkat kerusakan bangunan secara otomatis. Namun, meskipun CNN efektif dalam mengenali pola gambar, metode ini memerlukan jumlah data pelatihan yang sangat besar untuk mencapai akurasi yang lebih tinggi.

Di sisi lain, metode berbasis *Technique for Order Preference by Similarity to Ideal Solution* (TOPSIS) juga telah diterapkan dalam sistem pendukung keputusan untuk menilai tingkat kerusakan bangunan pascabencana. Penelitian oleh (Safitri dkk., 2022) mengembangkan sistem berbasis TOPSIS yang dioptimalkan dengan teknik *query optimization* untuk mempercepat proses analisis data. Namun, metode ini tetap bergantung pada penilaian manual dalam menentukan parameter awal, sehingga hasil klasifikasinya bisa berbeda-beda tergantung siapa yang menilai dan kurang memiliki standar yang jelas.

Berdasarkan berbagai penelitian di atas, dapat disimpulkan bahwa metode berbasis pengolahan citra dan *machine learning* telah berkembang pesat dalam membantu proses identifikasi kerusakan bangunan. Namun, masih terdapat tantangan dalam hal akurasi, efisiensi, serta kemampuan model dalam menangani variasi tekstur dan tingkat keparahan kerusakan yang beragam. Oleh karena itu, penelitian ini akan berfokus pada pengembangan metode ekstraksi fitur tekstur menggunakan *Gabor filters*, yang dikenal efektif dalam mengenali pola tekstur pada citra digital. Dengan pendekatan ini, diharapkan dapat diperoleh model *clustering* yang efisien dalam menentukan tingkat kerusakan bangunan

pascabencana, sehingga dapat digunakan sebagai alat bantu dalam penanggulangan bencana dan perencanaan rekonstruksi yang lebih baik.

Gabor filters adalah salah satu metode dalam pengolahan citra yang digunakan untuk mengekstraksi fitur pada gambar. Secara teknis, filter ini merupakan kombinasi antara gelombang *sinusoidal* kompleks yang berorientasi dengan amplop *Gaussian* 2D sebagai modulasi, sehingga menghasilkan representasi fitur yang mempertahankan informasi frekuensi dan spasial secara optimal (Sulistyaningrum dkk., 2021). Dalam berbagai penelitian, *Gabor filters* telah terbukti mampu menangkap informasi penting dari citra digital, terutama dalam aplikasi seperti pengenalan wajah (Sudhakar & Nithyanandam, 2017) dan klasifikasi gambar (Rizvi dkk., 2016). Dalam konteks identifikasi kerusakan bangunan, *Gabor filters* dapat digunakan untuk mengekstraksi fitur tekstur dari gambar bangunan pascabencana, sehingga memungkinkan sistem untuk mengenali pola kerusakan pada berbagai tingkat keparahan. Dengan kemampuannya dalam menganalisis tekstur secara akurat, metode ini berpotensi meningkatkan kinerja sistem *clustering* otomatis dalam menentukan tingkat kerusakan bangunan secara lebih cepat dan efisien.

Untuk *clustering* pada penelitian ini menggunakan menggunakan *Principal Component Analysis* (PCA) *clustering*. PCA adalah metode statistik yang digunakan untuk menyederhanakan data menjadi bentuk yang lebih sederhana tanpa menghilangkan informasi penting di dalamnya (Troccoli dkk., 2022). Biasanya PCA digunakan untuk mereduksi dimensi data, tetapi dalam konteks ini PCA dimanfaatkan untuk mengelompokkan data berdasarkan hasil komponen

utama (*principal component*) tanpa bantuan metode *clustering* lain. Teknik ini telah diterapkan dalam penelitian oleh (Almais dkk., 2023), di mana PCA digunakan untuk melihat pola penyebaran data kerusakan bangunan dan kemudian menentukan label kerusakan berdasarkan rentang nilai tertentu dari komponen utama (PC1). Misalnya, data dengan nilai PC1 di bawah 0 dikategorikan sebagai kerusakan ringan, antara 0 hingga kurang dari 2 sebagai kerusakan sedang, dan di atas 2 sebagai kerusakan berat. Pendekatan ini terbukti dapat membantu proses pelabelan data secara otomatis, akurat, dan efisien tanpa perlu data berlabel secara manual.

Penelitian ini bertujuan untuk mengembangkan metode identifikasi tingkat kerusakan bangunan pascabencana berdasarkan ekstraksi fitur menggunakan *Gabor filters*. Diharapkan bahwa metode ini dapat membantu proses evaluasi kerusakan bangunan dengan lebih cepat dan akurat, sehingga dapat digunakan sebagai alat bantu dalam mitigasi bencana dan perencanaan rekonstruksi. Selain itu, hasil penelitian ini juga diharapkan dapat berkontribusi dalam pengembangan teknologi pengolahan citra untuk bidang kebencanaan dan infrastruktur.

1.2 Rumusan Masalah

Berdasarkan latar belakang diatas, maka didapat rumusan masalah sebagai berikut:

1. Bagaimana metode ekstraksi fitur menggunakan *Gabor filters* dan PCA *clustering* dapat digunakan untuk mengidentifikasi tingkat kerusakan bangunan pascabencana?

2. Seberapa baik performa model dalam *clustering* tingkat kerusakan bangunan berdasarkan fitur yang diekstraksi menggunakan *Gabor filters*?

1.3 Batasan Masalah

Batasan masalah dalam penelitian ini adalah sebagai berikut:

1. Penelitian ini hanya difokuskan pada pengolahan tekstur gambar bangunan rusak pascabencana, di mana ekstraksi fiturnya menggunakan *Gabor filters* dan di-*clustering* menggunakan metode PCA.
2. Hasil *clustering* kerusakan bangunan dikategorikan menjadi *cluster 0*, *cluster 1*, dan *cluster 2*.
3. Dataset yang digunakan terbatas pada gambar bangunan pascabencana.

1.4 Tujuan Penelitian

Penelitian ini bertujuan untuk:

1. Mengembangkan metode identifikasi tingkat kerusakan bangunan pascabencana dengan menggunakan ekstraksi fitur berbasis *Gabor filters* dan PCA *clustering*.
2. Mengimplementasikan metode yang diusulkan untuk melakukan *clustering* tingkat kerusakan bangunan.

1.5 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

1. Menambah wawasan dalam bidang pengolahan citra digital khususnya dalam ekstraksi fitur menggunakan *Gabor filters* untuk sistem *clustering* kerusakan bangunan.

2. Menjadi referensi bagi penelitian selanjutnya dalam pengembangan metode untuk analisis kerusakan bangunan pascabencana.
3. Membantu pemerintah, lembaga kebencanaan, dan tim penanggulangan bencana dalam mengevaluasi tingkat kerusakan bangunan secara lebih cepat dan praktis.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terkait

Penelitian terkait ini sangat penting untuk dapat mengembangkan metode yang lebih sistematis dalam mengelompokkan kerusakan bangunan pascabencana. Dalam 5 tahun terakhir ini telah banyak peneliti yang melakukan penelitian terkait kerusakan bangunan, PCA, maupun mengenai *Gabor filters*. Berikut beberapa penelitian terkait tersebut

Tabel 2. 1 Penelitian Terkait

Nama Penulis	Topik Penelitian	Metode	Hasil
(Rastiveis dkk., 2023)	Pemetaan kerusakan perkotaan akibat gempa menggunakan citra satelit dan CNN berbasis <i>Gabor filters</i>	<i>Gabor filters</i> dan <i>Convolutional Neural Networks</i> (CNN)	Akurasi deteksi puing 95%. <i>Labeling</i> bangunan 84% dan jalan 87% dibanding peta manual.
(Minarno dkk., 2021)	Klasifikasi COVID-19 menggunakan <i>Gabor Filter</i> dan CNN dengan <i>Hyperparameter Tuning</i>	<i>Gabor Filter</i> , <i>Convolutional Neural Networks</i> (CNN), dan <i>Hyperparameter Tuning</i>	Penelitian ini menghasilkan akurasi 97,9% dan AUC 99%. Model dengan <i>Gabor Filter</i> dan <i>Hyperparameter Tuning</i> lebih unggul dibanding model tanpa tuning.
(Aristoteles dkk., 2021)	Identifikasi ikan mas (<i>Carassius Auratus</i>) menggunakan <i>Gabor Filter</i>	<i>Gabor filters</i> dan <i>Probability Neural Network</i> (PNN)	Menghasilkan akurasi sebesar 100% dalam identifikasi spesies ikan mas. Parameter kernel, frekuensi, orientasi, dan <i>downsample</i> berpengaruh.

Nama Penulis	Topik Penelitian	Metode	Hasil
(Sulistyaningrum dkk., 2021)	Pengukuran dimensi retak pada jalan aspal menggunakan <i>Gabor filters</i>	<i>Gabor filters</i>	Pada penelitian ini menghasilkan akurasi sebesar 95.19% untuk mendeteksi panjang retakan dan 87.94% untuk mendeteksi lebar retakan.
(Almais dkk., 2023)	<i>Clustering</i> data tingkat kerusakan pascabencana menggunakan PCA	<i>Principal Component Analysis</i> (PCA)	PCA menghasilkan tiga kluster berdasarkan skala nilai. PCA- <i>Cluster</i> menunjukkan distribusi yang sesuai dengan data asli.
(Purnamasari dkk., 2025)	<i>Clustering</i> tingkat kerusakan bangunan pascabencana menggunakan DWT dan PCA	<i>Discrete Wavelet Transform</i> (DWT) dan PCA	Menghasilkan akurasi sebesar 100% berdasarkan validasi <i>surveyor</i> . DWT dan PCA efektif untuk klasifikasi kerusakan.
(Almais dkk., 2025)	Evaluasi kerusakan bangunan pascabencana menggunakan PCA- <i>Clustering</i> dan <i>Watershed Segmentation</i>	PCA- <i>Clustering</i> dan <i>Watershed Segmentation</i>	Augmentasi gambar mengatasi kelemahan <i>watershed</i> . Variasi ukuran gambar tidak mempengaruhi akurasi penilaian kerusakan.
(Almais dkk., 2024)	Karakterisasi kerusakan struktural bangunan pascabencana menggunakan GLCM-PCA	GLCM (<i>Gray Level Co-occurrence Matrix</i>) dan PCA	PCA-GLCM pada jarak 0.5 pixel menghasilkan informasi akurat terkait kerusakan berat dengan visualisasi 2D dan 3D.
Penelitian saat ini	Identifikasi Tingkat Kerusakan Bangunan Pascabencana Menggunakan <i>Gabor filters</i> dan PCA <i>Clustering</i>	<i>Gabor filters</i> dan <i>Principal Component Analysis</i> (PCA) <i>Clustering</i>	Menggunakan <i>Gabor filters</i> untuk ekstraksi fitur tekstur dan PCA untuk <i>clustering</i> tingkat kerusakan bangunan.

Berdasarkan tabel 2.1 diatas, terdapat banyak penelitian tentang kerusakan bangunan, *Gabor filters*, maupun PCA. Penelitian oleh (Rastiveis dkk., 2023), yang menghasilkan akurasi sebesar 95% dalam mengidentifikasi kerusakan bangunan menggunakan *Gabor filters* dan CNN. Sedangkan penelitian dengan metode yang sama dilakukan oleh (Minarno dkk., 2021) dalam klasifikasi Covid-19 menghasilkan akurasi sebesar 97,9%. Penelitian (Sulistyaningrum dkk., 2021) menghasilkan tingkat akurasi sebesar 95,19% dalam mendeteksi retakan jalan serta mengkonfirmasi bahwa *Gabor filters* dapat digunakan untuk analisis tekstur permukaan yang berguna dalam mendeteksi pola kerusakan bangunan.

Dalam penelitian (Almais dkk., 2023) membuktikan bahwa distribusi hasil *clustering* sesuai dengan data target yang menunjukkan bahwa PCA tidak hanya dapat digunakan untuk reduksi dimensi, namun juga dapat digunakan untuk proses pelabelan data yang tidak berlabel. Penelitian oleh (Purnamasari dkk., 2025) menghasilkan akurasi sempurna sebesar 100% dalam mengklasifikasi kerusakan bangunan dengan menggunakan *Discrete Wavelet Transform* (DWT) dan PCA.

Berdasarkan penelitian-penelitian terkait diatas, metode *Gabor filters* dan PCA *Clustering* dipilih dalam penelitian ini karena keunggulannya dalam mengenali pola tekstur dan pengelompokan tingkat kerusakan bangunannya. *Gabor filters* membantu mendeteksi pola tekstur pada bangunan yang rusak, sementara PCA *Clustering* untuk mengelompokkan tingkat kerusakan bangunan tanpa memerlukan data label awal. Dengan menggabungkan kedua metode ini, penelitian ini diharapkan dapat memberikan hasil yang lebih akurat, efisien, dan dapat diandalkan untuk mengidentifikasi tingkat kerusakan bangunan pascabencana.

2.2 Bencana Alam

Bencana alam merupakan peristiwa yang terjadi akibat fenomena alam yang ekstrem, seperti gempa bumi, tsunami, banjir, tanah longsor, dan badai. Indonesia adalah salah satu negara dengan tingkat kerawanan bencana yang tinggi karena letaknya yang berada di antara tiga lempeng tektonik utama, yaitu Eurasia, Indo-Australia, dan Pasifik (Imelda dkk., 2024). Selain itu, Indonesia juga termasuk dalam Cincin Api Pasifik, yaitu jalur yang memiliki banyak gunung berapi aktif dan sering mengalami aktivitas seismic (Marbun dkk., 2024).

Kondisi geografis ini menyebabkan Indonesia sering mengalami gempa bumi dan letusan gunung berapi, yang pada akhirnya dapat memicu tsunami, tanah longsor, serta bencana lainnya. Akibatnya, infrastruktur dan bangunan di daerah rawan bencana berisiko mengalami kerusakan yang signifikan. Kerusakan ini dapat mengakibatkan dampak sosial dan ekonomi yang besar, seperti hilangnya tempat tinggal, terganggunya aktivitas ekonomi, serta meningkatnya jumlah korban jiwa.

Dalam penelitian ini, fokus utama adalah mengidentifikasi tingkat kerusakan bangunan pascabencana. Tingkat kerusakan dapat dikelompokkan ke dalam beberapa level sesuai hasil analisis *clustering*. *Clustering* ini sangat penting untuk membantu proses pemulihan pascabencana dan merancang strategi rekonstruksi yang lebih efektif. Dengan bantuan teknologi pengolahan citra digital, analisis dapat dilakukan secara otomatis melalui ekstraksi fitur dari citra bangunan yang terdampak, sehingga proses identifikasi menjadi lebih cepat dan akurat.

2.3 Preprocessing

Preprocessing dalam pengolahan citra adalah tahap awal untuk menyiapkan gambar agar lebih mudah dianalisis (Chakraborty dkk., 2021). Tujuannya supaya gambar menjadi lebih jelas dan rapi, sehingga proses pengambilan fitur penting dari gambar bisa dilakukan dengan lebih akurat dan efisien. Pada tahap ini dilakukan untuk mengurangi *noise*, menyamakan ukuran citra, serta menyamakan format data supaya hasil ekstraksi fitur menjadi konsisten.

Preprocessing pada pengolahan citra dapat dilakukan melalui beberapa tahapan. Tahap pertama adalah konversi citra ke *greyscale*, yaitu proses mengubah gambar berwarna tiga dimensi menjadi gambar skala abu-abu satu dimensi, sehingga informasi warna pada gambar hilang dan hanya tingkat kecerahan yang dipertahankan (Xie dkk., 2023). Hal ini bertujuan untuk menyederhanakan komputasi karena metode *Gabor filters* hanya memerlukan nilai intensitas, bukan warna. Rumus dasar *greyscale* dapat ditulis sebagai berikut (Sabini, 2021):

$$Gray = (0,299 * R) + (0,587 * G) + (0,114 * B) \quad (2.1)$$

Keterangan :

R = nilai ntensitas warna merah

G = nilai intensitas warna hijau

B = nilai intensitas warna biru

Tahap kedua adalah penyamaan ukuran citra atau *resize*. *Resize* dilakukan supaya seluruh data memiliki ukuran yang sama, sehingga hasil konvolusi antara kernel Gabor dan citra menjadi setara antar semua gambar. Terdapat beberapa metode interpolasi dalam *resize* citra, berikut macam-macam metode interpolasi:

- a. Nearest Neighbor Interpolation

Cara kerja metode *Nearest Neighbor* adalah dengan mengambil nilai dari piksel terdekat tanpa melakukan perhitungan tambahan (Koiku & Muñoz-Coreas, 2024). Cara ini sangat cepat dan sederhana, namun hasilnya sering terlihat kasar. Metode ini cocok digunakan untuk gambar sederhana seperti citra biner yang hanya memiliki dua warna.

b. Bilinear Interpolation

Metode *Bilinear* menggunakan rata-rata dari empat piksel di sekitar titik baru untuk menghasilkan nilai piksel yang lebih halus. Hasilnya lebih lembut dibandingkan metode *Nearest Neighbor*, tetapi terkadang sedikit mengaburkan detail pada gambar. Metode ini umumnya digunakan untuk memperbesar gambar dengan kualitas yang cukup baik.

c. Bicubic Interpolation

Metode *Bicubic* melibatkan enam belas piksel terdekat dalam perhitungannya dan menggunakan fungsi matematis berbentuk kubik. Cara ini menghasilkan gambar yang lebih halus dan detail dibandingkan *Bilinear*, namun memerlukan waktu komputasi yang lebih lama. Metode ini cocok untuk memperbesar gambar dengan kualitas tinggi.

d. Area-based Interpolation


Cara kerja metode *Area-based* yaitu dengan cara menghitung rata-rata nilai piksel dalam suatu area tertentu. Metode ini sangat efektif digunakan saat gambar diperkecil karena mampu menghasilkan tampilan yang halus tanpa menyebabkan gambar tampak buram. Namun, untuk memperbesar gambar, hasilnya kurang optimal dibandingkan metode *Bicubic* atau *Bilinear*.

Melalui tahapan preprocessing ini, citra masukan menjadi lebih bersih, seragam, dan siap untuk diproses menggunakan *Gabor filters*.

2.4 *Gabor filters*


Gabor filters adalah metode ekstraksi fitur berbasis transformasi gelombang yang banyak digunakan dalam analisis citra (Andini dkk., 2020). Filter ini dirancang untuk meniru respons sel kompleks dalam sistem visual manusia terhadap orientasi dan frekuensi spasial tertentu. Dengan demikian, *Gabor filters* sangat efektif dalam menangkap informasi tekstur dari suatu citra, terutama dalam mengidentifikasi pola yang berulang atau detail tekstur yang sulit dikenali oleh metode konvensional.

Secara matematis, *Gabor filters* dua dimensi merupakan fungsi kernel *Gaussian* yang dimodulasi oleh gelombang bidang *sinusoidal* dalam domain spasial (Sulistyaningrum dkk., 2021). Kernel *Gaussian* berfungsi sebagai pembungkus (envelope) dari fungsi gelombang.



