

**IMPLEMENTASI *LAW'S TEXTURE ENERGY MEASURES* UNTUK
CLUSTERING TINGKAT KERUSAKAN BANGUNAN BERBASIS
PRINCIPAL COMPONENT ANALYSIS (PCA)**

SKRIPSI

Oleh :
NURUL AZIZA KUSUMA DEWI
NIM. 210605110164



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

**IMPLEMENTASI *LAW'S TEXTURE ENERGY MEASURES* UNTUK
CLUSTERING TINGKAT KERUSAKAN BANGUNAN BERBASIS
*PRINCIPAL COMPONENT ANALYSIS (PCA)***

SKRIPSI

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

Oleh :
NURUL AZIZA KUSUMA DEWI
NIM. 210605110164

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

HALAMAN PERSETUJUAN

IMPLEMENTASI *LAW'S TEXTURE ENERGY MEASURES* UNTUK CLUSTERING TINGKAT KERUSAKAN BANGUNAN BERBASIS PRINCIPAL COMPONENT ANALYSIS (PCA)

SKRIPSI

Oleh :

NURUL AZIZA KUSUMA DEWI

NIM. 210605110164

Telah Diperiksa dan Disetujui untuk Diuji:

Tanggal: 22 Juni 2026

Pembimbing I,



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

Pembimbing II,




Dr. Ririen Kusumawati, S.Si., M.Kom.
NIP. 19720309 200501 2 002

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

IMPLEMENTASI *LAW'S TEXTURE ENERGY MEASURES* UNTUK *CLUSTERING* TINGKAT KERUSAKAN BANGUNAN BERBASIS *PRINCIPAL COMPONENT ANALYSIS* (PCA)

SKRIPSI

Oleh :

NURUL AZIZA KUSUMA DEWI
NIM. 210605110164

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 29 Juni 2026

Susunan Dewan Penguji

Ketua Penguji : Dr. Totok Chamidy, M.Kom
NIP. 19691222 200604 1 001


Anggota Penguji I : Ashri Shabrina Afrah, M.T
NIP. 19900430 202012 2 003

Anggota Penguji II : Dr. Agung Teguh Wibowo Almais, M.T
NIP. 19860301 202321 1 016

Anggota Penguji III : Dr. Ririen Kusumawati, S.Si., M.Kom.
NIP. 19720309 200501 2 002

()
()
()
()

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 : Nurul Aziza Kusuma Dewi
NIM : 210605110164
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Implementasi *Law's Texture Energy Measures*
untuk *Clustering* Tingkat Kerusakan Bangunan
Berdasarkan *Principal Component Analysis* (PCA)

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, 29 Juni 2026
Yang membuat pernyataan,



Nurul Aziza Kusuma Dewi
NIM. 210605110164

MOTTO

“If you hate your life, maybe your life will hate you too. But if you love your life, your life will love you back too.”

(Kim Namjoon - BTS)

“Maybe I made a mistake yesterday, but yesterday's me is still me. I am who I am today, with all my faults. Tomorrow I might be a tiny bit wiser, and that's me, too.

These faults and mistakes are what I am, making up the brightest starts in the constellation of my life. I have come to love myself for who I was, who I am, and who I hope to become.”

(Kim Namjoon - BTS)

HALAMAN PERSEMBAHAN

Segala puji dan syukur penulis panjatkan ke hadirat Allah SWT atas segala rahmat, nikmat, serta karunia-Nya yang tiada henti diberikan. Berkat izin, pertolongan, dan kemudahan dari-Nya, penulis dapat menyelesaikan skripsi ini sebagai salah satu syarat untuk memperoleh gelar sarjana. Dengan penuh rasa syukur dan ketulusan hati, karya sederhana ini penulis persembahkan kepada:

Kepada Papa tercinta, Suhartono, Ibu tercinta, Sundusiyah, dan Kakak tercinta Siti Nur Insyiah, yang senantiasa memberikan kasih sayang, doa, dukungan, serta pengorbanan yang tidak ternilai harganya. Terima kasih atas setiap nasihat, kesabaran, dan kepercayaan yang selalu diberikan kepada penulis.

Keluarga besar penulis, yang selalu memberikan doa, perhatian, motivasi, dan semangat selama proses penyusunan skripsi ini. Kehadiran dan dukungan kalian menjadi sumber kekuatan bagi penulis untuk terus berjuang dan menyelesaikan setiap tahap perjalanan akademik ini. Dan untuk diri saya sendiri, terima kasih telah berjuang dan bertahan hingga sampai pada titik ini. Semoga setiap usaha yang telah dilakukan membawa manfaat dan keberkahan di masa yang akan datang.

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 “Implementasi *Law's Texture Energy Measures* untuk *Clustering* Tingkat Kerusakan Bangunan Berbasis *Principal Component Analysis* (PCA)” 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 memperoleh banyak bimbingan, bantuan, dukungan, serta doa dari berbagai pihak. Oleh karena itu, dengan segala kerendahan hati, penulis menyampaikan ucapan terima kasih yang sebesar-besarnya 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 telah memberikan bimbingan, arahan, masukan, serta motivasi kepada penulis dengan penuh kesabaran selama proses penyusunan skripsi ini.

5. Dr. Ririen Kusumawati, S.Si., M.Kom., selaku Dosen Pembimbing II yang telah memberikan bimbingan, masukan, arahan, serta saran yang berharga kepada penulis dalam proses penyusunan dan penyempurnaan skripsi ini.
6. Dr. Totok Chamidy, M.Kom., selaku Dosen Penguji I, dan Ashri Shabrina Afrah, M.T., selaku Dosen Penguji II, atas saran, kritik, dan masukan yang berharga dalam penyempurnaan penelitian serta penyusunan skripsi ini.
7. Seluruh Dosen dan Staf Fakultas Sains dan Teknologi, khususnya Program Studi Teknik Informatika, yang telah menjadi bagian dari perjalanan akademik penulis melalui ilmu, pengalaman, serta berbagai bantuan yang diberikan selama masa perkuliahan.
8. Teruntuk orang-orang yang paling ku cinta dan ku sayangi, Nenek Marwiyah, Cik Hosnia, Cik Aisyah, dan Cik Hamede. Terima kasih telah merawat, membimbing, dan menyayangiku sejak kecil sampai dewasa. Terima kasih atas segala pengorbanan, doa, perhatian, serta kasih sayang yang telah kalian berikan. Kalian selalu menjadi bagian terpenting dalam hidupku, sumber kekuatan, dan penyemangat dalam setiap langkah yang kujalani.
9. Teruntuk sahabat-sahabat terbaikku, Annisa Ayu Permadani, Salsabila Ramadanti Nuraini, Vinka Rosalia Fatimah Devi, Ferina Putri Soedjono, Iqlima Rahmafitri Karindah, dan Jinan Naurah. Terima kasih atas doa, dukungan, bantuan, serta kebersamaan yang telah kalian berikan selama masa perkuliahan hingga penyusunan skripsi ini. Terima kasih telah menjadi tempat berbagi cerita, tawa, dan semangat di setiap proses

perjuangan. Semoga persahabatan ini selalu terjaga dan menjadi kenangan indah yang tidak terlupakan.

10. Teruntuk Kim Namjoon, Kim Seokjin, Min Yoongi, Jung Hoseok, Park Jimin, Kim Taehyung, dan Jeon Jungkook. Terima kasih atas karya, semangat, dan pesan-pesan positif yang telah memberikan warna serta motivasi dalam perjalanan hidup penulis. Kehadiran kalian melalui musik dan berbagai cerita yang dibagikan menjadi salah satu sumber kekuatan hingga skripsi ini dapat terselesaikan.
11. *I think i'm still in the middle of just meeting who i'am, i'm like maybe too sensitive, than the others or maybe the average, or i think too much somethimes i can't sleep but do i wanna die? No, i try to love the life, the skies, taking walks, good friends, i'm still fighting the demons but maybe it could be forever, and forever is to long but i just wanna say one thing simply in short, i think life is fun.*
12. Teman-teman Teknik Informatika angkatan 2021 (ASTER), terima kasih atas kebersamaan, semangat, dan dukungan selama menjalani perkuliahan. Semoga seluruh anggota ASTER senantiasa diberikan kemudahan, kesuksesan, dan keberkahan dalam setiap langkah ke depan. Bagi yang masih berjuang menyelesaikan tugas akhir, semoga diberikan kelancaran dan dapat segera menyusul meraih gelar yang diimpikan.
13. Teruntuk diriku sendiri, terima kasih telah bertahan, berjuang, dan tidak menyerah hingga sampai di titik ini. Terima kasih telah melewati berbagai tantangan, rasa lelah, dan keraguan selama proses perkuliahan hingga

penyusunan skripsi. Semoga segala usaha yang telah dilakukan menjadi awal dari langkah-langkah baik di masa depan.

Penulis menyadari bahwa skripsi ini masih jauh dari kata sempurna dan tidak terlepas dari berbagai kekurangan, baik dalam penyajian maupun isi. Oleh karena itu, penulis mengharapkan kritik dan saran yang membangun sebagai bahan evaluasi dan perbaikan di masa mendatang. Penulis berharap skripsi ini dapat memberikan manfaat bagi pembaca serta menjadi kontribusi dalam pengembangan ilmu pengetahuan, khususnya pada bidang pengolahan citra digital dan mitigasi bencana.