Gambar 2. 1 *Gaussian Envelope*

Sedangkan gelombang *sinusoidal* adalah gelombang yang memodelkan frekuensi dan arah tertentu. Fungsi sinusoidal ini berperan sebagai pendeteksi pola dalam gambar, seperti garis atau tekstur berulang dalam arah tertentu. Berikut gambar dari *sinusoidal* kompleks:



Gambar 2. 2 Bagian riil (a) dan imajiner (b) dari sinusoidal kompleks (Marmol & Borowiec, 2020)

Gabor Filter yang didefinisikan dengan rumus berikut:

$$g(x, y) = \exp\left(-\frac{x'^2 + \gamma y'^2}{2\sigma^2}\right) \cos\left(2\pi \frac{x'}{\lambda} + \varphi\right) \quad (2.2)$$

Dengan,

$$x' = x \cos \theta + y \sin \theta \quad (2.3)$$

$$y' = -x \sin \theta + y \cos \theta \quad (2.4)$$

Keterangan :

θ = sudut orientasi filter

λ = panjang gelombang sinusoidal

σ = standar deviasi Gaussian

φ = fase offset. Nilai yang valid berada di antara $-\pi$ hingga π

γ = rasio aspek spasial y , dengan nilai default 0.5

Pada *Gabor Filter* terdapat proses untuk menghasilkan gambar baru yang melalui proses konvolusi gabor dengan rumus berikut:

$$S(x, y) = \sum_{i=-m}^m \sum_{j=-n}^n I(x + i, y + j) \cdot K(i, j) \quad (2.5)$$

Keterangan :

$S(x, y)$ = Hasil konvolusi di titik koordinat (x, y)

$I(x + i, y + j)$ = nilai piksel dari gambar pada titik sekitar (x, y)

$K(i, j)$ = nilai kernel pada titik (i, j)

m, n = setengah ukuran kernel

Hasil dari konvolusi kemudian dilakukan normalisasi min-max supaya data menjadi lebih seragam dan mudah diolah. Berikut rumus min-max normalisasi:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2.6)$$

Keterangan :

x_{norm} = Nilai Hasil Normalisasi

x = nilai asli data

x_{min} = nilai minimum

x_{max} = nilai maksimum

Gabor filters memiliki keunggulan dalam mendeteksi fitur tekstur pada berbagai skala dan orientasi. Dengan menerapkan berbagai parameter pada filter, dapat diperoleh informasi yang lebih kaya dari suatu citra, memungkinkan analisis yang lebih mendalam terhadap kondisi permukaan objek.

Dalam konteks identifikasi kerusakan bangunan pascabencana, *Gabor filters* digunakan untuk mengekstraksi pola-pola tekstur dari citra bangunan yang terdampak. Misalnya, perbedaan antara bangunan yang masih utuh dan yang mengalami kerusakan parah dapat dikenali berdasarkan perubahan pola tekstur yang ditangkap oleh filter ini. Setelah ekstraksi fitur dilakukan, data yang dihasilkan

dapat digunakan dalam proses analisis lebih lanjut, seperti klasifikasi dan *clustering* tingkat kerusakan.

2.5 Ekstraksi Fitur

Tahap ekstraksi fitur dilakukan setelah citra diproses dengan Gabor Filter. Tujuan tahap ini adalah mengambil nilai-nilai penting dari hasil respon Gabor yang dapat menggambarkan karakteristik tekstur pada citra bangunan. Hasil respon Gabor berupa nilai intensitas atau magnitude yang menunjukkan seberapa kuat filter merespons pola tertentu pada citra. Dari respons tersebut, kemudian diekstraksi sejumlah fitur statistik untuk merepresentasikan pola tekstur, antara lain:

1. Kontras (*Contrast*)

Kontras merupakan ukuran tingkat perbedaan atau penyebaran nilai intensitas piksel dalam suatu citra. Semakin besar kontras, semakin tinggi variasi nilai piksel yang ada, yang biasanya menunjukkan adanya tekstur yang kasar atau tidak seragam. Dalam konteks citra bangunan, nilai kontras yang tinggi dapat mengindikasikan adanya retakan, patahan, atau puing-puing yang menimbulkan variasi tajam pada tekstur permukaan. Secara matematis, kontras dihitung dengan standar deviasi dari nilai intensitas piksel (Sari dkk., 2016):

$$Contrast = \sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (2.7)$$

Keterangan :

N = jumlah piksel dalam citra

x_i = nilai intensitas piksel ke – i

μ = rata – rata intensitas citra

σ = standar devian, yang menjadi ukuran kontras

2. Mean

Mean digunakan untuk mengukur rata-rata intensitas atau tingkat kecerahan pada suatu citra. Nilai *mean* menunjukkan seberapa terang atau gelap keseluruhan tampilan gambar. Citra dengan nilai *mean* tinggi cenderung memiliki tingkat kecerahan yang tinggi (lebih terang), sedangkan nilai *mean* rendah menandakan citra yang lebih gelap. Dalam analisis kerusakan bangunan, nilai *mean* dapat merepresentasikan tingkat reflektivitas permukaan material bangunan—bangunan yang rusak parah biasanya memiliki nilai *mean* lebih rendah karena permukaannya tidak lagi memantulkan cahaya secara merata akibat adanya retakan, kotoran, atau bayangan. Nilai *mean* dihitung menggunakan rumus (Sari dkk., 2016):

$$\mu = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N x_{ij} \quad (2.8)$$

Keterangan :

μ = nilai rata – rata (*mean*) pada respon Gabor

P_{ij} = nilai piksel hasil respon gabor pada posisi (i,j)

M = tinggi citra

N = lebar citra

3. Energi (*Energy*)

Energi merupakan ukuran yang menggambarkan kekuatan suatu pola tekstur pada skala atau orientasi tertentu. Nilai energi yang tinggi menandakan adanya pola dominan yang kuat dalam citra, sedangkan nilai energi yang rendah menunjukkan pola tekstur yang lemah atau tidak konsisten. Dalam konteks kerusakan bangunan, energi yang tinggi dapat menunjukkan adanya pola tekstur

yang tajam, misalnya pola retakan atau pecahan pada bangunan, sementara energi rendah sering terlihat pada area yang relatif rata dan tidak banyak mengalami perubahan struktur. Rumus energi dapat dituliskan sebagai berikut (Sari dkk., 2016):

$$Energy = \sum_{i=1}^N x_i^2 \quad (2.9)$$

Keterangan :

N = jumlah piksel dalam citra
 x_i = nilai intensitas piksel ke – i
 $\sum x_i^2$ = jumlah kuadrat dari seluruh intensitas piksel

Melalui proses ekstraksi fitur ini, informasi dari citra diubah menjadi data numerik yang lebih mudah dianalisis. Nilai-nilai fitur tersebut nantinya akan digunakan dalam tahap *clustering*, untuk membantu pengelompokan tingkat kerusakan bangunan pascabencana secara lebih akurat.

2.6 Clustering

Clustering merupakan salah satu metode dalam pembelajaran tanpa pengawasan atau *unsupervised learning* yang digunakan untuk mengelompokkan data ke dalam beberapa kelompok berdasarkan tingkat kemiripannya (B dkk., 2020). Data yang memiliki karakteristik serupa akan berada dalam satu kelompok atau dalam satu *cluster*, sedangkan data yang berbeda akan masuk ke kelompok lain. Data yang awalnya acak dapat tersusun menjadi kelompok yang lebih teratur dan mudah dipahami.

Tujuan utama dari *clustering* adalah menemukan pola atau hubungan tersembunyi di dalam data tanpa memerlukan label kelas tertentu (Kangane dkk., 2021). Metode ini membantu menyederhanakan data yang kompleks menjadi beberapa kelompok yang memiliki arti atau karakteristik masing-masing. Dalam penelitian ini, *clustering* digunakan untuk mengelompokkan tingkat kerusakan bangunan pascabencana berdasarkan kemiripan nilai fitur yang dihasilkan dari proses ekstraksi menggunakan *Gabor filters* dan hasil reduksi dimensi melalui PCA.

Ada beberapa jenis metode *clustering* yang umum digunakan, di antaranya (Velunachiyar & Sivakumar, 2023):

1. *Partitioning-based method*, yaitu metode yang bekerja dengan cara membagi seluruh data menjadi beberapa kelompok yang terpisah. Setiap data hanya bisa masuk ke satu kelompok, tidak boleh ganda. Tujuan utamanya adalah membuat data dalam satu *cluster* menjadi sesama yang paling mirip, dan sejauh mungkin dari data di *cluster* lain. Contoh algoritma yang menggunakan metode ini adalah *K-Means*, *K-Medoids*, dan *CLARANS*.
2. *Hierarchical method*, yaitu metode yang mengelompokkan data dengan membentuk struktur bertingkat seperti pohon yang disebut dendrogram. Prosesnya bisa dilakukan dari bawah ke atas (*agglomerative*), yaitu setiap data awalnya menjadi *cluster* sendiri lalu digabung berdasarkan kemiripan, atau dari atas ke bawah (*divisive*), yaitu seluruh data dijadikan satu *cluster* besar lalu dipecah menjadi beberapa kelompok kecil. Beberapa algoritma

yang menggunakan pendekatan ini misalnya CURE, BIRCH, ROCK, dan CHAMELEON

3. *Density-Based Method*, yaitu metode yang bekerja dengan cara membentuk *cluster* berdasarkan kepadatan data di suatu wilayah. Area yang memiliki banyak titik data dianggap sebagai satu *cluster*, sedangkan area yang jarang atau kosong dianggap sebagai noise. Contoh algoritma yang menggunakan metode ini antara lain DBSCAN, OPTICS, dan DENCLUE.
4. *Grid-Based Method*, metode ini bekerja dengan membagi ruang data ke dalam kotak-kotak atau sel (*grid*). Setiap sel mewakili area tertentu dari ruang data, dan pengelompokan dilakukan berdasarkan kepadatan titik pada masing-masing sel tersebut. Beberapa algoritma yang termasuk dalam kategori ini misalnya CLIQUE, STING, dan *WaveCluster*.
5. *Distribution model-based method*, metode ini bekerja dengan cara mengasumsikan bahwa data terbentuk dari model statistik tertentu, seperti distribusi normal. Tujuannya adalah menemukan parameter model yang paling sesuai dengan data yang ada. Contoh algoritma yang termasuk dalam metode ini antara lain EM (*Expectation-Maximization*), *AutoClass*, COBWEB, CLASSIT, dan SOM.

Untuk menilai seberapa baik hasil *clustering*, salah satu ukuran yang sering digunakan adalah *Silhouette score*. Nilai ini menunjukkan seberapa tepat suatu data ditempatkan dalam *cluster*-nya. Nilai yang mendekati 1 menunjukkan bahwa data tersebut sesuai dengan kelompoknya, sedangkan nilai yang mendekati -1 menandakan kemungkinan salah pengelompokan (Shahapure & Nicholas, 2020).

2.7 Principal Component Analysis (PCA)

Principal Component Analysis (PCA) adalah teknik statistik yang digunakan untuk mengurangi dimensi data dengan tetap mempertahankan informasi yang paling penting (Almais dkk., 2023). Metode ini bekerja dengan mengubah kumpulan variabel yang berkorelasi menjadi kumpulan variabel yang tidak berkorelasi yang disebut *principal components*.

Proses PCA dimulai dengan melakukan normalisasi data. Berikut rumus dari normalisasi data yang menggunakan *Standar Scale*:

$$X_{standar} = \frac{X - \bar{X}(x)}{standar\ devian(x)} \quad (2.10)$$

Dengan nilai,

$$\bar{X} = \frac{\sum_{i=1}^n Xi}{n} \quad (2.11)$$

Dan nilai,

$$Standar\ devian(x) = \frac{\sum_{i=1}^n (Xi - \bar{X})^2}{n - 1} \quad (2.12)$$

Keterangan :

$X_{standar}$ = *Standar Scale*

n = *jumlah data*

x = *data*

$\bar{x}$ = *rata – rata*

Setelah itu, matriks kovarians dihitung menggunakan persamaan berikut (Hediyati & Suartana, 2021):

$$C = \frac{1}{(n-1)} \sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})^T \quad (2.13)$$

Keterangan :

C = matriks kovarians

n = jumlah data

x_i = data ke - i

$\bar{x}$ = rata - rata

Setelah itu, nilai *eigenvector* dan *eigenvalue* dihitung menggunakan persamaan berikut (Hediyati & Suartana, 2021):

$$\det(C - \lambda I) = 0 \quad (2.14)$$

$$C_v = \lambda_v \quad (2.15)$$

Keterangan :

C = matriks kovarians

λ = nilai eigen

v = vektor eigen

Setelah menemukan *eigenvector* dan *eigenvalue*, yaitu menentukan komponen utama berdasarkan nilai *variance ratio* tertinggi, berikut rumus *variance ratio*:

$$S^2 = \frac{\sum_{i=1}^n (X_i - \mu)^2}{n-1} \quad (2.16)$$

Keterangan :

S = Variance Ratio

n = jumlah data

x_i = data ke - i

μ = rata - rata

Dalam penelitian ini, PCA digunakan untuk menyederhanakan fitur yang telah diekstraksi dari gambar bangunan menggunakan *Gabor filters*. PCA juga membantu mengelompokkan data berdasarkan pola yang terbentuk, sehingga memudahkan identifikasi tingkat kerusakan bangunan.


BAB III

METODE PENELITIAN

3.1 Desain Sistem

Dalam pengembangan sistem ini, tahap desain menjadi bagian penting karena menentukan bagaimana sistem akan bekerja dalam memproses data citra bangunan yang rusak. Desain sistem mencakup beberapa aspek utama, seperti alur kerja sistem, metode ekstraksi fitur menggunakan *Gabor filters*, serta teknik *clustering* yang digunakan untuk mengelompokkan tingkat kerusakan ke dalam tiga *cluster*, yaitu *cluster 0*, *cluster 1*, dan *cluster 2*. Dengan perancangan yang baik, diharapkan sistem dapat memberikan hasil yang akurat dan dapat diandalkan dalam menganalisis tingkat kerusakan bangunan pascabencana.

Dalam implementasinya, sistem ini menggunakan bahasa pemrograman Python karena menyediakan berbagai *library* yang sangat membantu dalam pengolahan gambar digital serta analisis data. Dalam penelitian ini, digunakan beberapa *library* utama seperti *NumPy* yang berperan penting untuk mengelola dan memproses data numerik. Untuk keperluan visualisasi data dalam bentuk grafik 2D dan 3D, digunakan *Matplotlib* agar hasil analisis lebih mudah dipahami. Proses pemrosesan dan pemanggilan dataset juga dipermudah dengan adanya *library* seperti *Glob*, *OS*, dan *CSV*, yang memungkinkan akses otomatis ke file gambar dan data fitur dari direktori penyimpanan. Selain itu, fungsi-fungsi matematika dasar dari *library Math* turut digunakan untuk mendukung perhitungan yang diperlukan selama ekstraksi dan analisis fitur gambar.



Gambar 3. 1 Desain Sistem

Berikut penjelasan tahapan desain sistem di atas:

3.1.1 *Preprocessing*

Pada tahap *preprocessing*, gambar dibaca oleh sistem dari dataset yang telah disiapkan. Setelah itu, gambar dikonversi ke dalam format *grayscale*. *Grayscale* adalah proses mengubah gambar berwarna yang terdiri dari tiga warna RGB menjadi satu intensitas warna yaitu abu-abu. Gambar dengan format *grayscale* lebih akurat dari pada gambar RGB (Bui dkk., 2016). Rumus dari konversi dari citra RGB ke grayscale terdapat pada rumus 2.1.

Setelah proses *grayscale*, kemudian gambar di-*resize* menjadi 128x128 piksel. *Resize* dilakukan supaya semua gambar memiliki ukuran yang sama dan

menghasilkan jumlah fitur yang sama. Ukuran 128x128 piksel didasari penelitian yang pernah dilakukan oleh (Marinov dkk., 2021), yang menghasilkan bahwa ukuran 128x128 piksel merupakan ukuran yang paling optimal dalam akurasi dan waktu.



Gambar 3. 2 Perbedaan Gambar *Preprocessing*

3.1.2 *Gabor filters*

Pada tahap ini, dilakukan ekstraksi fitur yang menggunakan *Gabor filters*. Komponen utama dalam Gabor terdiri dari frekuensi, orientasi dan kernel *Gaussian* (Aristoteles dkk., 2021). Ekstraksi fitur dalam *Gabor filters* terdiri dari beberapa tahap, yaitu inisialisasi parameter, kernel Gabor, konvolusi gabor dan titik fitur.

1. Inisialisasi Parameter

Pada tahap pertama yaitu inisialisasi parameter. Untuk parameter yang digunakan adalah V (banyaknya frekuensi), U (banyaknya orientasi), dan ukuran kernel. Untuk mendapatkan nilai frekuensi sebanyak U dan nilai orientasi sebanyak V, menggunakan rumus f_u dan θ_v berikut ini:

$$f_u = \frac{f_{max}}{\sqrt{2^u}}, \quad u = 0, 1, 2, \dots, U - 1 \quad (3.2)$$

$$\theta_v = \frac{v\pi}{V}, \quad v = 0, 1, 2, \dots, V - 1 \quad (3.3)$$

Keterangan :

f_{max} = frekuensi puncak maksimum

U = jumlah skala
 V = jumlah orientasi


Frekuensi akan mempengaruhi jarak pola fitur yang dihasilkan. Semakin kecil nilai frekuensi (f), semakin lebar atau besar pola/fitur yang ditangkap (karena panjang gelombangnya besar). Semakin besar nilai frekuensi (f), semakin kecil dan halus detail yang ditangkap (karena panjang gelombangnya kecil). (Wijaya, 2017). Sedangkan orientasi digunakan untuk mengatur arah fitur *Gabor filters*. Sedangkan ukuran kernel yang digunakan adalah 7×7 . Karena dari hasil penelitian yang pernah dilakukan (Aristoteles dkk., 2021), ukuran tersebut menghasilkan akurasi yang tertinggi.

2. Pembuatan Kernel Gabor

Tahap kedua adalah pembuatan kernel gabor yang dibentuk berdasarkan kombinasi parameter panjang gelombang, orientasi, dan ukuran kernel. Setiap kernel dibentuk berdasarkan kombinasi frekuensi yaitu seberapa rapat pola dan orientasi yaitu arah sudutnya, seperti horizontal, vertikal, atau diagonal (Aristoteles dkk., 2021). Jika menggunakan kombinasi 3 frekuensi dan 5 orientasi, maka akan menghasilkan 15 filter yang berbeda-beda sesuai frekuensi dan orientasinya.

3. Konvolusi Gabor

Tahap ketiga dalam ekstraksi fitur ini adalah konvolusi gabor yaitu proses penghitungan setiap kernel mulai dari kiri atas kemudian digeser ke seluruh bagian gambar, satu piksel ke piksel lainnya dari kiri atas hingga ke posisi kanan bawah (Aristoteles dkk., 2021). Hasil ini disimpan sebagai gambar baru, yaitu sebagai gambar hasil filter.



Gambar 3. 3 Contoh Hasil *Gabor filters* 8 Orientasi dan 2 Skala Frekuensi (Li dkk., 2023)

Karena hasil konvolusi gabor masih berupa bilangan kompleks, maka dilakukan *magnitude* untuk menjadikan bilangan riil. Berikut rumus *magnitude* (modulus):

$$|z| = \sqrt{a^2 + b^2} \quad (3.4)$$

Keterangan :

$z = a + bi \rightarrow$ Bilangan kompleks
 $a =$ bagian real (real part)
 $b =$ bagian imajiner (imaginary part)

Setelah itu dilakukan normalisasi *Min–Max* pada data *magnitude* digunakan untuk menskalakan nilai piksel ke dalam rentang $[0,1]$. Berikut rumusnya:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3.5)$$

Keterangan :

$x =$ nilai asli
 $x_{min} =$ nilai minimum dari seluruh data
 $x_{max} =$ nilai maksimum dari seluruh data
 $x' =$ nilai hasil normalisasi yang berada pada rentang $[0,1]$.

Proses ini dilakukan dengan cara mengurangi setiap nilai data dengan nilai minimum, kemudian membaginya dengan selisih antara nilai maksimum dan minimum. Dengan demikian, nilai terkecil akan dipetakan menjadi 0 dan nilai terbesar menjadi 1, sedangkan nilai lain akan berada di antara keduanya.

Normalisasi ini bertujuan untuk menyeragamkan skala data sehingga lebih stabil dan optimal digunakan dalam tahap ekstraksi fitur maupun proses klasifikasi.

4. Ekstraksi Fitur

Setelah melalui tahap *magnitude* dan normalisasi, tahap keempat adalah ekstraksi fitur. Fitur yang digunakan ada 3 yaitu *contrast*, *mean*, dan *energy*. Hasil ekstraksi fitur nanti disimpan dalam file csv bersama nilai frekuensi dan orientasinya.

3.1.3 Konversi ke *Spreadsheet*

Hasil dari proses ekstraksi fitur *Gabor filters* kemudian dikonversi dan disimpan ke dalam *spreadsheet* untuk memudahkan analisis dan pemrosesan data lebih lanjut. Penyimpanan ini bertujuan agar data fitur yang telah diekstrak dapat dikelola secara sistematis dan dapat diakses dengan mudah untuk tahap berikutnya.

3.1.4 PCA

1. Normalisasi Data

Sebelum melakukan PCA, langkah pertama yang dilakukan adalah normalisasi data. Normalisasi bertujuan untuk menyamakan skala antar fitur sehingga setiap fitur memiliki nilai yang sama dan seimbang untuk setiap data. Normalisasi data yang digunakan adalah *Standar Scale* dikarenakan jenis data kerusakan bangunan menggunakan skala standar (Almais dkk., 2023).

2. Penentuan *Variance ratio* dan *Eigenvalue*

Setelah normalisasi, data dicari nilai *variance ratio* dan *eigenvalue* karena bagian penting untuk memperoleh komponen utama (*principal components*) yang

dapat menjelaskan sebagian besar variansi dalam data. *Variance ratio* merupakan ukuran yang menunjukkan seberapa besar penyebaran atau variasi data terhadap komponen utama yang terbentuk (Almais dkk., 2023). Komponen utama pertama biasanya menjelaskan sebagian besar variasi data, diikuti oleh komponen kedua dan seterusnya. Sementara itu, *eigenvalue* adalah angka yang menunjukkan seberapa besar peran *eigenvector* dalam menjelaskan sebaran data pada arah tertentu (Dar, 2021). Nilai ini berkaitan langsung dengan *eigenvector*, yaitu vektor yang menunjukkan arah dari setiap komponen utama dalam representasi data berbentuk matriks. Dalam penerapan PCA, memilih jumlah komponen utama secara tepat menjadi langkah penting karena akan berdampak langsung terhadap seberapa akurat data dapat direpresentasikan (Almais dkk., 2023). Semakin tepat pemilihan jumlah komponen, maka semakin optimal pula hasil analisis yang dihasilkan dari proses reduksi dimensi tersebut.

3. Visualisasi Data dalam 2D dan 3D

Setelah mengurangi dimensi data, langkah berikutnya adalah membuat visualisasi dalam bentuk 2D dan 3D untuk melihat bagaimana data tersebar dan apakah ada pola tertentu. Pada visualisasi 2D, data digambarkan menggunakan dua komponen utama pertama (PC1 dan PC2), sedangkan visualisasi 3D menggunakan tiga komponen utama pertama (PC1, PC2, dan PC3) (Purnamasari dkk., 2025). Visualisasi ini membantu kita memahami bentuk penyebaran data dan memudahkan dalam mengenali pola atau kelompok yang mungkin ada dalam dataset.

4. Klasterisasi Data

Klasterisasi data merupakan langkah penting dalam proses analisis data tanpa pengawasan (*unsupervised learning*), di mana data dikelompokkan ke dalam beberapa grup berdasarkan kemiripan karakteristiknya (Huang dkk., 2021). Pada tahap ini, dilakukan klasterisasi data untuk mengelompokkan gambar berdasarkan kesamaan fitur yang diekstraksi. Sebelum melakukan klasterisasi, terlebih dahulu ditentukan rentang nilai yang digunakan sebagai dasar pengelompokan. Dalam penelitian ini, rentang nilai ditentukan berdasarkan hasil koordinat dari komponen utama (*Principal Component/PC*) yang telah diperoleh melalui PCA. Berdasarkan penelitian yang dilakukan oleh (Almais dkk., 2023), klasterisasi pada PCA didapat dari nilai PC1 (n) dari setiap data dianalisis, kemudian ditentukan tiga rentang nilai yang digunakan sebagai acuan pemberian label kerusakan, yaitu:

- jika nilai n kurang dari 0 dikelompokkan sebagai *cluster* 0,
- nilai n antara 0 hingga kurang dari 2 sebagai *cluster* 1, dan
- nilai n lebih dari atau sama dengan 2 sebagai *cluster* 2.

Penelitian tersebut membuktikan bahwa klasterisasi ini menghasilkan tiga kelompok data tanpa menggunakan label awal (*unsupervised*), sehingga dapat dimanfaatkan untuk penandaan (*labeling*) data secara otomatis untuk mendukung proses identifikasi tingkat kerusakan.

3.2 Data Preparation



Gambar 3. 4 Contoh Dataset Bangunan Rusak

Dataset yang digunakan dalam penelitian ini berasal dari Badan Penanggulangan Bencana Daerah (BPBD) Kota Malang, yang menyediakan kumpulan gambar bangunan terdampak bencana di wilayah Kota Malang. Data ini diperoleh secara langsung melalui permintaan peneliti ke Unit Bidang Rehabilitasi dan Rekonstruksi BPBD Kota Malang pada tanggal 21 Maret 2025. Gambar-gambar tersebut merupakan hasil dokumentasi lapangan yang dilakukan oleh pihak BPBD sebagai bagian dari kegiatan pendataan pascabencana.

Sebagai pelengkap, digunakan pula dataset dari platform publik *Kaggle*. Dataset ini dimanfaatkan untuk memperluas variasi visual dari gambar bangunan yang mengalami kerusakan akibat bencana, sehingga sistem yang dikembangkan dapat mengenali berbagai pola tekstur dari beragam jenis bangunan dan kondisi kerusakan secara lebih menyeluruh.

Seluruh gambar dari kedua sumber tersebut selanjutnya melalui sejumlah tahapan, yaitu pra-pemrosesan citra, ekstraksi fitur dengan *Gabor filters*, dan reduksi dimensi menggunakan *Principal Component Analysis* (PCA). Tujuan dari proses ini adalah untuk mengidentifikasi tingkat kerusakan bangunan secara

otomatis berdasarkan ciri-ciri tekstur pada gambar, sehingga dapat mendukung proses analisis yang lebih efisien, sistematis, dan akurat.

3.3 Skenario Pengujian

Skenario pengujian dilakukan untuk mengevaluasi efektivitas metode ekstraksi fitur menggunakan *Gabor filters* dan teknik *clustering* dengan PCA dalam mengidentifikasi tingkat kerusakan bangunan pascabencana. Pengujian dilakukan berdasarkan dataset citra bangunan yang tidak memiliki label kelas, sehingga pendekatan yang digunakan adalah *clustering*.

Tahap pertama dalam pengujian adalah pengumpulan dan *preprocessing* data, di mana dataset citra bangunan pascabencana dikonversi ke *grayscale*, sebelum dianalisis lebih lanjut. Setelah itu, fitur tekstur diekstraksi menggunakan *Gabor filters* dengan berbagai parameter seperti frekuensi, orientasi, dan skala. Hasil ekstraksi disimpan dalam bentuk vektor fitur untuk analisis selanjutnya.

Setelah fitur diperoleh, dilakukan reduksi dimensi menggunakan *Principal Component Analysis* (PCA). Evaluasi PCA dilakukan menggunakan *Silhouette score*. *Silhouette score* merupakan metrik yang digunakan untuk mengukur kualitas *clustering* dengan menilai seberapa baik suatu data berada dalam klasternya dibandingkan dengan klaster lain (Hasan, 2024; Shahapure & Nicholas, 2020). Skor ini dihitung dengan rumus berikut (Shahapure & Nicholas, 2020):

$$S = \frac{b - a}{\max(a, b)} \quad (3.6)$$

Keterangan :

S = *Silhouette Score*

a = jarak intra klaster

b = jarak antar klater terdekat

x_{max} = nilai maksimum

Nilai *Silhouette score* berkisar antara -1 hingga 1. Nilai yang mendekati 1 menunjukkan bahwa data dikelompokkan dengan baik dalam klasternya. Nilai yang mendekati 0 menunjukkan bahwa data berada di batas antara dua klaster. Nilai yang mendekati -1 menunjukkan bahwa data lebih dekat ke klaster lain dibandingkan klaster tempatnya berada, yang menandakan *clustering* yang buruk (Shahapure & Nicholas, 2020).

BAB IV

HASIL DAN PEMBAHASAN

4.1 Uji Coba Sistem

Pada bagian ini dilakukan uji coba sistem yang telah dibangun untuk melihat bagaimana alur kerja, ekstraksi fitur menggunakan *Gabor filters*, serta proses *clustering* dengan PCA berjalan sesuai rancangan. Uji coba awal dilakukan menggunakan 1 citra bangunan dari total 30 citra dalam dataset, dengan tujuan untuk memastikan setiap tahapan dapat berjalan dengan benar sebelum diaplikasikan pada seluruh data. Melalui uji coba ini, dapat diamati bagaimana sistem mengekstraksi fitur dari citra, memprosesnya menggunakan PCA, serta mengelompokkan hasilnya ke dalam tiga *cluster* (0, 1, dan 2) secara konsisten dan sesuai dengan tujuan penelitian.

4.2 Hasil Uji Coba

Berikut hasil langkah-langkah dari proses *Gabor filters* dan PCA *Clustering*:

4.2.1 Preprocessing Data

Hal pertama yang dilakukan dalam *preprocessing* data adalah gambar di-*crop* secara manual sesuai dengan bagian objek yang menjadi fokus penelitian. *Crop* dilakukan untuk menghilangkan bagian gambar yang dapat mengganggu proses pengolahan data lebih lanjut. Setelah proses *crop* selesai, gambar dibaca ke sistem menggunakan fungsi *imread(image_path)* untuk membaca gambar ke sistem. Setelah gambar akan diubah ukurannya menjadi 128x128 piksel

menggunakan metode *resize*. *Resize* bertujuan untuk menyeragamkan ukuran gambar sehingga memudahkan proses analisis. Metode yang digunakan adalah metode pemetaan skala sederhana, di mana setiap piksel pada gambar hasil *resize* dihitung berdasarkan perbandingan posisi dengan gambar asli.



Gambar 4. 1 Data Sebelum dan Sesudah di-*Crop*

Setelah proses *resize*, gambar akan dikonversi ke *grayscale* agar mengurangi kompleksitas data. Konversi dilakukan menggunakan metode perhitungan luminasi yaitu hasil perjumlahan nilai piksel merah dikali 0.299 ditambah nilai piksel hijau dikali 0.587 dan ditambah nilai piksel biru dikali 0.114. Metode luminansi merupakan kontribusi setiap komponen warna merah (R), hijau (G), dan biru (B) dihitung berdasarkan sensitivitas mata manusia terhadap masing-masing warna. Dengan *preprocessing* ini, data gambar menjadi lebih terstruktur dan siap digunakan dalam proses analisis lebih lanjut.



Gambar 4. 2 Hasil *Resize* (kiri) dan *Grayscale* (kanan)

4.2.2 Proses *Gabor Filter*

Proses penggunaan *Gabor Filter* dilakukan melalui beberapa langkah yang berurutan. Langkah-langkah ini dimulai dari penentuan parameter, pembuatan kernel Gabor, proses konvolusi, sampai ke tahap ekstraksi fitur. Setiap langkah penting karena akan berpengaruh pada hasil akhir, yaitu seberapa baik tekstur kerusakan bangunan bisa dikenali dari citra.

a. Inisialisasi Parameter

Pada tahap ini dilakukan penentuan nilai awal parameter yang dibutuhkan oleh *Gabor Filter*. Parameter tersebut meliputi ukuran kernel, U, dan V. Ukuran kernel yang digunakan adalah 7x7. Parameter U adalah jumlah frekuensi dan V adalah jumlah orientasi. Pada tahap ini peneliti menggunakan parameter orientasi 5 yang artinya arah filternya akan diputar ke 5 arah berbeda mulai 0 radian hingga π radian. Sedangkan nilai U adalah 3, sehingga akan menghasilkan 3 nilai frekuensi. Nilai frekuensi didapat dari rumus f_u . Penentuan parameter ini penting agar filter dapat bekerja sesuai kebutuhan, misalnya bisa mendeteksi pola tekstur dari berbagai arah dan skala.

b. Pembuatan Kernel Gabor


Kernel gabor terbentuk dari pembungkus Gaussian dan gelombang sinusoidal. Hasil dari pembuatan kernel gabor ini berupa bilangan kompleks yang terdiri dari bilangan real dan imajiner. Kombinasi antara frekuensi dan orientasi menghasilkan array 3 dimensi dengan ukuran $f \times \theta$ yaitu 3×5 . Setiap elemen dalam array 3D berisi array 2D sesuai dengan ukuran kernel yaitu 7×7 . Berikut hasil dari pembentukan kernel gabor:

Tabel 4. 1 *Array* 3D Hasil Pembuatan Kernel Gabor

GaborArray{1,1} U0V0						
-0.0000 + 0.2451i	-0.4578 - 0.0000i	0.0000 - 0.6661i	0.7548 + 0.0000i	0.0000 + 0.6661i	-0.4578 + 0.0000i	-0.0000 - 0.2451i
-0.0000 + 0.2865i	-0.5353 - 0.0000i	0.0000 - 0.7788i	0.8825 + 0.0000i	0.0000 + 0.7788i	-0.5353 + 0.0000i	-0.0000 - 0.2865i
-0.0000 + 0.3147i	-0.5879 - 0.0000i	0.0000 - 0.8553i	0.9692 + 0.0000i	0.0000 + 0.8553i	-0.5879 + 0.0000i	-0.0000 - 0.3147i
-0.0000 + 0.3247i	-0.6065 - 0.0000i	0.0000 - 0.8825i	1.0000 + 0.0000i	0.0000 + 0.8825i	-0.6065 + 0.0000i	-0.0000 - 0.3247i
-0.0000 + 0.3147i	-0.5879 - 0.0000i	0.0000 - 0.8553i	0.9692 + 0.0000i	0.0000 + 0.8553i	-0.5879 + 0.0000i	-0.0000 - 0.3147i
-0.0000 + 0.2865i	-0.5353 - 0.0000i	0.0000 - 0.7788i	0.8825 + 0.0000i	0.0000 + 0.7788i	-0.5353 + 0.0000i	-0.0000 - 0.2865i
-0.0000 + 0.2451i	-0.4578 - 0.0000i	0.0000 - 0.6661i	0.7548 + 0.0000i	0.0000 + 0.6661i	-0.4578 + 0.0000i	-0.0000 - 0.2451i
...	...	...	...	...	...	...
GaborArray{3,5} U2V4						
0.4741 + 0.2723i	0.6605 - 0.0757i	0.4917 - 0.4577i	0.1042 - 0.5543i	-0.1710 - 0.3543i	-0.2017 - 0.1065i	-0.1086 + 0.0164i
0.3190 + 0.4786i	0.7189 + 0.2604i	0.8099 - 0.2398i	0.4676 - 0.6183i	0.0072 - 0.5912i	-0.2187 - 0.3042i	-0.1878 - 0.0606i
0.0671 + 0.5285i	0.5344 + 0.5604i	0.9210 + 0.1617i	0.8401 - 0.4180i	0.3569 - 0.6962i	-0.0872 - 0.5350i	-0.2232 - 0.2181i
-0.1430 + 0.4103i	0.2040 + 0.6596i	0.7336 + 0.5410i	1.0000 + 0.0000i	0.7336 - 0.5410i	0.2040 - 0.6596i	-0.1430 - 0.4103i
-0.2232 + 0.2181i	-0.0872 + 0.5350i	0.3569 + 0.6962i	0.8401 + 0.4180i	0.9210 - 0.1617i	0.5344 - 0.5604i	0.0671 - 0.5285i
-0.1878 + 0.0606i	-0.2187 + 0.3042i	0.0072 + 0.5912i	0.4676 + 0.6183i	0.8099 + 0.2398i	0.7189 - 0.2604i	0.3190 - 0.4786i
-0.1086 - 0.0164i	-0.2017 + 0.1065i	-0.1710 + 0.3543i	0.1042 + 0.5543i	0.4917 + 0.4577i	0.6605 + 0.0757i	0.4741 - 0.2723i

c. Konvolusi Gabor


Pada tahap ini, gambar bangunan rusak dengan ukuran 128×128 piksel diproses menggunakan kernel Gabor. Cara kerjanya yaitu kernel diletakkan pada bagian paling kiri atas gambar, kemudian dihitung hasil perkaliannya dengan piksel gambar di area tersebut. Setelah itu, kernel digeser satu piksel ke kanan dan dihitung lagi. Jika sudah sampai ke tepi kanan, kernel diturunkan satu baris ke bawah lalu kembali dihitung mulai dari sisi kiri. Proses ini dilakukan berulang-ulang sampai seluruh gambar selesai dilewati oleh kernel. Cara ini biasanya disebut dengan istilah *sliding window*. Berikut hasil dari konvolusi gabor pada bagian real:



Gambar 4. 3 Hasil Konvolusi *Gabor filters Real*

Pada gambar 4.3 menunjukkan hasil konvolusi *Gabor Filter* yang menghasilkan 15 gambar hasil konvolusi dari berbagai frekuensi dan orientasi. Hasil konvolusi real menonjolkan bagian citra yang memiliki arah tepi atau pola tertentu sesuai dengan orientasi filter. Area yang sejajar dengan arah filter tampak lebih jelas dan kontras, sedangkan bagian lain terlihat lebih halus.