Wassalamualaikum Warahmatullahi Wabarakatuh.

Malang, 29 Juni 2026

A handwritten signature in black ink, consisting of stylized, cursive letters that appear to be 'D. M. A.' followed by a long horizontal stroke.

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
مستخلص البحث.....	xviii
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	5
1.3 Batasan Masalah	5
1.4 Tujuan Penelitian	5
1.5 Manfaat Penelitian	6
BAB II STUDI PUSTAKA.....	7
2.1 Penelitian Terkait.....	7
2.2 Deteksi Kerusakan Bangunan	13
2.3 <i>Preprocessing</i>	15
2.4 <i>Law's Texture Energy Measure (LTEM)</i>	16
2.4.1 Proses Ekstraksi Fitur Menggunakan LTEM	17
2.4.2 Rumus Dasar LTEM	18
2.4.3 Masker <i>Law's</i>	19
2.5 <i>Principal Component Analysis (PCA)</i>	19
2.6 <i>Clustering Data</i>	21
BAB III	23
METODE PENELITIAN.....	23
<i>Data Preparation</i> , piksel, dan <i>scenario</i> pengujian.	23
3.1 Desain Sistem	23
3.2 Data Preparation	27
3.2.1 Sumber Data.....	27
3.2.2 Hasil Ekstraksi Fitur.....	28
3.3 Piksel.....	29
3.4 Skenario Pengujian	29
3.4.1 Variasi Jumlah Kluster	30
3.4.2 Pengaruh Reduksi Dimensi dengan PCA.....	30
3.4.3 Evaluasi <i>Clustering</i>	30
BAB IV HASIL DAN PEMBAHASAN	33
4.1 Langkah Pengujian	33
4.2 Hasil Pengujian.....	33
4.2.1 Proses Algoritma LTEM	34
4.2.2 Implementasi <i>Principal Component Analysis (PCA)</i>	39
4.2.3 Evaluasi Sistem	52

4.3 Pembahasan	54
4.4 Integrasi Islam.....	56
BAB V KESIMPULAN DAN SARAN	58
5.1 Kesimpulan	58
5.2 Saran	59
DAFTAR PUSTAKA	

DAFTAR GAMBAR

Gambar 3.1 Desain Sistem.....	23
Gambar 4.1 Gambar citra yang digunakan	34
Gambar 4.2 Hasil pemrosesan citra	35
Gambar 4.3 Contoh perhitungan <i>masker Law's</i>	37
Gambar 4.4 Hasil ekstraksi fitur	37
Gambar 4.5 Visualisasi <i>cluster</i> 2D	44
Gambar 4.6 Visualisasi <i>cluster</i> 3D	45
Gambar 4.7 <i>Cluster 3</i>	46
Gambar 4.8 <i>Cluster 3D</i>	47
Gambar 4.9 <i>Cluster 2</i>	49
Gambar 4.10 <i>Cluster 4</i>	50
Gambar 4.11 <i>Cluster 5</i>	51

DAFTAR TABEL

Tabel 2.1 Penelitian Terkait	7
Tabel 3.1 Kriteria <i>Silhouette Score</i>	31
Tabel 4.1 Hasil masker <i>Law's</i>	36
Tabel 4.2 Nilai konvolusi L5L5	38
Tabel 4.3 Nilai Energi Ekstraksi Fitur	39
Tabel 4.4 Hasil normalisasi data	40
Tabel 4.5 Nilai Ratio dan <i>Eigenvalue</i>	41
Tabel 4.6 Hasil nilai komponen utama PCA.....	43
Tabel 4.7 Rentang nilai 3 <i>cluster</i>	47
Tabel 4.8 Hasil modifikasi parameter	48
Tabel 4.9 Rentang nilai <i>cluster 2</i>	50
Tabel 4.10 Rentang nilai <i>cluster 5</i>	51
Tabel 4.11 Rentang nilai 5 <i>cluster</i>	52
Tabel 4.12 Hasil <i>Silhouette Score</i>	53

ABSTRAK

Dewi, Nurul Aziza Kusuma. 2026. **Implementasi *Law's Texture Energy Measures* untuk *Clustering* Tingkat Kerusakan Bangunan Berbasis *Principal Component Analysis* (PCA).** 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. Ririen Kusumawati, S.Si., M.Kom.

Kata Kunci: *Law's Texture Energy Measures* (LTEM), *Principal Component Analysis* (PCA), *clustering*, kerusakan bangunan, pengolahan citra digital.

Indonesia merupakan negara yang rentan terhadap berbagai bencana alam yang dapat mengakibatkan kerusakan pada bangunan. Identifikasi tingkat kerusakan bangunan pascabencana perlu dilakukan secara cepat dan akurat untuk mendukung proses mitigasi serta penanganan bencana. Penelitian ini bertujuan untuk mengelompokkan tingkat kerusakan bangunan menggunakan metode *Law's Texture Energy Measures* (LTEM) untuk ekstraksi fitur tekstur dan *Principal Component Analysis* (PCA) untuk reduksi dimensi data. Data yang digunakan berupa citra bangunan rusak yang diperoleh dari dokumentasi BPBD Kota Malang dan Kaggle. Tahapan penelitian meliputi *preprocessing* citra, ekstraksi fitur menggunakan LTEM, normalisasi data, reduksi dimensi dengan PCA, serta proses *clustering* berdasarkan karakteristik tekstur citra. Evaluasi hasil *clustering* dilakukan menggunakan *Silhouette Score* dengan variasi jumlah *cluster* sebanyak 2, 3, 4, dan 5 *cluster*. Hasil penelitian menunjukkan bahwa nilai *Silhouette Score* yang diperoleh untuk masing-masing jumlah *cluster* adalah 0,588535 pada 2 *cluster*, 0,4723 pada 3 *cluster*, 0,5150 pada 4 *cluster*, dan 0,5144 pada 5 *cluster*. Berdasarkan hasil tersebut, 2 *cluster* merupakan jumlah *cluster* yang paling optimal karena menghasilkan nilai *Silhouette Score* tertinggi, sehingga menunjukkan kualitas pengelompokan yang lebih baik dibandingkan jumlah *cluster* lainnya. Dengan demikian, kombinasi metode LTEM dan PCA mampu mengelompokkan citra bangunan berdasarkan karakteristik teksturnya serta memberikan hasil *clustering* yang cukup baik dalam proses identifikasi tingkat kerusakan bangunan.

ABSTRACT

Dewi, Nurul Aziza Kusuma. 2026. *Implementation of Law's Texture Energy Measures for Building Damage Level Clustering Based on Principal Component Analysis (PCA)*. Undergraduate Thesis. Informatics Engineering Study Program, Faculty of Science and Technology, Maulana Malik Ibrahim State Islamic University of Malang. Supervisors: (I) Dr. Agung Teguh Wibowo Almais, M.T. (II) Dr. Ririen Kusumawati, S.Si., M.Kom.

Keywords: *Law's Texture Energy Measures (LTEM), Principal Component Analysis (PCA), clustering, building damage, digital image processing.*

Indonesia is a country that is highly vulnerable to various natural disasters that can cause damage to buildings. Identifying the level of building damage after a disaster needs to be carried out quickly and accurately to support mitigation and disaster response efforts. This study aims to classify building damage levels using the Law's Texture Energy Measures (LTEM) method for texture feature extraction and Principal Component Analysis (PCA) for dimensionality reduction. The data used in this study consist of images of damaged buildings obtained from the documentation of BPBD Kota Malang and Kaggle. The research stages include image preprocessing, feature extraction using LTEM, data normalization, dimensionality reduction using PCA, and clustering based on image texture characteristics. The clustering results were evaluated using the Silhouette Score with variations of 2, 3, 4, and 5 clusters. The results showed that the Silhouette Score values obtained for each cluster configuration were 0.588535 for 2 clusters, 0.4723 for 3 clusters, 0.5150 for 4 clusters, and 0.5144 for 5 clusters. Based on these results, 2 clusters were identified as the most optimal configuration because they achieved the highest Silhouette Score, indicating better clustering quality compared to the other cluster configurations. Therefore, the combination of LTEM and PCA was able to group building images based on their texture characteristics and produced reasonably good clustering results for the identification of building damage levels.

مستخلص البحث

ديوي، نورول عزيزة كوسوما. 2026. تطبيق مقياس طاقة النسيج لـ *Law* في تجميع مستويات أضرار المباني بالاعتماد على تحليل المكونات الرئيسية. (PCA) رسالة بكالوريوس، برنامج دراسة هندسة المعلوماتية، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية بمالانغ. المشرفان: (الأول) د. أغونغ تيغوه ويوويو أليس، ماجستير في الهندسة؛ (الثانية) د. ريرين كوسوماواتي، بكالوريوس في العلوم، ماجستير في علوم الحاسوب.

الكلمات المفتاحية: مقياس طاقة النسيج لـ *Law's (LTEM)* ، تحليل المكونات الرئيسية (PCA) ، التجميع، أضرار المباني، معالجة الصور الرقمية.