Pada baris pertama ($u=0$), filter dengan frekuensi rendah menangkap detail halus seperti garis vertikal dan diagonal pada dinding serta jendela. Baris kedua ($u=1$) mulai menampilkan bentuk yang lebih besar seperti batas atap dan struktur utama bangunan. Sementara pada baris ketiga ($u=2$), filter dengan frekuensi lebih tinggi menonjolkan bentuk keseluruhan bangunan, meskipun detail kecil mulai berkurang. Dari sisi orientasi ($v=0$ hingga $v=4$), setiap arah filter memberikan hasil berbeda. Orientasi rendah menonjolkan tepi vertikal, sedangkan orientasi menengah hingga tinggi lebih peka terhadap tepi diagonal dan horizontal seperti pada bagian atap.



Gambar 4. 4 Hasil Konvolusi *Gabor filters Imaginer*

Hasil konvolusi Gabor filter pada bagian imajiner menunjukkan tampilan yang berbeda dibandingkan dengan hasil real. Pada Gambar 4.4, dihasilkan 15 citra dari kombinasi parameter frekuensi (u) dan orientasi (v) tertentu. Pada baris pertama ($u=0$), filter dengan frekuensi rendah menampilkan pola halus namun tetap memperlihatkan garis dominan sesuai arah orientasi filter. Tepi jendela dan garis

atap masih dapat dikenali, tetapi tingkat kontrasnya lebih rendah dibandingkan hasil real. Ketika frekuensi meningkat ($u=1$ dan $u=2$), tampilan citra menjadi lebih jelas dan menunjukkan pergeseran fase di sekitar tepi objek, terlihat dari area terang dan gelap yang bergantian pada bagian kusen jendela dan garis atap.

Dari sisi orientasi ($v=0$ hingga $v=4$), perubahan arah filter menghasilkan tampilan yang menyesuaikan arah tepi bangunan. Orientasi rendah ($v=0$ dan $v=1$) lebih menonjolkan tepi vertikal seperti jendela dan kolom, sedangkan orientasi menengah hingga tinggi ($v=2$ sampai $v=4$) lebih sensitif terhadap tepi diagonal dan horizontal seperti bagian atap dan pertemuan antara dinding dan langit.

Secara visual hasil bagian imajiner tampak seperti bayangan lembut dari hasil real. Komponen imajiner ini menyimpan informasi fase dan arah tekstur, sedangkan bagian real merepresentasikan kekuatan intensitas. Kombinasi keduanya penting untuk mengenali arah, bentuk, dan pola tekstur secara lebih akurat. Dalam konteks identifikasi kerusakan bangunan, komponen imajiner membantu menonjolkan batas halus serta perubahan bentuk kecil yang mungkin menandakan adanya retakan atau deformasi pada struktur bangunan.

Tabel 4. 2 Hasil Konvolusi Gabor pada V_0 dan U_0

	0	1	2	3	...	127
0	-34.0328 - 85.3382i	-227.6964 - 74.9762i	-179.3748 + 203.6064i	133.9717 + 143.7775i	...	54.7166 - 105.1029i
1	-70.1622 - 105.9178i	-287.9651 - 56.6150i	-184.4731 + 260.1493i	174.2261 + 147.0833i	...	71.3751 - 147.7341i
2	-120.3159 - 119.2242i	-336.5050 - 13.6333i	-158.5407 + 306.0585i	207.0803 + 121.7208i	...	99.7390 - 184.8588i
3	-179.9342 - 123.0257i	-370.1341 + 47.2940i	-109.1454 + 339.5002i	232.4701 + 78.5434i	...	133.2365 - 209.9886i
...	...	...	...	...	...	...
127	134.9409 + 194.0844i	135.8746 - 110.3403i	-71.3267 - 110.2095i	-70.1379 - 2.3433i	...	266.9240 - 371.3532i


Karena nilai dari konvolusi gabor masih berupa bilangan kompleks, maka dilanjutkan dengan proses *magnitude* yang hasilnya berubah menjadi bilangan riil.

Berikut merupakan hasil dari proses *magnitude* dari V0 dan U0:

Tabel 4. 3 Hasil *Magnitude* V0 dan U0

	0	1	2	3	...	127
0	91.87408	239.72290	271.35007	196.52068	...	118.49271
1	127.04851	293.47766	318.91690	228.00930	...	164.07248
2	169.38217	336.78104	344.68380	240.20448	...	210.04913
3	217.97162	373.14337	356.61343	245.38017	...	248.69092
...	...	...	...	...	...	...
127	236.38487	175.03395	131.27693	70.17704	...	457.33100

Setelah melalui proses *magnitude*, dilakukan proses normalisasi. Normalisasi dilakukan supaya nilai yang dihasilkan konsisten antara rentang 0 hingga 1. Hasil normalisasi dapat dilihat dalam gambar dan tabel berikut:



Gambar 4. 5 Hasil Normalisasi *Gabor filters*

Hasil konvolusi Gabor filter pada bagian *magnitude* yang telah dinormalisasikan menunjukkan seberapa kuat setiap bagian gambar merespons pola arah dan frekuensi tertentu. Nilai *magnitude* ini berasal dari gabungan antara hasil

real dan imajiner, jadi bisa dibilang menggambarkan kekuatan total respon filter terhadap tekstur di citra.

Pada baris pertama ($u=0$), filter bekerja pada frekuensi rendah. Di sini terlihat bagian-bagian halus seperti pola dinding dan jendela muncul cukup jelas karena filter lebih sensitif terhadap detail kecil. Saat frekuensinya naik ke $u=1$ dan $u=2$, hasilnya mulai menampilkan bentuk bangunan secara lebih utuh. Detail kecil sedikit berkurang, tapi struktur besar seperti atap dan batas dinding justru terlihat lebih jelas.

Kalau dilihat dari kolom orientasi ($v=0$ sampai $v=4$), tiap arah filter memberi hasil yang berbeda. Orientasi awal ($v=0$ dan $v=1$) cenderung menyoroti garis vertikal seperti tiang dan jendela, sementara orientasi menengah dan tinggi ($v=2$ sampai $v=4$) lebih menangkap arah diagonal dan horizontal, misalnya pada bagian atap atau batas dinding. Jadi, tiap kombinasi orientasi dan frekuensi menampilkan sisi berbeda dari tekstur bangunan.

Tabel 4. 4 Hasil Normalisasi V0 dan U0

	0	1	2	3	...	127
0	0.081167	0.216382	0.245307	0.176872	...	0.105511
1	0.113336	0.265544	0.288809	0.205669	...	0.147196
2	0.152052	0.305147	0.312374	0.216823	...	0.189244
3	0.196489	0.338402	0.323284	0.221556	...	0.224584
...	...	...	...	...	...	...
127	0.213329	0.157221	0.117203	0.061324	...	0.415396

d. Ekstraksi Fitur

Pada tahap ini dilakukan proses ekstraksi fitur dari hasil konvolusi Gabor. Fitur yang digunakan diperoleh dari nilai *magnitude* yang sudah dinormalisasi. Dari data *magnitude* ini kemudian dihitung beberapa nilai penting. Pertama, kontras, yang diperoleh dengan menghitung standar deviasi menggunakan fungsi *np.std*.

Nilai kontras ini menunjukkan seberapa besar perbedaan atau variasi intensitas pada tekstur gambar. Kedua, *mean*, yang dihitung menggunakan *np.mean(arr)*. Nilai *mean* ini merepresentasikan rata-rata intensitas dari hasil magnitude yang telah dinormalisasi, sehingga dapat menggambarkan tingkat kecerahan atau kekuatan rata-rata respon Gabor terhadap pola tertentu. Ketiga, energi, yang diperoleh dengan menjumlahkan kuadrat seluruh elemen *magnitude* menggunakan fungsi *np.sum(arr ** 2)*. Energi ini menggambarkan seberapa kuat respon filter Gabor terhadap pola tertentu dalam gambar.

Semua hasil perhitungan fitur ini, bersama dengan informasi parameter filter seperti nilai skala (u), orientasi (v), sudut (radian dan derajat), serta nilai frekuensi dan panjang gelombang, dikumpulkan dalam bentuk tabel. Tabel tersebut kemudian disimpan ke dalam file CSV menggunakan library *Pandas*, sehingga setiap baris berisi kombinasi parameter (u,v) tertentu beserta nilai fitur yang dihasilkan. Dengan cara ini, data fitur dapat dianalisis lebih lanjut pada tahap berikutnya, yaitu reduksi dimensi menggunakan PCA dan proses *clustering*. Berikut hasil dari ekstraksi fitur:

Tabel 4. 5 Hasil Ekstraksi Fitur Gabor

u	v	theta_rad	orientasi	frekuensi	lambda	contrast	mean	energy
0	0	0.000000	0.0	0.250000	4.000000	0.122324	0.191387	845.285034
0	1	0.628319	36.0	0.250000	4.000000	0.135462	0.274909	1538.861328
0	2	1.256637	72.0	0.250000	4.000000	0.107209	0.168099	651.278564
0	3	1.884956	108.0	0.250000	4.000000	0.103005	0.144472	515.800720
0	4	2.513274	144.0	0.250000	4.000000	0.140717	0.269413	1513.630127
1	0	0.000000	0.0	0.176777	5.656854	0.140484	0.234858	1227.066895
1	1	0.628319	36.0	0.176777	5.656854	0.223979	0.493986	4819.990723
1	2	1.256637	72.0	0.176777	5.656854	0.134742	0.243934	1272.366455
1	3	1.884956	108.0	0.176777	5.656854	0.135495	0.233284	1192.431641
1	4	2.513274	144.0	0.176777	5.656854	0.207286	0.445004	3948.480713
2	0	0.000000	0.0	0.125000	8.000000	0.240155	0.484135	4785.134277
2	1	0.628319	36.0	0.125000	8.000000	0.244575	0.483979	4817.750977
2	2	1.256637	72.0	0.125000	8.000000	0.212652	0.410958	3507.942383
2	3	1.884956	108.0	0.125000	8.000000	0.207595	0.406595	3414.680176

2	4	2.513274	144.0	0.125000	8.000000	0.245205	0.473885	4664.408691
---	---	----------	-------	----------	----------	----------	----------	-------------

4.2.3 Proses PCA Clustering

Data yang telah disimpan di spreadsheet kemudian akan diproses di PCA.

Berikut hasil dari pengujian PCA:

a. Normalisasi Data

Tahapan pertama dalam proses PCA dimulai dengan normalisasi data. Pada tahap ini diawali dengan jika terdapat nilai kosong (*missing value*) maka mengisi nilai kosong tersebut dengan nilai rata-rata dari kolom yang bersangkutan menggunakan fungsi *SimpleImputer(strategy='mean')*. Tujuan dari mengisi nilai kosong adalah supaya dataset yang akan diolah tak ada kendala maupun *error*. Kemudian, setelah memastikan semua data lengkap, melakukan standarisasi dengan menggunakan fungsi *StandardScaler()*. Proses ini dilakukan agar data memiliki rata-rata sama dengan nol dan standar deviasi. Setelah tahap normalisasi semua fitur terdapa pada skala seragam. Berikut hasil dari normalisasi data:

Tabel 4. 6 Hasil Normalisasi Data

Hasil Normalisasi:
[[-0.9943873 -1.11676669 -1.04554153]
[-0.73857451 -0.44672291 -0.62775416]
[-1.28870655 -1.3035938 -1.1624046]
[-1.3705727 -1.49313861 -1.24401196]
[-0.63624296 -0.49081125 -0.6429526]
[-0.64078238 -0.7680211 -0.81556879]
[0.98501308 1.31080024 1.34868943]
[-0.75258884 -0.69521511 -0.78828184]
[-0.73792457 -0.78065355 -0.83643192]
[0.6599643 0.91784917 0.82372069]
[1.29998692 1.23177312 1.32769307]
[1.38604909 1.23051673 1.34734028]
[0.76446155 0.64471991 0.558355]
[0.66598495 0.60971921 0.50217694]
[1.3983199 1.14954465 1.25497197]]

b. Penentuan Variance ratio dan Eigen value

Tahap ini dilakukan untuk mengetahui seberapa besar kontribusi setiap komponen utama (*principal component*) dalam menjelaskan variasi suatu data. Untuk mendapatkan nilai dari *variance ratio* menggunakan fungsi *pca.explained_varian_ratio_*. Nilai yang dihasilkan adalah presentase variasi data yang dijelaskan oleh masing-masing komponen utama. Sedangkan untuk menghitung *eigen value* menggunakan fungsi *pca.explained_variance_*. Nilai *eigen value* adalah nilai variasi yang dijelaskan oleh masing-masing komponen. Berikut hasil dari *variance ratio* dan *eigen value*:

Tabel 4. 7 Persentase Nilai *Variance ratio* dan *Eigen value*

PC	<i>Explained Variance (%)</i>	<i>Eigen value</i>
PC 1	99.26	3.19
PC 2	0.51	0.02
PC 3	0.23	0.01

Tabel tersebut menunjukkan seberapa besar masing-masing komponen utama (PC) mampu menjelaskan informasi dari data. Hasilnya, PC1 memiliki nilai eigen terbesar yaitu 3,19 dengan kontribusi sebesar 99,26%. Artinya, hampir seluruh variasi atau pola yang ada pada data sudah bisa ditangkap hanya dengan PC1 saja. PC2 memiliki nilai eigen jauh lebih kecil yaitu 0,02 dengan kontribusi 0,51%, sehingga hanya menambah sedikit informasi baru yang tidak tercakup di PC1. Sementara itu, PC3 bernilai 0,01 dengan kontribusi 0,23%, yang berarti komponen ini tidak lagi memberikan informasi tambahan. Dari hasil ini dapat dipahami bahwa PC1 sudah cukup kuat untuk mewakili keseluruhan data, sementara PC2 berperan sangat kecil dan PC3 hampir tidak berpengaruh sama sekali.

Tabel 4. 8 Nilai *Eigenvector*

PC	<i>contrast_std</i>	<i>mean</i>	<i>energy</i>
PC 1	0.576619	0.577395	0.578036
PC 2	0.794450	-0.561372	-0.231753
PC 3	-0.190680	-0.592854	0.782410

Berdasarkan Tabel 4.8, setiap komponen utama (PC) memiliki peran yang berbeda dalam menjelaskan variasi data. PC1 memiliki nilai eigenvector yang hampir seimbang pada ketiga fitur, yaitu *contrast_std* (0,576619), *mean* (0,577395), dan *energy* (0,578036). Hal ini menunjukkan bahwa ketiga fitur tersebut berkontribusi hampir sama terhadap pembentukan PC1. Dengan demikian, PC1 dapat dianggap sebagai representasi umum dari seluruh fitur utama karena menampung informasi yang paling besar dan merata dari ketiganya.

Pada PC2, kontribusi terbesar berasal dari *contrast_std* dengan nilai 0,794450, sedangkan *mean* dan *energy* bernilai negatif, masing-masing sebesar – 0,561372 dan –0,231753. Hal ini menunjukkan bahwa PC2 terutama membedakan antara citra dengan tingkat kontras tinggi dan citra dengan nilai rata-rata serta energi yang lebih rendah. Dengan kata lain, semakin tinggi nilai PC2, semakin besar perbedaan kontras pada tekstur.

Sementara itu, PC3 memiliki pengaruh terbesar dari fitur *energy* dengan nilai 0,782410, diikuti *mean* (–0,592854) dan *contrast_std* (–0,190680). Arah tanda menunjukkan bahwa PC3 menjelaskan variasi energi yang berlawanan dengan nilai rata-rata dan sedikit berlawanan dengan kontras. Artinya, semakin tinggi nilai PC3, maka energi tekstur meningkat sementara nilai rata-rata dan kontrasnya menurun.

c. Pembuatan Komponen Utama PCA

Tahap berikutnya adalah pembuatan komponen utama (*principal component*) PCA. Komponen Utama ini merupakan nilai baru dari data yang telah

diubah ke sumbu baru sesuai arah terbesar dari variasi data. Untuk membuatnya digunakan fungsi *PCA(n_components=...)* dari *scikit-learn* yang berfungsi menentukan berapa banyak komponen utama yang dipakai. Pada penelitian ini menggunakan *n_components=3* untuk berikutnya diproses di visualisasai. Setelah itu, fungsi *fit_transform()* digunakan untuk menghitung dan menghasilkan nilai komponen utama, misalnya PC1, PC2, dan PC3. Hasilnya kemudian dimasukkan ke dalam tabel menggunakan fungsi *pd.DataFrame()* agar lebih mudah dibaca. Dengan cara ini, setiap data sudah punya nilai komponen utama yang nantinya dipakai untuk visualisasi dan proses *clustering*. Berikut hasil dari pembuatan komponen utama PC1 hingga PC3:


Tabel 4. 9 Hasil Pembuatan Komponen Utama PCA

	PC1	PC2	PC3
0	2.956823	0.389535	0.487457
1	1.078772	0.737674	0.491157
2	3.847291	0.531467	0.542060
3	3.623000	0.403665	0.515067
4	1.039100	0.632643	0.481252
5	0.471899	0.541767	0.476277
6	-1.207476	0.610601	0.525478
7	0.880794	0.386596	0.459326
8	0.947658	0.563817	0.474998
9	-0.881713	0.549840	0.508929
10	-1.113825	0.462520	0.512202
11	-1.109656	0.477019	0.512952
12	-1.013530	0.415694	0.505120
13	-1.013064	0.387894	0.503316
14	-1.006072	0.409268	0.504408

d. Visualisasi Data

Pada tahap ini hasil dari komponen utama divisualisasikan dalam grafik 2D dan 3D. Visualisasi ini bertujuan untuk melihat bagaimana sebaran data komponen utama yang telah dibuat. Pada visualisasi 2D, data ditampilkan dengan sumbu PC1 dan PC2 yang setiap titik mewakili satu data. Dengan tampilan ini, kita bisa melihat

pemisahan data secara sederhana. Kemudian, dibuat juga visualisasi 3D dengan menggunakan sumbu PC1, PC2, dan PC3. Dengan tambahan satu sumbu lagi, penyebaran data terlihat lebih jelas. Melalui visualisasi 2D dan 3D ini, hasil PCA dapat lebih mudah dipahami dan bisa digunakan sebagai dasar untuk tahap *clustering*.



Gambar 4. 6 Visualisasi 2D dan 3D


e. *Clustering Data*

Tahap terakhir adalah *clustering* data yaitu mengelompokkan hasil PCA dalam suatu *cluster*. Pada tahap ini, data hasil reduksi dimensi PCA dikelompokkan ke dalam beberapa *cluster* berdasarkan nilai komponen utamanya. Proses *clustering* dilakukan dengan mengambil acuan pada nilai PC1. Alasan pemilihan PC1 sebagai dasar *clustering* adalah karena PC1 memiliki kontribusi paling besar dalam menjelaskan variasi data dikarenakan komponen ini mempunyai kontribusi paling besar dalam kontribusi data, sebagaimana ditunjukkan pada tabel 4.7. PC1 memiliki *variance ratio* sebesar 99,26% dengan *eigen value* 3,19. Artinya, hampir seluruh informasi dan pola utama dari data sudah tercakup pada PC1, sehingga penggunaan PC1 sebagai acuan pengelompokan dianggap paling representatif.


Tabel 4. 10 Rentang Nilai *Clustering* Data

<i>Cluster</i>	Rentang Nilai (n)
<i>Cluster 0</i>	$n < 0$
<i>Cluster 1</i>	$0 \leq n < 2$
<i>Cluster 2</i>	$n \geq 2$

Hasil komponen utama kemudian dikelompokkan menjadi tiga *cluster*. Alasan pemilihan jumlah *cluster* ini karena BPBD, sebagai badan penanggulangan bencana, yang membagi tingkat kerusakan bangunan hanya ke dalam tiga kategori, yaitu rusak ringan, sedang, dan berat (Ari Septian dkk., 2020). Dengan merujuk pada pembagian tersebut, peneliti menyesuaikan hasil PCA agar juga terbagi menjadi tiga *cluster* sebagai representasinya. Dapat dilihat dalam tabel 4.10, bahwa peneliti mengelompokkan komponen utama dalam 3 *cluster*. Jika nilai n kurang dari 0, maka data dikelompokkan ke dalam *Cluster 0*. Jika nilai n berada pada rentang 0 hingga kurang dari 2, maka data dikategorikan sebagai *Cluster 1*. Sedangkan jika nilai PC1 lebih besar atau sama dengan 2, maka data dikelompokkan ke dalam *Cluster 2*. Rentang nilai ini berdasarkan acuan penelitian yang telah dilakukan oleh Almais dkk., (2023).

Gambar 4. 7 Visualisasi *Clustering* Data

Hasil pengelompokan ini divisualisasikan dalam bentuk grafik 2D (PC1 vs PC2) dan grafik 3D (PC1, PC2, PC3). Warna hijau digunakan untuk *Cluster* 0, kuning untuk *Cluster* 1, dan merah untuk *Cluster* 2. Visualisasi ini memudahkan dalam melihat persebaran data dan perbedaan karakteristik antar *cluster*. Selain itu, ditampilkan pula jumlah data yang masuk dalam masing-masing *cluster*, sehingga dapat diketahui distribusi data secara keseluruhan.



Gambar 4. 8 Visualisasi 2D dengan Label u dan v

Gambar 4.8 memberikan keterangan sebaran titik tersebut mewakili nilai frekuensi dan orientasi. Berikut hasil dari setiap *cluster* dapat dilihat pada tabel berikut:

Tabel 4. 11 Hasil *Cluster* Terhadap Nilai Fitur


u	v	PC1	PC2	PC3	Cluster	contrast_std	mean	energy
0	0	-1.822559	0.079238	0.033648	Cluster 0	0.122324	0.191387	845.285034
0	1	-1.046676	-0.190499	-0.085488	Cluster 0	0.135462	0.274909	1538.861328
0	2	-2.167693	-0.022621	0.109096	Cluster 0	0.107209	0.168099	651.278564
0	3	-2.371513	0.037658	0.173228	Cluster 0	0.103005	0.144472	515.800720
0	4	-1.021911	-0.080929	-0.090754	Cluster 0	0.140717	0.269413	1513.630127

1	0	-1.284367	0.111087	-0.060600	Cluster 0	0.140484	0.234858	1227.066 895
1	1	2.104418	-0.265866	0.090291	Cluster 2	0.223979	0.493986	4819.990 723
1	2	-1.291026	-0.024933	-0.061094	Cluster 0	0.134742	0.243934	1272.366 455
1	3	-1.359735	0.045838	-0.050911	Cluster 0	0.135495	0.233284	1192.431 641
1	4	1.386650	-0.181846	-0.025506	Cluster 1	0.207286	0.445004	3948.480 713
2	0	2.228271	0.033595	0.060656	Cluster 2	0.240155	0.484135	4785.134 277
2	1	2.288528	0.098119	0.060362	Cluster 2	0.244575	0.483979	4817.750 977
2	2	1.135810	0.115998	-0.091130	Cluster 1	0.212652	0.410958	3507.942 383
2	3	1.026345	0.070431	-0.095557	Cluster 1	0.207595	0.406595	3414.680 176
2	4	2.195458	0.174730	0.033757	Cluster 2	0.245205	0.473885	4664.408 691

Hasil *clustering* pada Tabel 4.11 menunjukkan bahwa *Cluster 0* memiliki nilai *contrast* yang relatif rendah hingga sedang (sekitar 0.10–0.14), nilai *mean* yang kecil (sekitar 0.14–0.27), serta *energy* yang juga lebih rendah dibandingkan *cluster* lain (sekitar 500–1500). Kombinasi ini menandakan tekstur yang kurang menonjol dan permukaan yang cenderung tidak rata, sehingga dapat dikaitkan dengan kerusakan berat, karena area bangunan yang rusak parah biasanya menampilkan ketidakaturan intensitas dan pola tekstur yang tidak seragam. Selanjutnya, *Cluster 1* memiliki nilai *contrast* menengah (sekitar 0.20–0.21), *mean* sedang (sekitar 0.40–0.44), dan *energy* cukup tinggi (sekitar 3400–3900). Nilai-nilai ini menggambarkan tekstur dengan tingkat variasi yang masih ada namun tidak sekuat *cluster* berat, sehingga dapat diinterpretasikan sebagai kerusakan sedang atau area dengan sebagian permukaan rusak dan sebagian masih utuh. Sementara itu, *Cluster 2* menunjukkan nilai *contrast* paling tinggi (sekitar 0.22–0.24), *mean*

besar (sekitar 0.47–0.49), serta *energy* paling tinggi (sekitar 4600–4800). Ciri ini menunjukkan tekstur yang jelas dan kuat dengan pola teratur serta tingkat kecerahan tinggi, menandakan kerusakan ringan atau kondisi bangunan yang masih utuh, di mana struktur dan tekstur permukaannya masih seragam serta memiliki respons yang kuat terhadap filter Gabor.

Selain dikelompokkan ke dalam 3 *cluster*, penelitian ini juga melakukan pengelompokan dalam 2, 4, dan 5 *cluster* sebagai pembandingan. Hal ini dilakukan untuk mengetahui jumlah *cluster* yang paling sesuai dengan data serta menghasilkan nilai validasi atau *silhouette score* yang paling baik.



Gambar 4. 9 Visualisasi 2D pada 2 *Cluster*


Pada saat data dibagi menjadi dua *cluster*, pola yang muncul sangat sederhana yaitu sebagian besar titik berkumpul di satu kelompok besar, sementara hanya beberapa titik yang terpisah dan membentuk kelompok kecil di sisi lainnya. Struktur ini menunjukkan bahwa mayoritas data memiliki karakteristik yang mirip, sehingga saat hanya ada dua *cluster*, pemisahannya menjadi tidak seimbang. Visualisasi grafik juga memperlihatkan bahwa batas antara kedua *cluster* terlihat jelas, tetapi variasi pola di dalam *cluster* masih sangat luas karena jumlah kelompoknya masih terlalu sedikit.

Rentang nilai pada 2 *cluster* ditentukan berdasarkan pola penyebaran data pada komponen utama pertama yaitu PC1. Penentuan rentang nilai ini berdasarkan kedekatan antar titik yang terbentuk. Berikut rentang nilai setiap *cluster* dalam 2 cluter:

Tabel 4. 12 Rantang Nilai pada 2 *Cluster*

<i>Cluster</i>	Rentang Nilai (n)
<i>Cluster 0</i>	$n < 2$
<i>Cluster 2</i>	$n \geq 2$

Tabel 4.12 menunjukkan bahwa pada pemisahan 2 *cluster*, data dengan nilai PC1 di bawah 2 digolongkan ke dalam *cluster 0*, sedangkan data dengan nilai PC1 di atas 2 masuk ke *cluster 2*. Pembagian ini mengikuti pola perbedaan nilai PC1 yang terlihat pada data.



Gambar 4. 10 Visualisasi 2D pada 4 *Cluster*

Pada empat *cluster*, struktur data semakin terurai. Kelompok yang sebelumnya besar kini terpecah lagi menjadi beberapa bagian yang lebih kecil. Beberapa titik berpindah ke *cluster* baru karena dianggap memiliki kemiripan yang lebih dekat dengan kelompok tersebut. Hasilnya, terdapat satu *cluster* yang tetap menjadi kelompok utama, sementara titik-titik lain tersebar ke dalam tiga *cluster* yang lebih kecil. Pola yang muncul menunjukkan bahwa data sebenarnya memiliki


variasi yang lebih halus dibandingkan yang terlihat pada 2 atau 3 *cluster*. Namun, beberapa *cluster* mulai berisi sedikit titik, menandakan bahwa perbedaan antar titik-titik tertentu cukup signifikan sehingga mereka terpisah dari kelompok utama.

Dalam pengelompokan 4 *cluster*, rentang nilai ditetapkan dengan melihat pola sebaran data pada PC1. Pemilihan batas tiap *cluster* dilakukan berdasarkan kedekatan posisi titik-titik pada sumbu tersebut. Adapun pembagian rentang nilai untuk masing-masing *cluster* pada 4 *cluster* adalah sebagai berikut:

Tabel 4. 13 Rentang Nilai pada 4 *Cluster*

<i>Cluster</i>	Rentang Nilai (n)
<i>Cluster 0</i>	$n < 0$
<i>Cluster 1</i>	$0 \leq n < 2$
<i>Cluster 2</i>	$2 \leq n < 3.3$
<i>Cluster 3</i>	$n \geq 3.3$

Tabel 4.13 menunjukkan pembagian data ke dalam empat *cluster* berdasarkan nilai PC1. Data dengan nilai PC1 di bawah 0 masuk ke *cluster 0*, sedangkan nilai antara 0 hingga 2 dikelompokkan ke *cluster 1*. Nilai PC1 yang berada pada rentang 2 hingga 3,3 ditempatkan pada *cluster 2*, dan data dengan nilai di atas 3,3 masuk ke *cluster 3*. Pembagian ini mengikuti pola perubahan nilai PC1 yang terlihat pada penyebaran data.



Gambar 4. 11 Visualisasi 2D pada 5 *Cluster*

Saat jumlah *cluster* dinaikkan menjadi lima, pola data menjadi yang paling terpecah. *Cluster* besar yang mendominasi pada jumlah *cluster* sebelumnya tetap terlihat, tetapi titik-titik lain semakin tersebar sehingga beberapa *cluster* hanya berisi 1–2 titik. Hal ini menunjukkan bahwa ada beberapa titik yang memiliki karakteristik sangat spesifik, sehingga mereka tidak masuk ke kelompok besar dan justru membentuk *cluster* yang sangat kecil. Secara visual, pola pemisahannya sangat detail, tetapi struktur ini juga menunjukkan bahwa data sebenarnya memiliki kemiripan yang kuat sehingga hanya sedikit titik yang benar-benar berbeda.

Rentang nilai pada 5 *cluster* ditentukan dengan mengamati pola penyebaran data pada komponen utama pertama (PC1). Pembagian batas setiap *cluster* mengikuti kedekatan titik-titik yang membentuk kelompok alami pada sumbu tersebut. Berikut rentang nilai yang diperoleh untuk masing-masing *cluster* dalam pembagian 5 *cluster*:

Tabel 4. 14 Rentang Nilai pada 5 *Cluster*

<i>Cluster</i>	Rentang Nilai (n)
<i>Cluster 0</i>	$n < 0$
<i>Cluster 1</i>	$0 \leq n < 0.7$
<i>Cluster 2</i>	$0.7 \leq n < 2$
<i>Cluster 3</i>	$2 \leq n < 3.3$
<i>Cluster 4</i>	$n \geq 3.3$

Tabel 4.14 menyajikan pembagian data ke dalam lima *cluster* berdasarkan nilai PC1. Data dengan nilai PC1 di bawah 0 dimasukkan ke *cluster 0*, sedangkan nilai antara 0 hingga 0,7 dikelompokkan ke *cluster 1*. Nilai PC1 pada rentang 0,7 hingga 2 masuk ke *cluster 2*, sementara nilai antara 2 hingga 3,3 ditempatkan pada *cluster 3*. Adapun data dengan nilai PC1 di atas 3,3 dimasukkan ke *cluster 4*. Pembagian ini disusun berdasarkan perubahan pola penyebaran data pada PC1.

Rentang nilai pada setiap *cluster* ditentukan berdasarkan pola penyebaran data pada komponen utama pertama (PC1), karena PC1 memiliki kontribusi terbesar dalam menjelaskan variasi data. Proses penentuan rentang nilai tidak dilakukan secara sembarangan, tetapi melalui pengamatan langsung terhadap distribusi titik pada grafik PCA dan melihat bagian mana dari sumbu PC1 yang menunjukkan pemisahan alami. Pada awalnya, nilai PC1 diurutkan untuk melihat apakah terdapat jarak atau lonjakan yang cukup besar antartitik. Jarak seperti ini menjadi batas alami yang menunjukkan bahwa titik-titik tersebut mulai memasuki kelompok dengan karakteristik berbeda. Selain itu, pengelompokan sementara dengan jumlah *cluster* berbeda (2, 3, 4, dan 5) digunakan untuk memperkuat pengamatan—jika pada visualisasi terlihat bahwa titik-titik mulai berkumpul dalam suatu area tertentu dan menjauh dari area lainnya, maka titik tersebut menjadi kandidat batas rentang. Rentang nilai akhir kemudian ditetapkan dengan mempertimbangkan keseimbangan jumlah anggota antar *cluster* dan meminimalkan *cluster* yang terlalu kecil, sehingga pemisahan setiap *cluster* menjadi lebih stabil dan mampu menghasilkan nilai silhouette yang lebih baik. Dengan cara ini, rentang setiap *cluster* terbentuk dari kombinasi analisis visual, distribusi data, serta pertimbangan kualitas pemisahan *cluster*.

4.2.4 Evaluasi Sistem

Evaluasi sistem pada penelitian ini menggunakan metode *silhouette score*. *Silhouette score* merupakan salah satu ukuran yang umum digunakan untuk menilai kualitas hasil *clustering*. Metode ini menghitung seberapa dekat data dalam satu *cluster* dan seberapa jauh jaraknya dengan data pada *cluster* lain. Dengan

demikian, *silhouette score* memberikan gambaran apakah *cluster* yang terbentuk sudah benar-benar mewakili pola yang ada pada data atau belum. Semakin nilai *silhouette score* mendekati 1, maka semakin baik kualitas pengelompokan data yang dihasilkan.

Pada implementasinya, perhitungan dilakukan dengan menggunakan fungsi *silhouette_score()* dari *library scikit-learn* untuk memperoleh nilai keseluruhan dari seluruh data. Selain itu, menggunakan fungsi *silhouette_samples()* untuk menghitung nilai *silhouette* pada masing-masing data. Nilai per sampel ini kemudian dirata-ratakan berdasarkan *cluster* dengan bantuan fungsi *groupby()* dari *Pandas*, sehingga diperoleh informasi rata-rata *silhouette score* untuk setiap *cluster*.

Tabel 4. 15 Hasil *Silhouette score* Masing-masing Jumlah *Cluster*

Jumlah <i>Cluster</i>	<i>Silhouette score</i>
2 <i>Cluster</i>	0.6897
3 <i>Cluster</i>	0.8491
4 <i>Cluster</i>	0.7847
5 <i>Cluster</i>	0.6565

Tabel 4.15 menampilkan nilai *silhouette score* untuk setiap jumlah *cluster* yang diuji. Dari hasil tersebut, terlihat bahwa 3 *cluster* memberikan nilai *silhouette* tertinggi sebesar 0.8491, yang menunjukkan bahwa pemisahan datanya paling baik dan paling jelas dibandingkan jumlah *cluster* lainnya. Pada 4 *cluster*, nilai *silhouette* menurun menjadi 0.7847, sementara 2 *cluster* memperoleh nilai 0.6897. Adapun 5 *cluster* memiliki nilai terendah, yaitu 0.6565, yang menandakan bahwa pemisahan datanya kurang optimal. Secara keseluruhan, hasil ini menunjukkan bahwa jumlah *cluster* yang paling sesuai untuk data pada penelitian ini adalah 3 *cluster* karena memberikan kualitas pengelompokan terbaik.

4.3 Pembahasan

Pada bagian ini dibahas hasil dari tahapan-tahapan yang telah dilakukan, mulai dari proses normalisasi data, perhitungan *variance ratio* dan *eigen value*, pembuatan komponen utama PCA, visualisasi data, hingga proses *clustering* dan evaluasi sistem. Dalam penelitian ini menggunakan 30 citra kerusakan bangunan. Sebelum citra diproses, hal pertama yang dilakukan adalah memotong bagian bangunan yang rusak untuk memfokuskan pada area objek yang rusak dan menghilangkan bagian gambar yang tidak relevan.

Setelah itu gambar diproses ke tahap *preprocessing* yang diawali dengan proses *resize* gambar menjadi 128x128 piksel supaya dataset yang diproses memiliki ukuran yang sama. Dengan ukuran yang konsisten dapat membuat proses ekstraksi fitur menjadi optimal. Tahap *preprocessing* berikutnya yaitu mengubah gambar menjadi skala abu-abu (*greyscale*) sehingga menjadi 1 intensitas piksel yang berkisar antara 0 hingga 255.

Setelah tahap *preprocessing* dilanjutkan dalam tahap *Gabor filters* yang terdiri dari 4 tahapan. Tahap pertama yaitu inisialisasi parameter gabor yang memiliki 4 parameter yang diinisialisasi. Parameter U (jumlah frekuensi) bernilai 3 yang artinya memiliki 3 frekuensi dimana nilai frekuensi didapat dari rumus f_u . Maka nilai dari f_1 adalah 0.25, f_2 adalah 0.1768, dan f_3 adalah 0.125. Parameter berikutnya adalah parameter V (jumlah orientasi) bernilai 5 yang artinya memiliki 5 macam orientasi. Maka nilai orientasinya terdiri dari 0, 36, 72, 108, dan 144. Parameter berikutnya adalah ukuran kernel yang bernilai 7x7 piksel.