تُعدّ إندونيسيا من الدول المعرضة لمختلف الكوارث الطبيعية التي قد تؤدي إلى أضرار في المباني. لذلك، فإن تحديد مستوى أضرار المباني بعد الكوارث يجب أن يتم بسرعة ودقة لدعم جهود التخفيف من آثار الكوارث وإدارة الاستجابة لها. يهدف هذا البحث إلى تصنيف مستويات أضرار المباني باستخدام طريقة *Law's Texture Energy Measures (LTEM)* لاستخراج خصائص النسيج، وطريقة *Principal Component Analysis (PCA)* لتقليل أبعاد البيانات. وقد استُخدمت في هذه الدراسة صور لمبانٍ متضررة تم الحصول عليها من وثائق هيئة إدارة الكوارث الإقليمية بمدينة مالانغ (BPBD Kota Malang) ومن منصة Kaggle. شملت مراحل البحث المعالجة المسبقة للصور، واستخراج الخصائص باستخدام LTEM، وتطبيق البيانات، وتقليل الأبعاد باستخدام PCA، ثم تنفيذ عملية التجميع (*Clustering*) اعتماداً على خصائص نسيج الصور. وتم تقييم نتائج التجميع باستخدام معامل السيلويت (*Silhouette Score*) مع اختبار أربعة أعداد مختلفة من المجموعات، وهي 2 و3 و4 و5 مجموعات. وأظهرت النتائج أن قيم معامل السيلويت بلغت 0.588535 عند استخدام مجموعتين، و0.4723 عند استخدام ثلاث مجموعات، و0.5150 عند استخدام أربع مجموعات، و0.5144 عند استخدام خمس مجموعات. واستناداً إلى هذه النتائج، تبين أن المجموعتين (2 *Clusters*) تمثلان العدد الأمثل للمجموعات، وذلك لتحقيقهما أعلى قيمة لمعامل السيلويت، مما يدل على جودة أفضل في عملية التجميع مقارنةً ببقية السيناريوهات. وعليه، فإن الجمع بين طريقي LTEM وPCA أثبتت فعاليته في تجميع صور المباني وفقاً لخصائصها النسيجية، كما قدّم نتائج جيدة في عملية تحديد مستويات أضرار المباني.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Indonesia adalah negara kepulauan yang terletak di dalam Cincin Api Pasifik, sehingga menjadikannya sangat rentan terhadap berbagai bencana alam seperti gempa bumi, aktivitas vulkanik, tsunami, dan tanah longsor (Rizki & Marina, 2019). Peristiwa alam ini dapat menyebabkan kategori struktural yang parah pada bangunan dan infrastruktur, yang berdampak pada stabilitas serta fungsionalitasnya. Bangunan memiliki peran penting dalam kehidupan manusia, berfungsi sebagai tempat tinggal, pusat bisnis, serta fasilitas industri. Namun, seiring berjalannya waktu, struktur bangunan pasti mengalami degradasi akibat berbagai faktor, seperti penuaan material, kondisi lingkungan, kesalahan konstruksi, serta bencana alam (Wibowo & Yulianto, 2023).

Faktor-faktor ini secara signifikan berkontribusi terhadap penurunan kualitas bangunan, yang jika tidak terdeteksi, dapat menimbulkan risiko besar, termasuk kegagalan struktural yang membahayakan keselamatan penghuni. Oleh karena itu, deteksi dini terhadap kategori bangunan menjadi sangat penting untuk mencegah keruntuhan yang berpotensi membahayakan dan memastikan keamanan serta ketahanan infrastruktur (Luo dkk., 2020). Untuk mengatasi masalah ini, berbagai teknik telah dikembangkan untuk menemukan dan menganalisis tingkat kategori yang terjadi pada bangunan. Sebelumnya, inspeksi manual merupakan pendekatan utama, di mana para ahli secara visual memeriksa struktur bangunan untuk mengidentifikasi tanda-tanda kerusakan.

Namun, metode ini memiliki keterbatasan, seperti bias subjektif, proses yang memakan waktu lama, serta cakupan area penilaian yang terbatas (Tjen, 2022). Kemajuan teknologi dalam beberapa tahun terakhir, terutama dengan perkembangan kecerdasan buatan (AI), telah memungkinkan pengembangan sistem otomatis berbasis pemrosesan citra digital, yang menawarkan solusi lebih efisien dan akurat dalam mendeteksi kerusakan bangunan. Salah satu metode yang menjanjikan dalam bidang ini adalah analisis tekstur menggunakan *Law's Texture Energy Measures* (LTEM) (Ariyanto, 2020). *Law's Texture Energy Measures* (LTEM) merupakan teknik dalam pemrosesan citra digital yang dirancang khusus untuk mengkarakterisasi tekstur melalui proses penyaringan berbasis energi.

Pendekatan ini berfungsi dengan mengekstraksi berbagai karakteristik tekstur dari gambar, sehingga memungkinkan untuk mendeteksi perbedaan halus antara struktur yang utuh dan yang mengalami kerusakan (Fadhila dkk., 2023). LTEM mampu mengidentifikasi pola ketidakteraturan melalui analisis perubahan tekstur, di mana pola tersebut menunjukkan adanya kerusakan struktural. LTEM memberikan analisis yang lebih terukur dan objektif dibandingkan dengan inspeksi visual konvensional, sehingga meningkatkan akurasi klasifikasi kerusakan dan mengurangi kesalahan manusia (Tjen, 2022). Selain itu, pendekatan ini memungkinkan dilakukannya banyak evaluasi dalam skala yang lebih luas, menjadikannya cocok untuk pemantauan jaringan infrastruktur yang luas.

Penelitian ini bertujuan untuk menggunakan *Law's Texture Energy Measures* (LTEM) dalam mendeteksi dan mengklasifikasikan kerusakan bangunan melalui analisis tekstur pada citra digital. Metode ini dapat dimanfaatkan secara

cermat untuk mengembangkan sistem deteksi otomatis yang lebih akurat. Sistem ini akan mendukung pemeliharaan berskala, secara signifikan mengurangi biaya inspeksi, serta secara menyeluruh meningkatkan langkah-langkah keselamatan. Temuan dari penelitian ini diharapkan dapat berkontribusi pada peningkatan sistem penilaian kerusakan berbasis digital, sekaligus menawarkan solusi yang lebih akurat, efisien, dan skalabel dalam pemantauan infrastruktur. Dalam menghadapi berbagai tantangan tersebut, penting bagi kita untuk merenungkan apa yang diingatkan oleh Al-Qur'an terkait tanggung jawab sosial dalam membantu sesama saat bencana. Allah berfirman dalam Q.S. An-Naml (88):

وَتَرَى الْجِبَالَ تَحْسَبُهَا جَامِدَةً وَهِيَ تَمُرُّ مَرَّ السَّحَابِ ۚ صُنْعَ اللَّهِ الَّذِي أَتَقَنَ كُلَّ شَيْءٍ ۚ إِنَّهُ خَبِيرٌ بِمَا تَفْعَلُونَ

"Dan kamu lihat gunung-gunung itu, kamu sangka dia tetap di tempatnya, padahal ia berjalan seperti jalannya awan. (Itulah) perbuatan Allah yang membuat dengan kokoh tiap-tiap sesuatu; sesungguhnya Allah Maha Mengetahui apa yang kamu kerjakan. (QS An-Naml:88)".

Ayat ini menekankan bahwa segala sesuatu yang diciptakan dengan sangat indah oleh Allah memiliki ketetapan yang kokoh dan pasti, namun tetap mengalami perubahan seiring waktu. Tafsir dari ayat ini dapat dikaitkan dengan pentingnya menjaga ketahanan struktural bangunan. Selain itu, tafsir ini juga dapat mencakup perlindungan terhadap berbagai faktor alami yang dapat menyebabkan degradasi dan kerusakan. Penggunaan *Law's Texture Energy Measures* (LTEM) untuk mengklasifikasikan tingkat kerusakan bangunan berdasarkan citra digital dapat memberikan hasil yang lebih terstruktur dalam membantu perencanaan infrastruktur yang lebih baik.

Penggunaan *Law's Texture Energy Measures* (LTEM) dalam analisis citra digital menghasilkan identifikasi dan klasifikasi kerusakan bangunan yang lebih

akurat. Pendekatan ini dapat dikombinasikan dengan *Principal Component Analysis* (PCA) *Clustering* untuk meningkatkan efisiensi dalam pemrosesan informasi tekstur dan pengelompokan tingkat kerusakan secara lebih sistematis (Abedi dkk., 2023). PCA berfungsi untuk mengurangi jumlah dimensi dalam atribut tekstur yang diekstraksi oleh LTEM, sehingga mempercepat proses klasterisasi tanpa menghilangkan informasi penting. Dengan menerapkan *unsupervised learning*, *PCA Clustering* dapat mengelompokkan data citra ke dalam berbagai kategori berdasarkan pola tekstur yang dihasilkan oleh LTEM, memungkinkan identifikasi kerusakan bangunan secara otomatis dalam skala besar.