Tahap berikutnya dalam *Gabor filters* adalah pembuatan kernel gabor. Setelah parameter ditentukan, nilai tersebut dimasukkan ke rumus pembuatan *Gabor filters*. Hasil dari pembuatan kernel gabor dapat dilihat pada tabel 4.1 yang hasilnya berupa array 3 dimensi dengan ukuran 3x5 dimana setiap elemen dalam array 3D berisi array 2D sesuai dengan ukuran kernel yaitu 7x7. Kernel gabor yang dihasilkan sebanyak 15 kernel yang berukuran 7x7 piksel yang nantinya akan dikonvolusi pada citra dataset.

Setelah membuat kernel gabor, proses berikutnya yaitu konvolusi yaitu proses menerapkan kernel gabor ke citra bangunan rusak. Konvolusi dilakukan dengan mengalikan nilai kernel gabor dengan citra bangunan. Hasil konvolusi kernel gabor menghasilkan nilai berupa bilangan kompleks yang terdiri dari bilangan real dan imajiner. Tabel 4.2 merupakan hasil dari konvolusi kernel. Kemudian dilakukan *magnitude* untuk mengubah bilangan kompleks menjadi bilangan riil. Hasil dari *magnitude* dapat dilihat dalam tabel 4.3. Setelah melalui proses *magnitude* dilakukan normalisasi supaya hasil antara 0 dan 1. Hasil dari normalisasi terdapat pada tabel 4.4.

Tahap terakhir dalam *Gabor Filter* adalah ekstraksi fitur. Fitur yang digunakan ada tiga yaitu kontras, *mean*, dan energi. Hasil dari normalisasi *magnitude* diproses untuk menghasilkan ketiga fitur tersebut. Nilai kontras dihitung menggunakan standar deviasi, *mean* diperoleh dari rumus sederhana, sedangkan energi dihitung dari jumlah kuadrat seluruh nilai *magnitude*. Setiap hasil perhitungan fitur ini kemudian disimpan bersama informasi parameter filter seperti skala (u), orientasi (v), sudut dalam radian dan derajat, serta nilai frekuensi dan

panjang gelombang. Semua data disimpan dalam bentuk tabel dan diekspor ke file CSV dalam file bernama *gabor_matrix_all_uv.csv*, sehingga mempermudah proses analisis lebih lanjut pada tahap *Principal Component Analysis* (PCA) dan *clustering*.

Setelah proses ekstraksi fitur *Gabor Filter*, kemudian lanjut ke proses PCA. Diawali dengan membaca file hasil *Gabor filters* kemudian menghapus kolom parameter dan menyisakan kolom yang menyimpan nilai kontras, *mean*, dan *energy*. Kemudian data itu diproses dalam PCA. Tahap pertama dalam PCA adalah normalisasi data. Hasil normalisasi menunjukkan bahwa data memiliki shape (15, 3), yang berarti terdapat 15 baris data dengan 3 fitur pada setiap baris. Tiga fitur tersebut merupakan hasil ekstraksi dari *Gabor Filter*, yaitu kontras, *mean*, dan energi. Proses normalisasi dilakukan menggunakan metode *StandardScaler* sehingga setiap fitur memiliki rata-rata nol dan standar deviasi satu. Hal ini bertujuan agar semua fitur berada pada skala yang sama, sehingga tidak ada fitur yang mendominasi karena perbedaan rentang nilai. Nilai negatif pada tabel hasil normalisasi menunjukkan bahwa data tersebut berada di bawah rata-rata untuk fitur tertentu, sedangkan nilai positif menandakan bahwa data berada di atas rata-rata. Pada tabel 4.6 menunjukkan bahwa pada baris pertama nilai kontras dan energi lebih rendah dari rata-rata, sedangkan *mean* lebih tinggi dari rata-rata. Data yang sudah dinormalisasi ini selanjutnya digunakan pada tahap *Principal Component Analysis* (PCA) agar analisis dimensi dan proses *clustering* dapat dilakukan secara lebih optimal.

Tahap kedua dalam PCA adalah menentukan *variance ratio* dan *eigen value* yang hasilnya terdapat pada tabel 4.7. Berdasarkan tabel tersebut, komponen pertama (PC1) memiliki nilai *explained variance* sebesar 99,26% dengan *eigen value* 3,19. Hal ini berarti hampir seluruh informasi atau variasi dalam data dapat dijelaskan hanya oleh PC1. Komponen kedua (PC2) hanya menyumbang sebesar 0,51% dengan *eigen value* 0,02, sehingga kontribusinya relatif kecil. Sementara itu, komponen ketiga (PC3) hanya memiliki kontribusi sebesar 0,23% dengan *eigen value* 0,01 yang menunjukkan bahwa pengaruhnya dapat diabaikan. Dengan demikian, dapat disimpulkan bahwa PC1 menjadi komponen paling dominan dalam menjelaskan variasi data, sehingga proses reduksi dimensi dapat difokuskan pada komponen ini tanpa kehilangan terlalu banyak informasi penting dari data asli.

Tahap berikutnya adalah penentuan komponen utama PCA yang hasilnya terletak pada tabel 4.8. Berdasarkan tabel menampilkan hasil perhitungan PCA yang menghasilkan tiga komponen utama, yaitu PC1, PC2, dan PC3. Angka-angka pada tabel menunjukkan posisi setiap data setelah diproyeksikan ke dalam ruang PCA. Dari tabel terlihat bahwa nilai pada PC1 jauh lebih besar dibanding PC2 dan PC3. Misalnya, data pada indeks 0, 2, dan 3 memiliki nilai PC1 yang tinggi dan positif, sedangkan data pada indeks 10 sampai 14 justru bernilai negatif. Hal ini menunjukkan bahwa PC1 menjadi komponen paling berpengaruh dalam membedakan data. Sementara itu, nilai pada PC2 dan PC3 relatif kecil dan tidak terlalu jauh berbeda antar data, sehingga perannya hanya menambah sedikit informasi tambahan. Dengan kata lain, sebagian besar variasi data sudah cukup dijelaskan oleh PC1 saja.

Setelah komponen utama diperoleh melalui PCA, langkah berikutnya adalah memvisualisasikan data ke dalam bentuk grafik 2D dan 3D agar pola distribusi lebih mudah diamati. Visualisasi ini kemudian digunakan sebagai dasar untuk melakukan proses *clustering*, yaitu pengelompokan data ke dalam beberapa *cluster* berdasarkan jelas.

Setelah dilakukan PCA, data divisualisasikan dalam bentuk grafik 2D dan 3D berdasarkan komponen utama PC1, PC2, dan PC3. Proses *clustering* dilakukan dengan aturan yang menggunakan rentang nilai PC1 sebagai acuan. Data dengan nilai PC1 kurang dari 0 dikelompokkan sebagai *Cluster 0*, data dengan nilai PC1 berada pada rentang 0 hingga 2 masuk ke *Cluster 1*, sedangkan data dengan nilai PC1 lebih dari 2 dimasukkan ke *Cluster 2*. Dengan adanya rentang ini, visualisasi menjadi lebih jelas karena setiap area *cluster* dapat dibedakan baik pada grafik 2D maupun 3D. Pada gambar hasil visualisasi didapat bahwa titik pada *cluster 0* sebanyak 9 titik, *cluster 1* sebanyak 3 titik, dan *cluster 2* sebanyak 3 titik. Maka Hasil *clustering* tersebut termasuk *cluster 0* dikarenakan titik yang paling banyak terdapat pada *cluster 0*.

4.4 Integrasi Islam

Dalam penelitian ini, selain aspek teknis tentang pengolahan citra dan analisis data, juga penting untuk mengaitkan ilmu dengan nilai-nilai Islam. Islam mengajarkan bahwa setiap ilmu dan tindakan hendaknya membawa manfaat, menghindarkan kerusakan, dan memperkuat hubungan manusia dengan Allah, sesama manusia, dan lingkungan. Di bawah ini integrasi Islam terhadap penelitian ini dalam tiga dimensi: *muamalah Ma'a Allah*, *Ma'a An-Nas*, dan *Ma'a Al-Alam*.

4.4.1 Muamalah Ma'a Allah

Muamalah Ma'a Allah berkaitan dengan hubungan seorang hamba dengan Tuhannya, yaitu Allah SWT. Penelitian ini tidak hanya berusaha memahami fenomena kerusakan bangunan akibat bencana alam secara ilmiah, tetapi juga menjadikannya sebagai sarana untuk merenungi kebesaran Allah dan memperbaiki diri. Hal ini sesuai dengan firman Allah dalam QS. Ar-Rum ayat 41, yang berbunyi:

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

“Telah tampak kerusakan di darat dan di laut disebabkan karena perbuatan tangan manusia, supaya Allah merasakan kepada mereka sebagian dari (akibat) perbuatan mereka, agar mereka kembali (ke jalan yang benar)” (QS. Ar-Rum : 41).

Menurut Tafsir Departemen Agama Republik Indonesia, ayat ini menggambarkan bahwa kerusakan yang terjadi di darat dan di laut merupakan akibat dari pelanggaran manusia terhadap aturan dan sistem yang telah ditetapkan oleh Allah. Kata *al-fasād* mencakup berbagai bentuk perusakan, baik pencemaran lingkungan yang membuat alam tidak layak dihuni maupun kehancuran ekosistem yang menyebabkan hilangnya manfaat dari bumi dan laut. Termasuk dalam bentuk *al-fasād* juga tindakan-tindakan manusia seperti perampokan, peperangan, dan pemberontakan. Semua itu merupakan hasil dari perilaku manusia yang serakah dan tidak bertanggung jawab dalam memanfaatkan alam. Namun, Allah tidak semata menghukum manusia, melainkan memperingatkan mereka melalui akibat perbuatan itu agar mereka sadar dan kembali ke jalan yang benar, yaitu kembali

kepada ketaatan, kesyukuran, dan tanggung jawab menjaga ciptaan-Nya. (Departemen Agama RI, 2011).

Kaitannya dengan penelitian ini adalah bahwa penelitian ini berhubungan dengan bencana alam yang menyebabkan kerusakan pada bangunan. Dalam ayat Al-Qur'an ini, Allah menjelaskan bahwa kerusakan yang terjadi di bumi bukanlah tanpa sebab, melainkan akibat dari perbuatan manusia sendiri dan mengingatkan manusia agar mereka merasakan sebagian dari akibat perbuatannya, supaya manusia sadar dan kembali ke jalan yang benar. Pesan ini menunjukkan bahwa setiap bencana memiliki makna peringatan agar manusia tidak hanya memperbaiki kerusakan bangunan yang ada, tetapi juga memperbaiki hubungannya dengan Allah. *Muamalah ma'a Allah* dalam konteks ini berarti kesadaran untuk kembali kepada Allah yaitu memperbaiki diri, memperkuat keimanan, serta menggunakan ilmu dan kemampuan yang dimiliki sebagai bentuk tanggung jawab dalam memperbaiki kerusakan yang ada.

4.4.2 *Muamalah Ma'a An-Nas*

Muamalah Ma'a An-Nas adalah hubungan dan interaksi seorang hamba dengan sesama manusia yang berdasarkan nilai-nilai tolong-menolong, keadilan, dan tanggung jawab sosial. Dalam konteks penelitian ini, prinsip tersebut tercermin dalam bagaimana data digunakan dengan amanah dan hasil analisis dimanfaatkan untuk membantu masyarakat terdampak bencana. Hal ini sejalan dengan firman Allah SWT dalam QS. Al-Maidah ayat 2, yang berbunyi:

وَتَعَاوَنُوا عَلَى الْبِرِّ وَالتَّقْوَىٰ وَلَا تَعَاوَنُوا عَلَى الْإِثْمِ وَالْعُدْوَانِ وَاتَّقُوا اللَّهَ إِنَّ اللَّهَ شَدِيدُ

الْعِقَابِ

“Dan tolong-menolonglah kamu dalam (mengerjakan) kebajikan dan takwa, dan jangan tolong-menolong dalam berbuat dosa dan pelanggaran. Dan bertakwalah kepada Allah, sesungguhnya Allah amat berat siksaan-Nya.” (QS. Al-Maidah : 2).

Menurut *Tafsir Ibnu Katsir*, ayat ini mengandung perintah agar seorang hamba yang beriman saling menolong dalam kebaikan (*al-birru*), yaitu segala bentuk amal saleh dan perbuatan yang diridhai Allah, serta dalam ketakwaan (*at-taqwa*), yaitu menjauhi maksiat dan segala hal yang dilarang. Sebaliknya, Allah melarang umat Islam untuk bekerja sama dalam perbuatan dosa (*al-itsmu*) dan permusuhan (*al-‘udwan*). Ibnu Katsir mengutip penjelasan Ibnu Jarir bahwa *al-itsmu* berarti meninggalkan perintah Allah, sedangkan *al-‘udwan* berarti melampaui batas dalam urusan agama dan hak sesama manusia. Dengan demikian, kerja sama yang baik hanyalah yang membawa manfaat dan keridhaan Allah, sedangkan kerja sama yang membawa kerugian, keburukan, atau kezaliman termasuk dalam larangan ayat ini (Abdullah bin Muhammad, 2003).

Kandungan ayat dan tafsir ini berkaitan dengan penelitian ini. Dalam penerapan ilmu dan teknologi, terutama dalam analisis kerusakan bangunan pascabencana, prinsip tolong-menolong dapat diwujudkan dengan menggunakan hasil penelitian untuk membantu korban bencana secara adil dan tepat sasaran. Dengan menerapkan prinsip saling menolong, penelitian ini dapat membantu pihak-pihak yang membutuhkan, seperti memberikan informasi yang akurat untuk penyaluran bantuan dan perbaikan bangunan rusak yang terdampak bencana.

4.4.3 Muamalah Ma'a Al-Alam

Muamalah Ma'a Al-Alam berkaitan dengan hubungan manusia dengan alam atau lingkungan. Penelitian terhadap kerusakan bangunan pascabencana tentu berkaitan erat dengan alam: sebab, dampak, dan pemulihannya. Islam mengajarkan manusia sebagai khalifah yang memelihara alam, tidak merusaknya, dan menggunakan sumber daya secara bertanggung jawab. Hal tersebut sesuai dengan QS. Al-A'raf ayat 56, yang berbunyi:

وَلَا تُفْسِدُوا فِي الْأَرْضِ بَعْدَ إِصْلَاحِهَا وَادْعُوهُ خَوْفًا وَطَمَعًا إِنَّ رَحْمَتَ اللَّهِ قَرِيبٌ مِّنَ
الْمُحْسِنِينَ

“Dan janganlah kamu membuat kerusakan di muka bumi, sesudah (Allah) memperbaikinya dan berdoalah kepada-Nya dengan rasa takut (tidak akan diterima) dan harapan (akan dikabulkan). Sesungguhnya rahmat Allah amat dekat kepada orang-orang yang berbuat baik.” (QS. Al-A'raf: 56).

Menurut *Tafsir al-Mishbah*, Allah SWT menegaskan larangan bagi manusia untuk membuat kerusakan di muka bumi dalam bentuk apa pun. Allah telah menciptakan bumi dalam keadaan seimbang, indah, dan bermanfaat bagi kehidupan. Oleh karena itu, setiap tindakan yang merusak keseimbangan tersebut, baik berupa perusakan lingkungan, penindasan sosial, maupun perilaku moral yang menyimpang, merupakan bentuk pelanggaran terhadap amanah manusia sebagai khalifah di bumi. Manusia diperintahkan untuk memelihara dan memperbaiki keadaan bumi apabila terjadi kerusakan, sebab menjaga kelestarian dan keharmonisan alam adalah bagian dari tanggung jawab spiritual dan moral terhadap Sang Pencipta (Latifah & Marhayuni, 2023).

Dalam kaitannya dengan penelitian ini, kerusakan bangunan setelah bencana bisa dipahami sebagai ujian dan peringatan dari Allah agar manusia mau memperbaiki apa yang telah rusak. Setelah bencana terjadi, manusia memiliki tanggung jawab untuk memperbaiki keadaan, membangun kembali yang hancur, dan menjaga lingkungan agar tidak semakin rusak. Melalui penelitian ini, analisis kerusakan bangunan menggunakan *Gabor filters* dan PCA menjadi salah satu cara untuk membantu proses perbaikan tersebut. Hasil penelitian dapat digunakan untuk menentukan prioritas perbaikan bangunan dan mendukung pembangunan kembali yang lebih aman dan berkelanjutan. Dengan begitu, penelitian ini menjadi bentuk usaha manusia untuk memperbaiki lingkungan setelah terjadinya kerusakan, sebagaimana pesan yang terdapat dalam QS. Al-A'raf ayat 56.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan mengenai identifikasi tingkat kerusakan bangunan pascabencana dengan ekstraksi fitur menggunakan *Gabor filters* dan pengelompokan menggunakan PCA *Clustering*, maka dapat ditarik beberapa kesimpulan sebagai berikut:

1. *Gabor filters* berhasil mengekstraksi fitur tekstur citra bangunan pascabencana melalui proses konvolusi, magnitude, normalisasi, serta perhitungan kontras, *mean*, dan energi. Hasilnya menghasilkan representasi tekstur yang informatif untuk analisis lanjutan.
2. PCA efektif mereduksi dimensi dan menemukan komponen utama data. Komponen pertama (PC1) memiliki explained variance sebesar 99,26% dengan eigen value 3,19, sehingga cukup representatif untuk menggambarkan variasi utama dan dijadikan dasar pengelompokan.
3. *Clustering* berbasis PCA membagi data menjadi tiga *cluster* (0, 1, 2) berdasarkan rentang nilai PC1. Pemisahan ini terlihat jelas pada visualisasi 2D dan 3D, menunjukkan kemampuan PCA tidak hanya dalam reduksi dimensi tetapi juga pengelompokan tanpa label.
4. Hasil *silhouette score* menunjukkan bahwa penggunaan tiga *cluster* memberikan nilai tertinggi dan mendekati 1, yang berarti kualitas *clustering* sangat baik. Karena itu, kombinasi *Gabor Filters* dan PCA *Clustering* efektif dan praktis untuk mengelompokkan citra bangunan pascabencana.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, penulis memberikan beberapa saran yang diharapkan dapat menjadi masukan untuk penelitian selanjutnya maupun pengembangan sistem:

1. Pada penelitian ini, pengelompokan hanya dilakukan menggunakan PCA *Clustering*. Untuk penelitian selanjutnya, dapat dipertimbangkan penerapan metode *clustering* lain seperti K-Means, DBSCAN, atau *Hierarchical Clustering* sebagai pembanding. Dengan adanya perbandingan tersebut, dapat diketahui kelebihan dan kelemahan masing-masing metode, serta dapat dipilih pendekatan yang paling sesuai untuk konteks identifikasi kerusakan bangunan pascabencana.
2. Dataset yang digunakan dalam penelitian ini masih terbatas pada jumlah dan variasi citra bangunan. Oleh karena itu, penelitian berikutnya disarankan untuk menggunakan dataset yang lebih besar, beragam, dan diperoleh dari berbagai jenis bencana serta wilayah yang berbeda. Hal ini penting agar sistem dapat mengenali pola tekstur yang lebih kompleks dan hasil *clustering* menjadi lebih representatif terhadap kondisi nyata di lapangan.

DAFTAR PUSTAKA

- Abdullah bin Muhammad. (2003). *Tafsir Ibnu Katsir Jilid 3* (Cetakan Kedua, Vol. 3). Pustaka Imam asy-Syafi'i.
- Almais, A. T. W., Susilo, A., Muhtaidah, A., & Wicaksono, H. (2025). *Post-Disaster Building Damage Assessment Using PCA-Clustering Based on Watershed Segmentation with Augmentation*. <https://doi.org/10.36227/techrxiv.173933047.71267877/v1>
- Almais, A. T. W., Susilo, A., Naba, A., Sarosa, M., Crysdian, 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., Crysdian, C., Muslim, M. A., & Wicaksono, H. (2024). Characterization of Structural Building Damage in Post-Disaster using GLCM-PCA Analysis Integration. *IEEE Access*, 1. <https://doi.org/10.1109/ACCESS.2024.3469637>
- Andini, D. P., Sugiarta, Y. B. G., & Zaelani, E. P. S. (2020). Pendeteksian dan Pengenalan Citra Wajah dengan Ekstraksi Fitur Menggunakan Filter Gabor. *JTERA (Jurnal Teknologi Rekayasa)*, 5(2), 257. <https://doi.org/10.31544/jtera.v5.i2.2020.257-266>
- Ari Septian, A. M., Afwani, R., & Albar, Moh. A. (2020). Implementasi Metode Simple Additive Weighting (SAW) dalam Sistem Pendukung Keputusan Penentuan Penerima Bantuan Korban Bencana Alam Gempa (Studi Kasus: BPBD Lombok Barat). *Jurnal Teknologi Informasi, Komputer, dan Aplikasinya (JTika)*, 2(2), 196–207. <https://doi.org/10.29303/jtika.v2i2.101>
- Aristoteles, -, Heningsy, Y., Syarif, A., & Pratidina, A. G. (2021). Implementation of Gabor Filter for Carassius Auratus's Identification. *International Journal on Advanced Science, Engineering and Information Technology*, 11(2), 566–571. <https://doi.org/10.18517/ijaseit.11.2.8128>
- Azzahra, Q. A., & Koesyanto, H. (2023). Efektivitas Tim Reaksi Cepat. *HIGEIA (Journal of Public Health Research and Development)*, 7(1), 1–11. <https://doi.org/10.15294/higeia.v7i1.58841>
- B, K., George, D. J., G, M., & Thomas, T. (2020). A Comparative Study on K-Means Clustering and Agglomerative Hierarchical Clustering. *International Journal of Emerging Trends in Engineering Research*, 8(5), 1600–1604. <https://doi.org/10.30534/ijeter/2020/20852020>

- Bui, H. M., Lech, M., Cheng, E., Neville, K., & Burnett, I. S. (2016). Using grayscale images for object recognition with convolutional-recursive neural network. *2016 IEEE Sixth International Conference on Communications and Electronics (ICCE)*, 321–325. <https://doi.org/10.1109/CCE.2016.7562656>
- Chakraborty, S., Mali, K., Chatterjee, S., & Sen, S. (2021). Preprocessing and Discrimination of Cytopathological Images. Dalam A. Mitra, J. Mondal, & A. Das, *Medical Internet of Things* (1 ed., hlm. 33–47). Chapman and Hall/CRC. <https://doi.org/10.1201/9780429318078-3>
- Dar, A. N. (2021). Principal Component Analysis (PCA). *Global Scientific Journals*, 9(7), 240–252.
- Departemen Agama RI. (2011). *Al-Qur'an dan Tafsirnya Jilid VII* (Ed. yang disempurnakan, Vol. 7). Widya Cahaya.
- Hasan, Y. (2024). Pengukuran *Silhouette score* Dan Davies-Bouldin Index Pada Hasil *Cluster K-Means* Dan *Dbscan*. *Jurnal Informatika dan Teknik Elektro Terapan*, 12(3S1). <https://doi.org/10.23960/jitet.v12i3S1.5001>
- Hediyati, D., & Suartana, I. M. (2021). Penerapan Principal Component Analysis (PCA) Untuk Reduksi Dimensi Pada Proses *Clustering* Data Produksi Pertanian Di Kabupaten Bojonegoro. *Journal of Information Engineering and Educational Technology*, 5(2), 49–54. <https://doi.org/10.26740/jieet.v5n2.p49-54>
- Huang, D., Wang, C.-D., Peng, H., Lai, J., & Kwoh, C.-K. (2021). Enhanced Ensemble *Clustering* via Fast Propagation of *Cluster-Wise* Similarities. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 51(1), 508–520. <https://doi.org/10.1109/TSMC.2018.2876202>
- Imelda, A., Farihin, M. Z., Sholihah, N. C., & Sari, D. P. (2024). Dinamika Pergerakan Lempeng Tektonik Menggunakan Analisis Literatur Tentang Teori Dan Dampaknya. *Journal of Science Education*, 4(1), 75–80. <https://doi.org/10.52562/biochephy.v4i1.1088>
- Kangane, P., Joshi, V., Kacker, A., & Jain, M. (2021). A Comprehensive Survey Of Various *Clustering* Paradigms. *International Journal of Engineering Applied Sciences and Technology*, 5(11). <https://doi.org/10.33564/IJEAST.2021.v05i11.042>
- Koiku, I., & Muñoz-Coreas, E. (2024). A Novel Quantum Generalized Neighbor Interpolation Design for Image Transformations. *2024 IEEE Computer Society Annual Symposium on VLSI (ISVLSI)*, 632–633. <https://doi.org/10.1109/ISVLSI61997.2024.00120>
- Latifah, L., & Marhayuni, Y. (2023). Bioremediasi Sebagai Implementasi Q.S Al-A'raf Ayat 56 Dalam Menangani Pencemaran Tanah. *Kaunia: Integration*

and Interconnection Islam and Science Journal, 19(1), 23–28.
<https://doi.org/10.14421/kaunia.3780>

Li, Y., Bi, Y., Zhang, W., Ren, J., & Chen, J. (2023). M2GF: Multi-Scale and Multi-Directional *Gabor filters* for Image Edge Detection. *Applied Sciences*, 13(16), 9409. <https://doi.org/10.3390/app13169409>

Marbun, G. J. H., Bambang Susetyarto, M., & Tundono, S. (2024). Struktur Dan Konstruksi Tahan Gempa Sebagai Gagasan Eksplorasi Bentuk Bangunan Pusat Evakuasi. *Metrik Serial Teknologi dan Sains*, 5(1), 49–56.
<https://doi.org/10.51616/teksi.v5i1.512>

Marinov, M., Kalmukov, Y., & Valova, I. (2021). Content-Based Image Retrieval: Impact of image resolution on the search accuracy and results ordering. *2021 International Conference Automatics and Informatics (ICAI)*, 72–75.
<https://doi.org/10.1109/ICAI52893.2021.9639858>

Marmol, U., & Borowiec, N. (2020). Detection of Line Objects by *Means* of Gabor Wavelets and Hough Transform. *Archives of Civil Engineering*, 339–363.
<https://doi.org/10.24425/ace.2020.134401>

Minarno, A. E., Mandiri, M. H. C., & Alfarizy, M. R. (2021). Klasifikasi COVID-19 menggunakan Filter Gabor dan CNN dengan Hyperparameter Tuning. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 9(3), 493. <https://doi.org/10.26760/elkomika.v9i3.493>

Purnamasari, P., Imamudin, M., Zaman, S., Syauqi, A., & Almais, A. T. W. (2025). *Clustering* of Post-Disaster Building Damage Levels Using Discrete Wavelet Transform and Principal Component Analysis. *Journal of Information Technology and Cyber Security*, 3(1), 33–44.
<https://doi.org/10.30996/jitscs.12270>

Rastiveis, H., Teymoor Seydi, S., Chen, Z., & Li, J. (2023). Seismic urban damage map generation based on satellite images and Gabor convolutional neural networks. *International Journal of Applied Earth Observation and Geoinformation*, 122, 103450. <https://doi.org/10.1016/j.jag.2023.103450>

Rizki, A. M., & Marina, N. (2019). Klasifikasi Kerusakan Bangunan Sekolah Menggunakan Metode Convolutional Neural Network Dengan Pre-Trained Model Vgg-16. *Jurnal Ilmiah Teknologi dan Rekayasa*, 24(3), 197–206.
<https://doi.org/10.35760/tr.2019.v24i3.2396>











Rizvi, S. T. H., Cabodi, G., Gusmao, P., & Francini, G. (2016). Gabor filter based image representation for object classification. *2016 International Conference on Control, Decision and Information Technologies (CoDIT)*, 628–632. <https://doi.org/10.1109/CoDIT.2016.7593635>













- Sabini, B. (2021). Perbandingan Metode Konversi Grayscale Menggunakan Metrik Kualitas Butteraugli. *Jurnal Inovasi Informatika*, 6(2), 38–54. <https://doi.org/10.51170/jii.v6i2.189>
- Sari, I. P., Hidayat, B., & Atmaja, R. D. (2016). *Perancangan dan Simulasi Deteksi Penyakit Tanaman Jagung Berbasis Pengolahan Citra Digital Menggunakan Metode Color Moments dan GLCM*.
- Shahapure, K. R., & Nicholas, C. (2020). Cluster Quality Analysis Using Silhouette score . 2020 IEEE 7th International Conference on Data Science and Advanced Analytics (DSAA), 747–748. <https://doi.org/10.1109/DSAA49011.2020.00096>
- Sudhakar, K., & Nithyanandam, P. (2017). An Accurate Facial Component Detection Using Gabor Filter. *Bulletin of Electrical Engineering and Informatics*, 6(3), 287–294. <https://doi.org/10.11591/eei.v6i3.683>
- Sulistyaningrum, D. R., Setiyono, B., Anita, J. N., & Muheimin, M. R. (2021). Measurement of Crack Damage Dimensions on Asphalt Road Using Gabor Filter. *Journal of Physics: Conference Series*, 1752(1), 012086. <https://doi.org/10.1088/1742-6596/1752/1/012086>
- Taufan Maulana, A., & Andriansyah, A. (2024). Mitigasi Bencana di Indonesia. *COMSERVA : Jurnal Penelitian dan Pengabdian Masyarakat*, 3(10), 3996–4012. <https://doi.org/10.59141/comserva.v3i10.1213>
- Troccoli, E. B., Cerqueira, A. G., Lemos, J. B., & Holz, M. (2022). K-means clustering using principal component analysis to automate label organization in multi-attribute seismic facies analysis. *Journal of Applied Geophysics*, 198, 104555. <https://doi.org/10.1016/j.jappgeo.2022.104555>
- Velunachiyar, S., & Sivakumar, K. (2023). Some Clustering Methods, Algorithms and their Applications. *International Journal on Recent and Innovation Trends in Computing and Communication*, 11(6s), 401–410. <https://doi.org/10.17762/ijritcc.v11i6s.6946>
- Wijaya, I. R. (2017). Analisis dan Implementasi Metode Gabor Filter dan Support Vector Machine pada Klasifikasi Sidik Jari. *Indonesian Journal on Computing (Indo-JC)*, 2(2), 37. <https://doi.org/10.21108/INDOJC.2017.2.2.176>
- Xie, B., Xu, Y., Wang, G., Yang, S., & Li, Y. (2023). Adaptive grayscale method based on weighted guided filtering. Dalam S. Saxena & S. Xu (Ed.), *International Conference on Signal Processing and Communication Technology (SPCT 2022)* (hlm. 13). SPIE. <https://doi.org/10.1117/12.2673796>
- Zakhra, V. M., Styawan, Y., Fattah, E. I., & Farduwin, A. (2023). Analisis Gempa Cianjur 2022 Dengan Pendekatan Spasial Temporal a-Value Dan b-Value.











JGE (Jurnal Geofisika Eksplorasi), 9(3), 217–230.
<https://doi.org/10.23960/jge.v9i3.318>













LAMPIRAN













Lampiran 1 Hasil Dataset





No	Citra Bangunan	Visualisasi		Silhoutte Score
		2D	3D	
1.				0.8491
2.				0.7389
3.				0.8374
4.				0.6719
5.				0.7457

No	Citra Bangunan	Visualisasi		Silhoutte Score
		2D	3D	
6.				0.7397
7.				0.7043
8.				0.8539
9.				0.7397
10.				0.8190
11.				0.7784

No	Citra Bangunan	Visualisasi		Silhouette Score
		2D	3D	
12.				0.7463
13.				0.7650
14.				0.7520
15.				0.6091
16.				0.7352

No	Citra Bangunan	Visualisasi		Silhoutte Score
		2D	3D	
17.				0.6589
18.				0.7377
19.				0.7617
20.				0.8017
21.				0.7922
22.				0.6265

No	Citra Bangunan	Visualisasi		Silhoutte Score
		2D	3D	
23.				0.7750
24.				0.6948
25.				0.7391
26.				0.6738
27.				0.7399
28.				0.7825

No	Citra Bangunan	Visualisasi		Silhoutte Score
		2D	3D	
29.				0.7399
30.				0.7825

Lampiran 2 Hasil Gabor Filters

GaborArray{1,1} U0V0						
-0.0000 + 0.2451i	-0.4578 - 0.0000i	0.0000 - 0.6661i	0.7548 + 0.0000i	0.0000 + 0.6661i	-0.4578 + 0.0000i	-0.0000 - 0.2451i
-0.0000 + 0.2865i	-0.5353 - 0.0000i	0.0000 - 0.7788i	0.8825 + 0.0000i	0.0000 + 0.7788i	-0.5353 + 0.0000i	-0.0000 - 0.2865i
-0.0000 + 0.3147i	-0.5879 - 0.0000i	0.0000 - 0.8553i	0.9692 + 0.0000i	0.0000 + 0.8553i	-0.5879 + 0.0000i	-0.0000 - 0.3147i
-0.0000 + 0.3247i	-0.6065 - 0.0000i	0.0000 - 0.8825i	1.0000 + 0.0000i	0.0000 + 0.8825i	-0.6065 + 0.0000i	-0.0000 - 0.3247i
-0.0000 + 0.3147i	-0.5879 - 0.0000i	0.0000 - 0.8553i	0.9692 + 0.0000i	0.0000 + 0.8553i	-0.5879 + 0.0000i	-0.0000 - 0.3147i
-0.0000 + 0.2865i	-0.5353 - 0.0000i	0.0000 - 0.7788i	0.8825 + 0.0000i	0.0000 + 0.7788i	-0.5353 + 0.0000i	-0.0000 - 0.2865i
-0.0000 + 0.2451i	-0.4578 - 0.0000i	0.0000 - 0.6661i	0.7548 + 0.0000i	0.0000 + 0.6661i	-0.4578 + 0.0000i	-0.0000 - 0.2451i
GaborArray{1,2} U0V1						
0.1050 - 0.0324i	0.1286 + 0.1883i	-0.2448 + 0.3080i	-0.5255 - 0.2048i	0.0481 - 0.6700i	0.6476 - 0.1504i	0.2756 + 0.4722i
0.1601 + 0.1153i	-0.1194 + 0.3552i	-0.5911 - 0.0143i	-0.2111 - 0.7460i	0.7085 - 0.4599i	0.5873 + 0.4897i	-0.2213 + 0.5309i
0.0073 + 0.3120i	-0.5140 + 0.1722i	-0.4567 - 0.6353i	0.5660 - 0.7484i	0.8792 + 0.3185i	-0.0368 + 0.7735i	-0.5159 + 0.1331i
-0.3404 + 0.2701i	-0.5698 - 0.3898i	0.2694 - 0.8708i	1.0000 + 0.0000i	0.2694 + 0.8708i	-0.5698 + 0.3898i	-0.3404 - 0.2701i
-0.5159 - 0.1331i	-0.0368 - 0.7735i	0.8792 - 0.3185i	0.5660 + 0.7484i	-0.4567 + 0.6353i	-0.5140 - 0.1722i	0.0073 - 0.3120i
-0.2213 - 0.5309i	0.5873 - 0.4897i	0.7085 + 0.4599i	-0.2111 + 0.7460i	-0.5911 + 0.0143i	-0.1194 - 0.3552i	0.1601 - 0.1153i
0.2756 - 0.4722i	0.6476 + 0.1504i	0.0481 + 0.6700i	-0.5255 + 0.2048i	-0.2448 - 0.3080i	0.1286 - 0.1883i	0.1050 + 0.0324i
GaborArray{1,3} U0V2						
0.1404 + 0.0505i	0.1452 + 0.1589i	0.0722 + 0.2773i	-0.0804 + 0.3426i	-0.2618 + 0.3009i	-0.3889 + 0.1505i	-0.3997 - 0.0466i
-0.0834 + 0.3033i	-0.2939 + 0.3131i	-0.5114 + 0.1761i	-0.6212 - 0.0963i	-0.5411 - 0.4022i	-0.2880 - 0.6019i	0.0239 - 0.6089i
-0.5160 - 0.1000i	-0.5293 - 0.4253i	-0.3216 - 0.7429i	0.0684 - 0.8878i	0.4818 - 0.7647i	0.7333 - 0.4229i	0.7311 - 0.0276i
0.0796 - 0.6918i	0.4808 - 0.7027i	0.8496 - 0.4482i	1.0000 + 0.0000i	0.8496 + 0.4482i	0.4808 + 0.7027i	0.0796 + 0.6918i
0.7311 + 0.0276i	0.7333 + 0.4229i	0.4818 + 0.7647i	0.0684 + 0.8878i	-0.3216 + 0.7429i	-0.5293 + 0.4253i	-0.5160 + 0.1000i
0.0239 + 0.6089i	-0.2880 + 0.6019i	-0.5411 + 0.4022i	-0.6212 + 0.0963i	-0.5114 - 0.1761i	-0.2939 - 0.3131i	-0.0834 - 0.3033i
-0.3997 + 0.0466i	-0.3889 - 0.1505i	-0.2618 - 0.3009i	-0.0804 - 0.3426i	0.0722 - 0.2773i	0.1452 - 0.1589i	0.1404 - 0.0505i
GaborArray{1,4} U0V3						
-0.3997 - 0.0466i	-0.3889 + 0.1505i	-0.2618 + 0.3009i	-0.0804 + 0.3426i	0.0722 + 0.2773i	0.1452 + 0.1589i	0.1404 + 0.0505i
0.0239 - 0.6089i	-0.2880 - 0.6019i	-0.5411 - 0.4022i	-0.6212 - 0.0963i	-0.5114 + 0.1761i	-0.2939 + 0.3131i	-0.0834 + 0.3033i
0.7311 - 0.0276i	0.7333 - 0.4229i	0.4818 - 0.7647i	0.0684 - 0.8878i	-0.3216 - 0.7429i	-0.5293 - 0.4253i	-0.5160 - 0.1000i