Penggunaan *Law's Texture Energy Measures* (LTEM) dalam analisis citra digital dapat menghasilkan atau mengklasifikasikan adanya kerusakan bangunan yang lebih akurat. Untuk pendekatan ini dapat dikombinasikan dengan *Principal Component Analysis* (PCA) *clustering* untuk meningkatkan efisiensi dalam pemrosesan informasi tekstur dan pengelompokan tingkat kerusakan secara lebih sistematis (Abedi dkk., 2023). PCA berfungsi untuk mengurangi adanya jumlah dimensi dalam atribut tekstur yang diekstraksi oleh LTEM, sehingga mempercepat proses klasterisasi tanpa menghilangkan informasi penting. Dengan menerapkan *unsupervised learning*, *PCA clustering* dapat mengelompokkan data citra ke dalam berbagai kategori berdasarkan pola tekstur yang akan dihasilkan LTEM, memungkinkan adanya identifikasi kerusakan bangunan secara otomatis dalam skala besar.

Kontribusi utama dari penelitian ini adalah merancang sistem yang otomatis berbasis kombinasi LTEM dan PCA yang mampu meningkatkan kecepatan dan

objektivitas dalam proses identifikasi pada tingkat kerusakan bangunan pasca bencana. Sistem ini tidak hanya akan membantu percepatan adanya penilaian pada kerusakan oleh instansi yang terkait. namun juga membuka peluang penggunaan algoritma dalam *scenario real-time assement* dan *decision-support system* berbasis citra digital. Penelitian ini memperkuat arah transformasi digital dalam pemantauan infrastruktur serta memberikan adanya landasan bagi pengembangan sistem mitigasi risiko bangunan yang berbasis kecerdasan buatan (Jannah & Amalia, 2024; Luo dkk., 2020).

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dibahas pada sub-bab sebelumnya, dapat dinyatakan permasalahan dalam penelitian ini sebagai berikut:

1. Bagaimana penerapan metode *Law's Texture Energy Measures* (LTEM) dalam mendeteksi dan mengklasifikasikan tingkat kerusakan bangunan berdasarkan analisis tekstur citra digital?
2. Bagaimana mengevaluasi hasil *clustering* tingkat kerusakan bangunan pasca bencana alam menggunakan metode LTEM dan PCA?

1.3 Batasan Masalah

1. Menggunakan data gambar kerusakan bangunan pasca bencana alam
2. Menggunakan data dari BPBD Kota Malang dan Kaggle.

1.4 Tujuan Penelitian

Berdasarkan rumusan masalah diatas, tujuan dari penelitian ini adalah sebagai berikut:

1. Menganalisis penerapan *Law's Texture Energy Measures* (LTEM) dalam mendeteksi dan mengklasifikasikan tingkat kerusakan bangunan pasca bencana alam berdasarkan citra digital.
2. Mengevaluasi hasil *clustering* tingkat kerusakan bangunan menggunakan PCA, guna mengukur efektivitas metode dalam membedakan kategori kerusakan berdasarkan data dari BPBD Kota Malang.

1.5 Manfaat Penelitian

1. Mempermudah dan mempercepat proses identifikasi tingkat kerusakan bangunan pasca bencana alam melalui analisis citra digital berbasis LTEM dan PCA.
2. Memberikan data yang lebih akurat dan objektif untuk membantu pemerintah dan pihak terkait perencanaan rekonstruksi dan mitigasi bencana.
3. Memberikan pengembangan metode yang berbasis citra digital dalam pemantauan dan pemeliharaan bangunan secara lebih sistematis dan berbasis data.
4. Pada pembahasan bab ini akan dibagi menjadi tiga subab yaitu desain sistem, data preparation, dan scenario pengujian.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terkait

Penelitian yang telah dilakukan sebelumnya memberikan dasar yang sangat kuat dalam memahami berbagai aspek yang berhubungan dengan analisis data, dalam pengambilan Keputusan, serta metode yang diterapkan dalam pengolahan informasi. Berbagai studi yang telah memberikan adanya wawasan dan pendekatan metodologi yang dapat digunakan untuk mengidentifikasi, mengelola, serta mengevaluasi data secara efektif guna meningkatkan akurasi dalam pengambilan keputusan. Pada tabel 2.1, yang ditampilkan hasil tinjauan dari penelitian-penelitian terdahulu yang memiliki relevansi dengan penelitian ini, mencakup adanya pendekatan yang digunakan, temuan utama, serta kontribusi penting dalam bidang ini. Dengan adanya tinjauan ini, dapat diperoleh gambaran yang lebih luas mengenai perkembangan riset serta penerapan metode analisis data dalam berbagai konteks.

Tabel 2.1 Penelitian Terkait

Referensi	Topik	Metode	Subjek	Hasil
(Almais dkk., 2023)	Pelabelan adanya tingkat kerusakan sektor pasca bencana	PCA	Data kerusakan bangunan pasca bencana sebanyak 216 data	PCA menghasilkan 2 komponen utama dengan variansi kumulatif 94,52% dan berhasil mengelompokkan data ke dalam 3 tingkat kerusakan (ringan, sedang, dan berat), sehingga dapat digunakan untuk pelabelan otomatis data tanpa label.
(Ganasala & Prasad, 2020)	Medical Image Fusion Based on Laws of Texture	LTEM dan SWT	Citra CT dan MRI pasien	LTEM berhasil mengekstraksi berbagai karakteristik tekstur seperti

Referensi	Topik	Metode	Subjek	Hasil
	Energy Measures in SWT Domain		gangguan neurologis	edge, spot, ripple, dan wave untuk proses fusi citra. Metode yang diusulkan menghasilkan kualitas citra fusi yang lebih baik dibandingkan metode pembanding berdasarkan metrik VIFF, QAB/F, Q, dan QW.
(Purnamasari dkk., 2025)	<i>Clustering of Post-Disaster Building Damage Using DWT and PCA</i>	DWT dan PCA	Citra bangunan pascabencana	PCA berhasil mereduksi dimensi data fitur dan mengelompokkan tingkat kerusakan bangunan menjadi kategori rusak ringan, sedang, dan berat. Hasil validasi menunjukkan tingkat kesesuaian sebesar 100% terhadap penilaian manual tim survei BPBD Kota Malang.
(Almais dkk., 2025)	Penentuan Tingkat Kerusakan Bangunan Pascabencana	Image Augmentation, Watershed Segmentation, dan PCA	Citra bangunan pascabencana	Metode yang diusulkan berhasil mengelompokkan tingkat kerusakan bangunan berdasarkan hasil <i>clustering</i> PCA. Transformasi translasi, rotasi, dan refleksi diklasifikasikan sebagai rusak ringan , sedangkan transformasi dilasi diklasifikasikan sebagai rusak berat . Hasil validasi menunjukkan bahwa kombinasi dilasi, watershed segmentation, dan PCA mampu meningkatkan objektivitas dalam penilaian kerusakan bangunan pascabencana.
(Setiawan dkk., 2015)	Klasifikasi Mammogram Menggunakan LTEM dan ANN	LTEM dan Artificial Neural Network (ANN)	Citra mammogram	LTEM berhasil mengekstraksi fitur tekstur citra mammogram dengan performa lebih baik dibandingkan GLCM. Metode LTEM menghasilkan akurasi 93,90% untuk klasifikasi normal-abnormal dan 83,30% untuk klasifikasi benign-malignant,

Referensi	Topik	Metode	Subjek	Hasil
				menunjukkan kemampuan ekstraksi tekstur yang tinggi dalam proses klasifikasi citra medis.
(Kamal dkk., 2017)	Klasifikasi cacat kayu menggunakan tekstur citra	Laws Texture Energy Measures (LTEM), Gray Level Co-occurrence Matrix (GLCM), dan Backpropagation Neural Network (BPNN)	Sebanyak 395 citra cacat kayu yang terdiri dari sound knot, dry knot, edge knot, leaf knot, dan horn knot. LTEM digunakan untuk ekstraksi fitur tekstur dan BPNN digunakan sebagai klasifikator.	Metode LTEM menghasilkan akurasi klasifikasi sebesar 90,5% dengan nilai MSE 0,0718, lebih tinggi dibandingkan metode GLCM yang memperoleh akurasi 84,3% dengan MSE 0,10728. Hasil penelitian menunjukkan bahwa LTEM lebih efektif dalam mengekstraksi fitur tekstur untuk klasifikasi cacat kayu.
(Kvyetnyy dkk., 2017)	Segmentasi tekstur citra menggunakan Laws' Energy Measures.	Laws' Energy Measures (LEM) untuk ekstraksi fitur tekstur dan segmentasi citra	Citra digital yang memiliki beberapa jenis tekstur berbeda untuk diuji proses segmentasi berdasarkan karakteristik tekstur.	Metode Laws' Energy Measures mampu membedakan area citra berdasarkan karakteristik teksturnya dan menghasilkan segmentasi yang efektif pada objek dengan pola tekstur yang berbeda.

Penelitian yang dilakukan oleh Almais dkk. (2023) membahas tentang pelabelan tingkat kerusakan sektor pascabencana yang menggunakan metode PCA. Untuk penelitian ini menggunakan 216 data kerusakan bangunann pascabencana yang belum memiliki label. PCA sering digunakan untuk mereduksi dimensi data sekaligus membentuk kelompok data yang berdasarkan karakteristik kerusakan yang dimilikinya. Dari hasil penelitian ini menunjukkan bahwa PCA menghasilkan dua komponen utama dengan variasi kumulatif sebesar 94,52% dan mampu mengelompokkan ke dalam tiga kategori tingkat kerusakan, yaitu ringan, sedang, dan berat.