0.0796 + 0.6918i	0.4808 + 0.7027i	0.8496 + 0.4482i	1.0000 + 0.0000i	0.8496 - 0.4482i	0.4808 - 0.7027i	0.0796 - 0.6918i
-0.5160 + 0.1000i	-0.5293 + 0.4253i	-0.3216 + 0.7429i	0.0684 + 0.8878i	0.4818 + 0.7647i	0.7333 + 0.4229i	0.7311 + 0.0276i
-0.0834 - 0.3033i	-0.2939 - 0.3131i	-0.5114 - 0.1761i	-0.6212 + 0.0963i	-0.5411 + 0.4022i	-0.2880 + 0.6019i	0.0239 + 0.6089i
0.1404 - 0.0505i	0.1452 - 0.1589i	0.0722 - 0.2773i	-0.0804 - 0.3426i	-0.2618 - 0.3009i	-0.3889 - 0.1505i	-0.3997 + 0.0466i
GaborArray{1,5} U0V4						
0.2756 + 0.4722i	0.6476 - 0.1504i	0.0481 - 0.6700i	-0.5255 - 0.2048i	-0.2448 + 0.3080i	0.1286 + 0.1883i	0.1050 - 0.0324i
-0.2213 + 0.5309i	0.5873 + 0.4897i	0.7085 - 0.4599i	-0.2111 - 0.7460i	-0.5911 - 0.0143i	-0.1194 + 0.3552i	0.1601 + 0.1153i
-0.5159 + 0.1331i	-0.0368 + 0.7735i	0.8792 + 0.3185i	0.5660 - 0.7484i	-0.4567 - 0.6353i	-0.5140 + 0.1722i	0.0073 + 0.3120i
-0.3404 - 0.2701i	-0.5698 + 0.3898i	0.2694 + 0.8708i	1.0000 + 0.0000i	0.2694 - 0.8708i	-0.5698 - 0.3898i	-0.3404 + 0.2701i
0.0073 - 0.3120i	-0.5140 - 0.1722i	-0.4567 + 0.6353i	0.5660 + 0.7484i	0.8792 - 0.3185i	-0.0368 - 0.7735i	-0.5159 - 0.1331i
0.1601 - 0.1153i	-0.1194 - 0.3552i	-0.5911 + 0.0143i	-0.2111 + 0.7460i	0.7085 + 0.4599i	0.5873 - 0.4897i	-0.2213 - 0.5309i
0.1050 + 0.0324i	0.1286 - 0.1883i	-0.2448 - 0.3080i	-0.5255 + 0.2048i	0.0481 + 0.6700i	0.6476 + 0.1504i	0.2756 - 0.4722i
GaborArray{2,1} U1V0						
-0.2406 + 0.0464i	-0.2773 - 0.3643i	0.2958 - 0.5969i	0.7548 + 0.0000i	0.2958 + 0.5969i	-0.2773 + 0.3643i	-0.2406 - 0.0464i
-0.2813 + 0.0543i	-0.3242 - 0.4259i	0.3458 - 0.6978i	0.8825 + 0.0000i	0.3458 + 0.6978i	-0.3242 + 0.4259i	-0.2813 - 0.0543i
-0.3090 + 0.0596i	-0.3561 - 0.4678i	0.3798 - 0.7664i	0.9692 + 0.0000i	0.3798 + 0.7664i	-0.3561 + 0.4678i	-0.3090 - 0.0596i
-0.3188 + 0.0615i	-0.3674 - 0.4826i	0.3918 - 0.7907i	1.0000 + 0.0000i	0.3918 + 0.7907i	-0.3674 + 0.4826i	-0.3188 - 0.0615i
-0.3090 + 0.0596i	-0.3561 - 0.4678i	0.3798 - 0.7664i	0.9692 + 0.0000i	0.3798 + 0.7664i	-0.3561 + 0.4678i	-0.3090 - 0.0596i
-0.2813 + 0.0543i	-0.3242 - 0.4259i	0.3458 - 0.6978i	0.8825 + 0.0000i	0.3458 + 0.6978i	-0.3242 + 0.4259i	-0.2813 - 0.0543i
-0.2406 + 0.0464i	-0.2773 - 0.3643i	0.2958 - 0.5969i	0.7548 + 0.0000i	0.2958 + 0.5969i	-0.2773 + 0.3643i	-0.2406 - 0.0464i
GaborArray{2,2} U1V1						
-0.0064 + 0.1097i	-0.1864 + 0.1314i	-0.3776 - 0.1104i	-0.2133 - 0.5221i	0.3284 - 0.5860i	0.6562 - 0.1068i	0.4048 + 0.3675i
-0.1287 + 0.1495i	-0.3744 - 0.0145i	-0.3500 - 0.4765i	0.2031 - 0.7482i	0.7756 - 0.3345i	0.6741 + 0.3608i	0.1034 + 0.5658i
-0.3054 + 0.0641i	-0.4175 - 0.3457i	0.0151 - 0.7822i	0.7454 - 0.5700i	0.9070 + 0.2275i	0.3203 + 0.7050i	-0.2423 + 0.4745i
-0.3921 - 0.1874i	-0.1550 - 0.6728i	0.5676 - 0.7132i	1.0000 + 0.0000i	0.5676 + 0.7132i	-0.1550 + 0.6728i	-0.3921 + 0.1874i
-0.2423 - 0.4745i	0.3203 - 0.7050i	0.9070 - 0.2275i	0.7454 + 0.5700i	0.0151 + 0.7822i	-0.4175 + 0.3457i	-0.3054 - 0.0641i
0.1034 - 0.5658i	0.6741 - 0.3608i	0.7756 + 0.3345i	0.2031 + 0.7482i	-0.3500 + 0.4765i	-0.3744 + 0.0145i	-0.1287 - 0.1495i
0.4048 - 0.3675i	0.6562 + 0.1068i	0.3284 + 0.5860i	-0.2133 + 0.5221i	-0.3776 + 0.1104i	-0.1864 - 0.1314i	-0.0064 - 0.1097i
GaborArray{2,3} U1V2						

-0.0733 + 0.1300i	-0.1627 + 0.1410i	-0.2671 + 0.1038i	-0.3518 + 0.0097i	-0.3791 - 0.1238i	-0.3297 - 0.2553i	-0.2167 - 0.3391i
-0.3145 + 0.0003i	-0.4045 - 0.1442i	-0.4186 - 0.3425i	-0.3242 - 0.5386i	-0.1331 - 0.6610i	0.0961 - 0.6603i	0.2856 - 0.5383i
-0.2590 - 0.4574i	-0.1162 - 0.6690i	0.1379 - 0.7977i	0.4381 - 0.7752i	0.6836 - 0.5913i	0.7892 - 0.3060i	0.7313 - 0.0195i
0.3587 - 0.5969i	0.6586 - 0.5397i	0.9046 - 0.3233i	1.0000 + 0.0000i	0.9046 + 0.3233i	0.6586 + 0.5397i	0.3587 + 0.5969i
0.7313 + 0.0195i	0.7892 + 0.3060i	0.6836 + 0.5913i	0.4381 + 0.7752i	0.1379 + 0.7977i	-0.1162 + 0.6690i	-0.2590 + 0.4574i
0.2856 + 0.5383i	0.0961 + 0.6603i	-0.1331 + 0.6610i	-0.3242 + 0.5386i	-0.4186 + 0.3425i	-0.4045 + 0.1442i	-0.3145 - 0.0003i
-0.2167 + 0.3391i	-0.3297 + 0.2553i	-0.3791 + 0.1238i	-0.3518 - 0.0097i	-0.2671 - 0.1038i	-0.1627 - 0.1410i	-0.0733 - 0.1300i
GaborArray{2,4} U1V3						
-0.2167 - 0.3391i	-0.3297 - 0.2553i	-0.3791 - 0.1238i	-0.3518 + 0.0097i	-0.2671 + 0.1038i	-0.1627 + 0.1410i	-0.0733 + 0.1300i
0.2856 - 0.5383i	0.0961 - 0.6603i	-0.1331 - 0.6610i	-0.3242 - 0.5386i	-0.4186 - 0.3425i	-0.4045 - 0.1442i	-0.3145 + 0.0003i
0.7313 - 0.0195i	0.7892 - 0.3060i	0.6836 - 0.5913i	0.4381 - 0.7752i	0.1379 - 0.7977i	-0.1162 - 0.6690i	-0.2590 - 0.4574i
0.3587 + 0.5969i	0.6586 + 0.5397i	0.9046 + 0.3233i	1.0000 + 0.0000i	0.9046 - 0.3233i	0.6586 - 0.5397i	0.3587 - 0.5969i
-0.2590 + 0.4574i	-0.1162 + 0.6690i	0.1379 + 0.7977i	0.4381 + 0.7752i	0.6836 + 0.5913i	0.7892 + 0.3060i	0.7313 + 0.0195i
-0.3145 - 0.0003i	-0.4045 + 0.1442i	-0.4186 + 0.3425i	-0.3242 + 0.5386i	-0.1331 + 0.6610i	0.0961 + 0.6603i	0.2856 + 0.5383i
-0.0733 - 0.1300i	-0.1627 - 0.1410i	-0.2671 - 0.1038i	-0.3518 - 0.0097i	-0.3791 + 0.1238i	-0.3297 + 0.2553i	-0.2167 + 0.3391i
GaborArray{2,5} U1V4						
0.4048 + 0.3675i	0.6562 - 0.1068i	0.3284 - 0.5860i	-0.2133 - 0.5221i	-0.3776 - 0.1104i	-0.1864 + 0.1314i	-0.0064 + 0.1097i
0.1034 + 0.5658i	0.6741 + 0.3608i	0.7756 - 0.3345i	0.2031 - 0.7482i	-0.3500 - 0.4765i	-0.3744 - 0.0145i	-0.1287 + 0.1495i
-0.2423 + 0.4745i	0.3203 + 0.7050i	0.9070 + 0.2275i	0.7454 - 0.5700i	0.0151 - 0.7822i	-0.4175 - 0.3457i	-0.3054 + 0.0641i
-0.3921 + 0.1874i	-0.1550 + 0.6728i	0.5676 + 0.7132i	1.0000 + 0.0000i	0.5676 - 0.7132i	-0.1550 - 0.6728i	-0.3921 - 0.1874i
-0.3054 - 0.0641i	-0.4175 + 0.3457i	0.0151 + 0.7822i	0.7454 + 0.5700i	0.9070 - 0.2275i	0.3203 - 0.7050i	-0.2423 - 0.4745i
-0.1287 - 0.1495i	-0.3744 + 0.0145i	-0.3500 + 0.4765i	0.2031 + 0.7482i	0.7756 + 0.3345i	0.6741 - 0.3608i	0.1034 - 0.5658i
-0.0064 - 0.1097i	-0.1864 - 0.1314i	-0.3776 + 0.1104i	-0.2133 + 0.5221i	0.3284 + 0.5860i	0.6562 + 0.1068i	0.4048 - 0.3675i
GaborArray{3,1} U2V0						
-0.1733 - 0.1733i	0.0000 - 0.4578i	0.4710 - 0.4710i	0.7548 + 0.0000i	0.4710 + 0.4710i	0.0000 + 0.4578i	-0.1733 + 0.1733i
-0.2026 - 0.2026i	0.0000 - 0.5353i	0.5507 - 0.5507i	0.8825 + 0.0000i	0.5507 + 0.5507i	0.0000 + 0.5353i	-0.2026 + 0.2026i
-0.2225 - 0.2225i	0.0000 - 0.5879i	0.6048 - 0.6048i	0.9692 + 0.0000i	0.6048 + 0.6048i	0.0000 + 0.5879i	-0.2225 + 0.2225i
-0.2296 - 0.2296i	0.0000 - 0.6065i	0.6240 - 0.6240i	1.0000 + 0.0000i	0.6240 + 0.6240i	0.0000 + 0.6065i	-0.2296 + 0.2296i

-0.2225 - 0.2225i	0.0000 - 0.5879i	0.6048 - 0.6048i	0.9692 + 0.0000i	0.6048 + 0.6048i	0.0000 + 0.5879i	-0.2225 + 0.2225i
-0.2026 - 0.2026i	0.0000 - 0.5353i	0.5507 - 0.5507i	0.8825 + 0.0000i	0.5507 + 0.5507i	0.0000 + 0.5353i	-0.2026 + 0.2026i
-0.1733 - 0.1733i	0.0000 - 0.4578i	0.4710 - 0.4710i	0.7548 + 0.0000i	0.4710 + 0.4710i	0.0000 + 0.4578i	-0.1733 + 0.1733i
GaborArray{3,2} U2V1						
-0.1086 + 0.0164i	-0.2017 - 0.1065i	-0.1710 - 0.3543i	0.1042 - 0.5543i	0.4917 - 0.4577i	0.6605 - 0.0757i	0.4741 + 0.2723i
-0.1878 - 0.0606i	-0.2187 - 0.3042i	0.0072 - 0.5912i	0.4676 - 0.6183i	0.8099 - 0.2398i	0.7189 + 0.2604i	0.3190 + 0.4786i
-0.2232 - 0.2181i	-0.0872 - 0.5350i	0.3569 - 0.6962i	0.8401 - 0.4180i	0.9210 + 0.1617i	0.5344 + 0.5604i	0.0671 + 0.5285i
-0.1430 - 0.4103i	0.2040 - 0.6596i	0.7336 - 0.5410i	1.0000 + 0.0000i	0.7336 + 0.5410i	0.2040 + 0.6596i	-0.1430 + 0.4103i
0.0671 - 0.5285i	0.5344 - 0.5604i	0.9210 - 0.1617i	0.8401 + 0.4180i	0.3569 + 0.6962i	-0.0872 + 0.5350i	-0.2232 + 0.2181i
0.3190 - 0.4786i	0.7189 - 0.2604i	0.8099 + 0.2398i	0.4676 + 0.6183i	0.0072 + 0.5912i	-0.2187 + 0.3042i	-0.1878 + 0.0606i
0.4741 - 0.2723i	0.6605 + 0.0757i	0.4917 + 0.4577i	0.1042 + 0.5543i	-0.1710 + 0.3543i	-0.2017 + 0.1065i	-0.1086 - 0.0164i
GaborArray{3,3} U2V2						
-0.1470 - 0.0256i	-0.1970 - 0.0869i	-0.2267 - 0.1752i	-0.2185 - 0.2758i	-0.1653 - 0.3629i	-0.0766 - 0.4099i	0.0233 - 0.4017i
-0.1907 - 0.2502i	-0.1706 - 0.3940i	-0.0893 - 0.5334i	0.0483 - 0.6268i	0.2118 - 0.6401i	0.3557 - 0.5645i	0.4392 - 0.4223i
0.0502 - 0.5232i	0.2255 - 0.6405i	0.4444 - 0.6766i	0.6534 - 0.6050i	0.7913 - 0.4367i	0.8177 - 0.2189i	0.7314 - 0.0138i
0.5198 - 0.4634i	0.7531 - 0.3973i	0.9324 - 0.2309i	1.0000 + 0.0000i	0.9324 + 0.2309i	0.7531 + 0.3973i	0.5198 + 0.4634i
0.7314 + 0.0138i	0.8177 + 0.2189i	0.7913 + 0.4367i	0.6534 + 0.6050i	0.4444 + 0.6766i	0.2255 + 0.6405i	0.0502 + 0.5232i
0.4392 + 0.4223i	0.3557 + 0.5645i	0.2118 + 0.6401i	0.0483 + 0.6268i	-0.0893 + 0.5334i	-0.1706 + 0.3940i	-0.1907 + 0.2502i
0.0233 + 0.4017i	-0.0766 + 0.4099i	-0.1653 + 0.3629i	-0.2185 + 0.2758i	-0.2267 + 0.1752i	-0.1970 + 0.0869i	-0.1470 + 0.0256i
GaborArray{3,4} U2V3						
0.0233 - 0.4017i	-0.0766 - 0.4099i	-0.1653 - 0.3629i	-0.2185 - 0.2758i	-0.2267 - 0.1752i	-0.1970 - 0.0869i	-0.1470 - 0.0256i
0.4392 - 0.4223i	0.3557 - 0.5645i	0.2118 - 0.6401i	0.0483 - 0.6268i	-0.0893 - 0.5334i	-0.1706 - 0.3940i	-0.1907 - 0.2502i
0.7314 - 0.0138i	0.8177 - 0.2189i	0.7913 - 0.4367i	0.6534 - 0.6050i	0.4444 - 0.6766i	0.2255 - 0.6405i	0.0502 - 0.5232i
0.5198 + 0.4634i	0.7531 + 0.3973i	0.9324 + 0.2309i	1.0000 + 0.0000i	0.9324 - 0.2309i	0.7531 - 0.3973i	0.5198 - 0.4634i
0.0502 + 0.5232i	0.2255 + 0.6405i	0.4444 + 0.6766i	0.6534 + 0.6050i	0.7913 + 0.4367i	0.8177 + 0.2189i	0.7314 + 0.0138i
-0.1907 + 0.2502i	-0.1706 + 0.3940i	-0.0893 + 0.5334i	0.0483 + 0.6268i	0.2118 + 0.6401i	0.3557 + 0.5645i	0.4392 + 0.4223i
-0.1470 + 0.0256i	-0.1970 + 0.0869i	-0.2267 + 0.1752i	-0.2185 + 0.2758i	-0.1653 + 0.3629i	-0.0766 + 0.4099i	0.0233 + 0.4017i
GaborArray{3,5} U2V4						
0.4741 + 0.2723i	0.6605 - 0.0757i	0.4917 - 0.4577i	0.1042 - 0.5543i	-0.1710 - 0.3543i	-0.2017 - 0.1065i	-0.1086 + 0.0164i

0.3190 + 0.4786i	0.7189 + 0.2604i	0.8099 - 0.2398i	0.4676 - 0.6183i	0.0072 - 0.5912i	-0.2187 - 0.3042i	-0.1878 - 0.0606i
0.0671 + 0.5285i	0.5344 + 0.5604i	0.9210 + 0.1617i	0.8401 - 0.4180i	0.3569 - 0.6962i	-0.0872 - 0.5350i	-0.2232 - 0.2181i
-0.1430 + 0.4103i	0.2040 + 0.6596i	0.7336 + 0.5410i	1.0000 + 0.0000i	0.7336 - 0.5410i	0.2040 - 0.6596i	-0.1430 - 0.4103i
-0.2232 + 0.2181i	-0.0872 + 0.5350i	0.3569 + 0.6962i	0.8401 + 0.4180i	0.9210 - 0.1617i	0.5344 - 0.5604i	0.0671 - 0.5285i
-0.1878 + 0.0606i	-0.2187 + 0.3042i	0.0072 + 0.5912i	0.4676 + 0.6183i	0.8099 + 0.2398i	0.7189 - 0.2604i	0.3190 - 0.4786i
-0.1086 - 0.0164i	-0.2017 + 0.1065i	-0.1710 + 0.3543i	0.1042 + 0.5543i	0.4917 + 0.4577i	0.6605 + 0.0757i	0.4741 - 0.2723i