Penelitian oleh Ganasala & Prasad (2020) mengusulkan Metodi fusi citra medis yang berbasis LTEM *pada Stationary Wavelet Transform* (SWT). Penelitian ini menggunakan citra CT dan MRI dari pasien yang mengalami gangguan neurologis. LTEM digunakan untuk mengekstraksi karakteristik tekstur seperti *edge*, *spot*, *ripple*, dan *wave*. Hasil penelitian ini menunjukkan bahwa metode diusulkan mampu menghasilkan kualitas lebih baik dibandingkan metode pembanding berdasarkan nilai metrik VIFF, QAB/F, Q dan QW.

Selanjutnya Purnamasari dkk. (2025) melakukan penelitian pengelompokan tingkat kerusakan bangunan pascabencana yang menggunakan kombinasi *Discrete Wavelet Transform* (DWT) dan PCA. DWT untuk mengekstraksi fitur cita bangunan, sedangkan PCA untuk mereduksi dimensi data dan melakukan pengelompokan tingkat kerusakan. Dari penelitian ini menunjukkan bahwa metode tersebut mampu mengelompokkan bangunan ke dalam kategori ringan, sedang, dan berat. Hasil validasi menunjukkan tingkat kesesuaian sebesar 100% terhadap penilaian manual yang dilakukan tim survei BPBD Kota Malang, sehingga metode ini diusulkan sangat akurat dalam mengidentifikasi tingkat kerusakan bangunan.

Penelitian yang dilakukan Almais dkk. (2025) berfokus untuk penentuan tingkat kerusakan bangunan pascabencana menggunakan kombinasi *Image Augmentation*, *Watershed Segmentation*, dan PCA. Penelitian ini memanfaatkan citra bangunan pascabencana yang kemudian melalui proses *augmentasi* dan *segmentasi* untuk meningkatkan kualitas data sebelum di proses pengelompokan menggunakan PCA. Hasil dari penelitian ini menunjukkan transformasi translasi,

rotasi, dan refleksi yang cenderung dikelompokkan sebagai kerusakan ringan, transformasi dilasi dikategorikan sebagai kerusakan berat. Validasi dilakukan menunjukkan kombinasi metode tersebut mampu meningkatkan objektivitas dalam penilaian tingkat kerusakan bangunan pascabencana.

Dalam bidang klasifikasi citra medis, Setiawan dkk. (2015) menerapkan metode LTEM dan *Artificial Neural Network* (ANN) untuk klasifikasi citra mammogram. LTEM digunakan sebagai metode ekstraksi fitur tekstur, sedangkan ANN digunakan sebagai klasifikator. Dari hasil penelitian menunjukkan LTEM mampu menghasilkan performa ekstraksi tekstur lebih baik dibandingkan metode *Gray Level Co-occurrence Matrix* (GLCM). Akurasi yang diperoleh mencapai 93,90% untuk klasifikasi normal dan abnormal serta 83,30% untuk klasifikasi *benign* dan *malignant*. Hasil tersebut menunjukkan bahwa LTEM mempunyai kemampuan yang baik dalam menangkap karakteristik tekstur pada citra medis.

Penelitian lain yang dilakukan oleh Kamal dkk. (2017) membahas klasifikasi cacat kayu menggunakan kombinasi *Laws Texture Energy Measures* (LTEM), *Gray Level Co-occurrence Matrix* (GLCM), dan *Backpropagation Neural Network* (BPNN). Untuk penelitian ini menggunakan 395 citra cacat kayu yang terdiri atas *sound knot*, *dry knot*, *edge knot*, *leaf knot*, dan *horn knot*. LTEM dan GLCM bisa digunakan untuk ekstraksi fitur tekstur, sedangkan BPNN digunakan sebagai metode klasifikasi. Dari hasil penelitian menunjukkan bahwa LTEM menghasilkan akurasi klasifikasi sebesar 90,5% dengan nilai MSE 0,0718, lebih tinggi dibandingkan GLCM yang mencapai akurasi 84,3% dengan nilai MSE

0,10728. Temuan ini menunjukkan bahwa LTEM lebih efektif dalam mengekstraksi fitur tekstur untuk proses klasifikasi.

Sementara itu, Kvyetnyy dkk. (2017) meneliti penggunaan *Laws' Energy Measures* (LEM) untuk segmentasi tekstur citra. Penelitian ini menggunakan citra digital yang memiliki berbagai jenis tekstur untuk menguji kemampuan metode dalam membedakan area berdasarkan karakteristik teksturnya. Hasil penelitian menunjukkan bahwa pada metode LEM mampu mengidentifikasi dan memisahkan area citra yang memiliki pola tekstur berbeda secara efektif. Oleh karena itu, metode ini dinilai memiliki potensi baik dalam aplikasi segmentasi citra berbasis tekstur.

Penelitian terdahulu ini menjadi rujukan dalam memahami bagaimana metode analisis data yang yang bisa diterapkan dalam pengolahan informasi terkait bencana, sistem pendukung keputusan, serta pemetaan risiko. Studi-studi tersebut diharapkan bisa membantu dalam pengembangan pendekatan yang lebih efektif dan inovatif guna mendukung analisis data yang lebih akurat. Dengan menelaah berbagai penelitian sebelumnya, penelitian ini juga berupaya untuk memberikan adanya kontribusi yang dapat memperkaya suatu metode yang telah ada dan membuka peluang untuk pengembangan penelitian selanjutnya.

Dengan menggunakan pendekatan sistematis dan teknis analisi data yang telah teruji, penelitian ini diharapkan dapat memberikan suatu kontribusi dalam pengolahan data serta peningkatan efektivitas sistem pendukung keputusan. Selain itu, hasil dari penelitian ini juga dapat menjadikan referensi bagi penelitian berikutnya, baik dalam bidang yang sama maupun bidang yang berkaitan, sehingga

memberikan suatu dampak nyata bagi pengolahan risiko dan mitigasi bencana secara lebih baik.

2.2 Deteksi Kerusakan Bangunan

Deteksi kerusakan bangunan merupakan proses identifikasi dan analisis terhadap suatu kondisi struktur bangunan guna menentukan adanya tingkat kerusakan yang terjadi. Teknologi ini sangat penting dalam mitigasi bencana, pemeliharaan infrastruktur, serta evaluasi keamanan bangunan pasca kejadian seperti kebakaran, gempa bumi, atau bencana lainnya. Dalam beberapa tahun terakhir, pendekatan yang berbasis citra digital dan kecerdasan buatan mulai banyak digunakan dalam sistem deteksi kerusakan. Dengan memanfaatkan citra bangunan dan teknik pengolahan citra digital, sistem dapat mengidentifikasi pola-pola kerusakan seperti adanya retakan, keruntuhan Sebagian, hingga deformasi struktural secara otomatis.

Hal ini, dapat mengurangi ketergantungan pada inspeksi visual manual yang cenderung memakan waktu yang bersifat subjektif. Salah satu metode yang paling banyak digunakan adalah teknik ekstraksi ciri dari tekstur permukaan bangunan yang bisa membedakan antara area rusak dan tidak rusak. Data tekstur yang diperoleh dari citra dapat dievaluasi dan dianalisis menggunakan metode klasifikasi atau *clustering* untuk bisa menentukan tingkat kategori. Metode pengolahan lanjutan seperti *Principal Component Analysis* (PCA) juga bisa digunakan untuk mereduksi dimensi data tekstur sebelum dilakukan proses *clustering* guna meningkatkan efisiensi dan akurasi sistem. Dalam studi oleh Raute (Jellouli dkk., 2021), deteksi adanya kerusakan pasca bencana yang menggunakan suatu

pendekatan yang berbasis citra satelit menunjukkan potensi besar dalam pemetaan kategori secara *real-time* dan luas.

Sementara itu, penelitian oleh Jannah & Amalia (2024), mengembangkan algoritma *Convolutional Neural Network* (CNN) untuk mengidentifikasi tingkat kerusakan struktur bangunan pasca gempa bumi menggunakan citra terrestrial. Hasil penelitian menunjukkan bahwa metode ini mampu meningkatkan akurasi deteksi kategori dengan signifikan. Dengan semakin berkembangnya teknologi dan metode pengolahan citra, maka deteksi kategori bangunan menjadi lebih cepat, akurasi, dan efisien, serta berpotensi besar yang diterapkan dalam sistem tanggap darurat dan evaluasi teknis infrastruktur (Nhat-Duc & Van-Duc, 2023). Penggunaan *deep learning* juga semakin berkembang dalam bidang ini. Contohnya, penelitian oleh Luo dkk. (2020) mengembangkan model deteksi kategori yang berbasis *Convolutional Neural Network* (CNN) yang mampu mengidentifikasi retakan pada struktur beton dengan tingkat akurasi yang tinggi.

Metode ini memanfaatkan dataset citra kategori yang sudah dilabeli sebelumnya untuk proses pelatihan dan validasi. Dengan adanya suatu kombinasi antara teknologi pengolahan citra, teknik *feature extraction* seperti *Law's Texture Energy Measures*, reduksi dimensi menggunakan PCA, serta algoritma pembelajaran mesin, sistem deteksi kategori bangunan juga dapat dikembangkan secara otomatis, akurat, dan efisien. Hal ini sejalan dengan arah transformasi digital dibagian dalam bidang manajemen infrastruktur dan mitigasi risiko pada bangunan.

2.3 Preprocessing

Citra bangunan rusak yang masuk akan diproses untuk meningkatkan kualitasnya. Pada tahap ini akan meliputi konversi ke *grayscale*, normalisasi nilai piksel, perbaiki kualitas dengan filtering, serta *resizing* agar semua citra memiliki ukuran yang seragam. *Preprocessing* hanya memastikan fitur tekstur dari adanya kategori yang dapat terdeteksi secara konsisten (Nhat-Duc & Van-Duc, 2023).

a) Resize

Resize merupakan proses mengubah ukuran citra digital menjadi dimensi tertentu agar seluruh data gambar memiliki ukuran yang seragam sebelum dianalisis. Tahap ini penting dilakukan karena ukuran citra yang tidak sama dapat memengaruhi hasil perhitungan fitur dan kinerja algoritma yang digunakan.

b) Grayscale

Grayscale adalah citra yang menampilkan variasi intensitas Cahaya dari hitam hingga putih tanpa warna. Setiap piksel memiliki nilai intensitas antara 0 (hitam) hingga 255 (putih). Proses konversi citra berwarna ke *grayscale* bertujuan menyederhanakan analisis citra dengan fokus pada tingkat kecerahan (Iqbal dkk., 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

2.4 Law's Texture Energy Measure (LTEM)

Law's Texture Energy Measures (LTEM) adalah metode analisis tekstur yang dikembangkan oleh Kenneth Ivan Laws pada tahun 1980. Metode ini menggunakan sekumpulan filter konvolusi, yang dikenal sebagai masker *laws*, untuk mengekstraksi fitur tekstur dari citra digital. Masker ini dirancang untuk mendeteksi berbagai pola tekstur dasar seperti *level (L)*, *edge (E)*, *spot (S)*, *wave (W)*, dan *ripple (R)* dalam citra.

a *Level (L)*

Digunakan untuk mendeteksi bagian area yang memiliki intensitas relatif seragam. Filter ini merepresentasikan rata-rata tingkat keabuan pada citra sehingga sering digunakan sebagai dasar pembentukan masker tekstur lainnya.

b *Edge (E)*

Digunakan untuk mendeteksi adanya perubahan intensitas yang tajam atau tepi objek pada citra. Respon yang tinggi pada filter menunjukkan adanya batas objek, retakan, atau transisi tekstur yang jelas.

c *Spot (S)*

Digunakan untuk mendeteksi pola bentuk titik atau bagian area kecil yang berbeda dari lingkungan disekitarnya. Filter ini sensitif terhadap detail lokal dan tekstur yang tersebar dalam bentuk ukuran kecil.

d *Wave (W)*

Digunakan untuk mendeteksi pola tekstur yang menyerupai perubahan intensitas yang bersifat periodik. Filter ini mampu menangkap tekstur yang memiliki pola berulang pada permukaan citra.

e *Ripple (R)*

Digunakan untuk mendeteksi variasi tekstur berfrekuensi tinggi, filter ini sensitif terhadap perubahan tekstur yang halus dan kompleks sehingga sering digunakan untuk mengidentifikasi detail permukaan yang tidak beraturan.

2.4.1 Proses Ekstraksi Fitur Menggunakan LTEM

Tahap ekstraksi fitur dilakukan setelah citra melalui proses filtering menggunakan *Law's Texture Energy Measures (LTEM)*. Tujuan dari tahap ini adalah memperoleh adanya informasi tekstur yang mampu merepresentasikan karakteristik tingkat kerusakan bangunan. LTEM menghasilkan energi tekstur yang menunjukkan respons terhadap berbagai pola tekstur lainnya. Pada proses fitur tekstur dengan LTEM melibatkan beberapa langkah utama:

1. Perhitungan Matriks

Perhitungan matriks merupakan proses menghasilkan filter dua dimensi berukuran 5×5 dari vektor dasar *Law's Masks* menggunakan operasi perkalian luar (*outer product*). Setiap elemen kernel diperoleh dari hasil perkalian antara elemen vektor pertama dan elemen vektor kedua yang dinyatakan dengan persamaan.

2. Konvolusi Citra dengan *Masker Laws*

Adanya citra yang dikonvolusi dengan masker 5×5 dan dirancang untuk menangkap pola yang bertekstur spesifik. Kombinasi umum dari masker ini menghasilkan 25 fitur yang berbeda.

3. Perhitungan Energi Tekstur

Setelah proses konvolusi dilakukan antara citra dan masker *Law's*, langkah berikutnya adalah menghitung energi tekstur dari hasil konvolusi tersebut. Energi

tekstur diperoleh dengan cara menghitung rata-rata kuadrat nilai hasil konvolusi dalam area (jendela) tertentu.

$$E = \frac{1}{N} \sum_{i=1}^N (I_i)^2 \quad (2.2)$$

Keterangan :

E = nilai energi tekstur yang menunjukkan intensitas pola tekstur

I_i = nilai piksel hasil konvolusi pada posisi ke – i

N = jumlah total piksel di area perhitungan

4. Normalisasi Fitur

Untuk mengurangi sensitivikasi terhadap variasi pencahayaan dan kontras, fitur energi tekstur ini biasanya akan dinormalisasikan sebelum digunakan dalam analisis lebih lanjut.

2.4.2 Rumus Dasar LTEM

Langkah utama dalam LTEM adalah menerapkan konvolusi antara citra dengan masker Law's, proses konvolusi dinyatakan sebagai:

$$F(x, y) = I(x, y) \times H(i, j) \quad (2.3)$$

$I(x, y)$ = citra input

$F(i, j)$ = salah satu masker *Law's* berukuran 5×5 .

$F(x, y)$ = citra hasil konvolusi.

Setelah konvolusi, energi tekstur akan dihitung dengan menghitung rata-rata kuadrat dari respons konvolusi dalam suatu jendela $N \times N$:

$$E = \frac{1}{N \times N} \sum_{x=1}^N \sum_{y=1}^N [F(x, y)]^2 \quad (2.4)$$

E = adalah nilai energi tekstur.

N = adalah ukuran jendela pengolahan.

$F(x, y)$ = adalah nilai piksel setelah konvolusi dengan masker *Law's*.

2.4.3 Masker *Law's*

Masker Laws terdiri dari lima vektor dasar 1D:

$$\begin{aligned} \mathbf{L5} \text{ (Level)} &= [1, 4, 6, 4, 1] \\ \mathbf{E5} \text{ (Edge)} &= [-1, -2, 0, 2, 1] \\ \mathbf{S5} \text{ (Spot)} &= [-1, 0, 2, 0, -1] \\ \mathbf{W5} \text{ (Wave)} &= [-1, 2, 0, -2, 1] \\ \mathbf{R5} \text{ (Ripple)} &= [1, -4, 6, -4, 1] \end{aligned}$$

Dengan mengalihkan dua vektor 1D, yang membentuk masker 2D berukuran 5x5.

Contoh masker tekstur:

$$F_{L5E5} = L5 \times E5 \quad (2.5)$$

Setiap masker digunakan untuk mengekstrak pola tekstur spesifik dari citra, yang kemudian diolah lebih lanjut dalam perhitungannya energi tekstur.

2.5 Principal Component Analysis (PCA)

Principal Component Analysis (PCA) adalah metode statistik yang bisa digunakan untuk mereduksi dimensi data dengan mentransformasikan adanya variabel yang saling berkorelasi menjadi sekumpulan variabel baru yang tidak berkorelasi, yang disebut sebagai komponen utama. Metode ini mempertahankan sebagian besar informasi yang dari data asli sambil mengurangi kompleksitasnya, sehingga sering digunakan dalam pengolahan citra digital yang meningkatkan efisiensi dan akurasi dalam suatu proses klasifikasi (Farook dkk., 2020).
Standarisasi Data: Menyesuaikan skala variabel agar memiliki rata-rata nol dan varians satu untuk memastikan adanya suatu kontribusi yang seimbang dalam analisis.

Proses *Principal Component Analysis* (PCA) dimulai dengan melakukan normalisasi data agar setiap fitur memiliki skala yang sama. Normalisasi dilakukan

dengan menggunakan metode *StandardScaler*. Berikut merupakan rumus penting dalam PCA:

$$X_{standar} = \frac{X - \bar{X}}{\sigma} \quad (2.6)$$

Dengan nilai rata-rata:

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n} \quad (2.7)$$

Dan standar deviasi:

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n - 1}} \quad (2.8)$$

- $X_{standar}$ nilai standar hasil normalisasi.
- n jumlah data
- X_i data ke-i
- $\bar{X}$ rata-rata
- σ standar deviasi

Setelah data dinormalisasikan, PCA menghitung matriks kovarians dengan persamaan:

$$C = \frac{1}{n - 1} \sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^T \quad (2.9)$$

- C matriks kovarian
- n jumlah data
- X_i data ke-i
- $\bar{X}$ rata-rata

Kemudian dilakukan perhitungan nilai eigenvector dan eigenvalue melalui persamaan:

$$\det(C - \lambda I) = 0 \quad (2.10)$$

$$C_v = \lambda_v$$

- C matriks kovarian
- λ eigenvalue
- v eigenvector

Setelah diperoleh eigenvalue dan eigenvector, komponen utama akan dipilih berdasarkan nilai explained ratio tertinggi. Variance ratio menggambarkan seberapa besar informasi yang akan dijelaskan oleh masing-masing komponen utama:

$$S^2 = \frac{\sum_{i=1}^n (X_i - \mu)^2}{n - 1} \quad (2.11)$$

- S = Variance Ratio
- n = jumlah data
- x_i = data ke - i
- μ = rata - rata

Dalam penelitian ini, PCA digunakan untuk mereduksi dimensi fitur hasil ekstraksi *Law's Texture Energy Measures* (LTEM) sehingga data akan menjadi lebih sederhana tetapi tetap representative. PCA membantu memvisualisasikan distribusi data dalam bentuk grafik 2D dan 3D, serta mempermudah proses *clustering* tingkat kategori bangunan. Dengan cara ini, data citra bangunan pasca bencana dapat dikelompokkan ke dalam tiga *clustering* berbeda.

2.6 Clustering Data

Clustering adalah teknik *data mining* yang memungkinkan pengorganisasian sekumpulan data ke dalam kelompok data dengan karakteristik yang sama, sehingga setiap objek dalam suatu kelompok memiliki tingkat kesamaan yang lebih tinggi dengan objek lain dalam kelompok tersebut dibandingkan dengan objek di kelompok lain. Teknik ini banyak digunakan dalam berbagai bidang, seperti segmentasi pelanggan yang umumnya diterapkan untuk

pemasaran dan analisis tren penjualan guna meningkatkan strategi bisnis, serta dalam sistem rekomendasi untuk menyesuaikan pengalaman pengguna (Yosia Galih Yudhistira dkk., 2022).

Clustering adalah salah satu algoritma yang paling banyak digunakan dalam *clustering*, di mana data dipisahkan menjadi k kelompok berdasarkan kedekatannya dengan titik pusat yang disebut *centroid*. Proses iteratif dilakukan untuk mengoptimalkan posisi titik pusat guna mendapatkan hasil *clustering* yang terbaik (Rose dkk., 2024). Dalam pengembangan aplikasi berbasis *clustering*, algoritma tersebut telah terbukti secara empiris mampu meningkatkan efisiensi pemrosesan data serta meningkatkan akurasi hasil analisis, terutama dalam sistem pendukung keputusan berbasis web (Ahsina dkk., 2022).


BAB III

METODE PENELITIAN

Pada pembahasan bab ini akan dibagi menjadi empat subbab yaitu desain sistem, *Data Preparation*, piksel, dan *scenario* pengujian.

3.1 Desain Sistem

Berikut Gambar 3.1 yang menunjukkan diagram alur dari proses LTEM dan PCA yang diterapkan dalam penelitian.



Gambar 3.1 Desain Sistem

Proses LTEM dimulai dengan menerima gambar sebagai input, diikuti dengan praproses untuk menyiapkan data sebelum ekstraksi fitur. Setelah itu, fitur diekstraksi melalui metode LTEM, diikuti dengan perhitungan menggunakan parameter LTEM tertentu serta pembuatan representasi fitur. Fitur LTEM yang telah diperoleh kemudian disimpan dengan cermat dalam *spreadsheet* sebagai data input untuk tahap selanjutnya. Sementara itu, metode PCA dimulai dengan

menyiapkan data dengan baik. Setelah itu, metode ini menghitung matriks kovarian untuk memahami hubungan antar fitur. Selanjutnya, komponen utama dibuat dengan menghitung nilai eigen serta vektor *eigen*. Data berdimensi rendah yang dihasilkan kemudian divisualisasikan dalam bentuk grafik 2D dan 3D, setelah itu dilakukan proses pengelompokan (*clustering*). Proses ini diakhiri dengan beberapa pengujian hasil untuk memastikan efektivitas keseluruhan dalam analisis.

1. Input Gambar

Tahap pertama masukkan gambar bangunan yang akan dianalisis ke dalam system. Citra ini umumnya diperoleh dari dokumentasi lapangan pada pasca bencana, seperti foto kondisi bangunan yang akan runtuh, atau mengalami kondisi kerusakan struktur. Pada tahap ini, citra disimpan dalam memori system untuk diproses lebih lanjut, sekaligus akan diperiksa kualitasnya (resolusi, pencahayaan, dan noise) agar tidak mengganggu hasil analisis tersebut (Luo dkk., 2020).

2. *Preprocessing*

Merupakan tahap awal yang dilakukan sebelum adanya proses ekstraksi fitur dengan menggunakan metode LTEM. Pada tahap ini bertujuan untuk mempersiapkan citra agar memiliki format yang seragam dan memudahkan proses analisis tekstur. Penelitian ini, *Preprocessing* dilakukan melalui dua tahapan, yaitu *resize* dan *grayscale*.

Pada tahap *resize* akan dilakukan untuk menyeragamkan ukuran pada keseluruhan citra sehingga setiap data akan memiliki dimensi yang sama sebelum dilakukan ekstraksi fitur. Keseragaman ukuran citra sangat diperlukan agar proses perhitungan fitur tekstur dapat dilakukan secara konsisten pada setiap citra. Setelah

proses resize, citra kemudian dikonversi dari format RGB ke *grayscale*. Untuk konversi ini dilakukan untuk mengurangi adanya kompleksitas data dengan mengubah informasi warna menjadi nilai intensitas keabuan tanpa menghilangkan karakteristik pada tekstur yang terkandung pada citranya. Hasil *preprocessing* selanjutnya akan digunakan sebagai masukan pada tahap ekstraksi fitur LTEM (Gonzalez dkk., 2009).

a) Resize

Pada penelitian ini, seluruh citra bangunan rusak akan diubah ke ukuran yang sama sebelum dilakukan adanya proses ekstraksi fitur. Dalam proses resize dilakukan untuk memastikan setiap citra yang memiliki jumlah piksel yang sama sehingga hasil ekstraksi fitur yang diperoleh dapat dibandingkan secara konsisten. Untuk ukuran citra yang akan digunakan dalam penelitian ini adalah 46 x 46.

b) *Grayscale*

Setelah proses di resize, citra RGB akan dikonversikan menjadi citra *grayscale*. Pada tahap ini dilakukan karena LTEM berfokus untuk menganalisis pola tekstur berdasarkan distribusi intensitas piksel. Dengan menghilangkan informasi warna, proses komputasi ini menjadi lebih sederhana dan karakteristik tekstur citra dapat dianalisis secara lebih efektif.

3. Ekstraksi Fitur dengan LTEM

Setelah *preprocessing*, citra akan dianalisis menggunakan *Law's Texture Energy Measures* (LTEM). Metode ini akan mengekstraksi pola tekstur dari citra kategori bangunan dengan menggunakan filter masker (L5, E5, S5, R5, W5). Hasil dari tahap ini berupa data numerik yang akan mewakili karakteristik tekstur,

misalnya retakan halus, keruntuhan besar, atau permukaan yang bergelombang (Ariyanto, 2020).

4. Output (*Spreadsheet*)

Data hasil dari ekstraksi fitur kemudian akan disimpan dalam bentuk *spreadsheet*. Setiap baris berisi representasi numerik dari citra bangunan rusak, yang nantinya akan dianalisis lebih lanjut pada tahap PCA.

5. Normalisasi Data

Fitur hasil LTEM sering memiliki skala nilai yang berbeda-beda. Oleh karena itu, dilakukan adanya normalisasi agar setiap fitur berada pada skala yang sama. Hal ini penting untuk menghindari dominasi fitur tertentu dalam analisi PCA (Nugraha & Wiguna, 2020).

6. Penentuan *Variance Ration* dan *Eigenvalue*

Pada tahap ini, PCA akan menghitung *eigenvalue* dan *variance ratio*. Nilai ini digunakan untuk menentukan seberapa besar informasi yang dijelaskan oleh setiap komponen utamanya. Hanya komponen dengan kontribusi besar yang bisa dipilih agar data lebih ringkas namun tetap *representative* (Nugraha & Wiguna, 2020).

7. Visualisasi Data dalam Grafik 2D dan 3D

Data hasil reduksi PCA akan divisualisasikan dalam bentuk 2D dan 3D. Visualisasi ini memungkinkan peneliti bisa melihat pola distribusi data kategori, misalnya kelompok citra dengan kategori (Abedi dkk., 2023).

8. *Clustering* Data

Tahap berikutnya Adalah pengelompokan data menggunakan metode *clustering*. Proses ini secara otomatis membagi data citra bangunan rusak ke dalam

kategori tertentu yang berdasarkan kemiripan pola tekstur yang sudah di reduksi oleh PCA (Rose dkk., 2024).

9. Hasil Akhir

Output akhir dari system ini berupa hasil dari klasifikasi tingkat kategori bangunan yang berupa 3 kategori (misalnya: *cluster 0*, *cluster 1*, *cluster 2*). Informasi ini dapat digunakan sebagai dasar pengambilan Keputusan cepat dalam penilain kondisi bangunan pasca bencana (Abedi dkk., 2023).

3.2 Data Preparation

Dalam penelitian ini, data yang digunakan diperoleh dari Badan Penanggulangan Bencana Daerah (BPBD) Kota Malang. Data tersebut mencakup beberapa informasi mengenai tingkat kategori bangunan akibat bencana alam yang terjadi di wilayah Kota Malang.

3.2.1 Sumber Data

Data citra kategori bangunan diambil pada tanggal 21 Maret 2025. Yang dimana pengambilan data citra bangunan rusak diperoleh dari Badan Penanggulangan Bencana Daerah (BPBD) Kota Malang, yang memiliki dokumentasi visual terkait bencana alam diwilayah sekitar. BPBD mendokumentasikan kerusakan akibat bencana untuk keperluan mitigasi dan rekontruksi, sehingga datanya sangat relevan untuk menganalisis ini. Selain itu, jika diperlukan data tambahan dapat dikumpulkan dari sumber lain seperti KAGGLE, dengan tanggal akses pada 19 Maret 2025.

3.2.2 Hasil Ekstraksi Fitur

Setelah melakukan proses prapemrosesan, fitur tekstur dari citra digital pada bangunan diekstrak menggunakan metode *Law's Texture Energy Measures* (LTEM). Proses ekstraksi ini akan menghasilkan sejumlah nilai energi tekstur yang akan mewakili pola texture lokal dari masing-masing citra. Dari hasil ekstraksi ini bisa mencakup beberapa fitur seperti *Level* (L5), *Edge* (E5), *Spot* (S5), *Wave* (W5), dan *Rippel* (R5) yang diperoleh melalui adanya proses konvolusi dengan masker *Law's 5x5*. Setiap gambar menghasilkan vektor fitur yang berdimensi tetap yang terdiri dari nilai energi untuk setiap kombinasi masker, seperti L5E5, E5S5, S5W5, dan seterusnya.

Hasilnya akan dinormalisasikan untuk mengurangi adanya sensitivitas terhadap pencahayaan kontras. Data hasil ekstraksi tersebut disimpan dalam bentuk *DataFrame* dan dikonversi ke dalam format *spreadsheet*. Setiap baris akan merepresentasikan satu gambar citra, dan setiap kolom akan berisi nilai energi dari adanya kombinasi masker tekstur. Berikut rumus menghitung energi tekstur:

1. Konvolusi citra dengan masker *Law's*

$$F(x, y) = I(x, y) * H(x, y) \quad (3.1)$$

- $I(x, y)$ adalah citra input.
- $H(x, y)$ masker Laws berukuran 5×5 .
- $F(x, y)$ adalah citra hasil konvolusi.

2. Perhitungan energi tekstur

Setelah konvolusi, nilai energi tekstur dihitung dengan rata-rata kuadrat dari hasil konvolusi tertentu:

$$E = \frac{1}{N} \sum_{x,y} F(x,y)^2 \quad (3.2)$$

- E Energi tekstur
- $F(x,y)$ nilai piksel hasil konvolusi
- N jumlah piksel

3.3 Piksel

Piksel adalah unit dasar dari citra digital yang merepresentasikan titik terkecil dalam suatu gambar. Setiap piksel memiliki koordinasi special berupa baris dan kolom yang bisa menentukan posisinya di dalam citra. Dalam konteks pengolahan citra digital, kumpulan piksel inilah yang membentuk keseluruhan tampilan gambar. Setiap piksel berfungsi sebagai pembawa informasi visual yang sangat kecil, namun ketika digabungkan secara keseluruhan, dapat menghasilkan visual yang utuh dan dapat dianalisis secara komputasional.

Nilai yang bisa dimiliki oleh piksel bersifat numerik dan menggambarkan tingkat kecerahan atau kombinasi warna. Dalam citra *grayscale*, nilai piksel umumnya berada dalam rentang 0 – 255, di mana nilai 0 mewakili warna hitam dan nilai 255 mewakili warna putih. Sementara itu, pada citra berwarna, setiap piksel terdiri atas tiga komponen utama merah, hijau, dan biru yang dikenal dengan model warna RGB. Kombinasi dari ketiga nilai tersebut menghasilkan variasi warna yang dapat ditampilkan oleh citra digital (Rohman Dijaya & Dijaya, 2023).

3.4 Skenario Pengujian

Skenario pengujian merupakan penelitian yang bertujuan untuk menganalisis performa pada metode yang digunakan dalam *clustering* data.

Pengujian ini dilakukan dengan berbagai parameter dan kondisi untuk menentukan kombinasi yang baik dalam proses *clustering*.

3.4.1 Variasi Jumlah Klaster

Dalam metode *clustering*, pemilihan jumlah klaster (K) sangat mempengaruhi hasil akhir. Oleh karena itu, dalam pengujian dengan beberapa variasi jumlah klaster untuk melihat bagaimana perbedaan nilai k memengaruhi hasil segmentasi data. Nilai k yang diuji dalam penelitian ini adalah:

- $K = 3$

3.4.2 Pengaruh Reduksi Dimensi dengan PCA

Selain jumlah klaster, penelitian ini juga bisa menguji adanya pengaruh *Principal Component Analysis* (PCA) dalam proses *clustering*. PCA juga digunakan untuk mereduksi jumlah fitur yang digunakan sebelum dilakukan proses *clustering*.

- Tanpa PCA: *Clustering* dilakukan langsung dengan menggunakan fitur yang diekstrak tanpa reduksi dimensi.
- Dengan PCA: *Clustering* dilakukan setelah fitur direduksi dengan menggunakan PCA untuk mengetahui apakah terdapat peningkatan efisiensi dan akurasi.

3.4.3 Evaluasi *Clustering*

Evaluasi kualitas dari hasil *clustering* merupakan langkah penting dalam analisis data untuk memastikan bahwa terdapat bagian data ke dalam klaster yang telah dilakukan secara optimal. Salah satunya menggunakan metode evaluasi internal yang pada umumnya digunakan adalah *Silhouette Score*. *Silhouette Score*

merupakan salah satu metode evaluasi yang digunakan untuk mengukur tingkat kedekatan antar data dalam satu *cluster* dalam tingkat keterpisahan data dengan *cluster* lainnya. Berikut rumus *silhouette Score* (Shahapure & Nicholas, 2020).

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

Keterangan :

S = *Silhouette Score*
 a = jarak intra klaster
 b = jarak antar klaster terdekat
 x_{max} = nilai maksimum

Nilai *Silhouette Score* pada rentang -1 hingga 1. Nilai mendekati 1 menunjukkan dengan baik dari *cluster* lain, sedangkan nilai mendekati 0 menunjukkan adanya tumpang tindih antar *cluster*. Adapun nilai negative itu mengindikasikan bahwa suatu data kemungkinan ditempatkan pada *cluster* kurang sesuai.

Tabel 3.1 Kriteria *Silhouette Score*

No	<i>Silhouette Score</i>	Keterangan
1	$0,7 \leq s \leq 1$	Kuat
2	$0,5 \leq s \leq 0,7$	Cukup
3	$0,25 \leq s \leq 0,5$	Lemah
4	$S \leq 0,25$	Tidak jelas

Tabel 3.1 menjelaskan kategori kualitas hasil *clustering* berdasarkan nilai *Silhouette Score* (S), yaitu ukuran untuk menilai seberapa baik data dikelompokkan ke dalam *cluster*, di mana nilai yang lebih tinggi menunjukkan hasil pengelompokan yang semakin baik dan jelas. Jika nilai *Silhouette Score* berada pada rentang 0,7 hingga kurang dari 1, maka kualitas *clustering* termasuk kategori kuat yang menunjukkan bahwa data terpisah dengan sangat jelas dan struktur *cluster* terbentuk dengan baik. Untuk nilai 0,5 hingga kurang dari 0,7, hasil

clustering berada pada kategori cukup yang menandakan bahwa pemisahan data sudah cukup baik meskipun belum optimal. Selanjutnya, jika nilai berada pada rentang 0,25 hingga kurang dari 0,5, maka kualitas *clustering* tergolong lemah yang menunjukkan bahwa data mulai bercampur dan pemisahan antar *cluster* kurang jelas. Sedangkan jika nilai kurang dari 0,25, maka hasil *clustering* dikategorikan tidak jelas, yang berarti pengelompokan data tidak terbentuk dengan baik dan antar *cluster* sulit dibedakan(Yuliasih dkk., 2024).

BAB IV

HASIL DAN PEMBAHASAN

4.1 Langkah Pengujian

Langkah pengujian pada penelitian ini dilakukan untuk mengevaluasi adanya kualitas pada metode LTEM dan PCA dalam melakukan *clustering* atau suatu pengelompokan tingkat kategori kerusakan bangunan pasca bencana alam. Data yang digunakan pada penelitian ini merupakan citra kerusakan bangunan pasca bencana yang diperoleh dari dokumentasi resmi BPBD Kota Malang. Data gambaran mempresentasikan adanya tingkat kategori bangunan yang terjadi akibat bencana alam, sehingga bisa digunakan sebagai dasar untuk menganalisis dan mengelompokkan tingkat kategori. Evaluasi hasil pada *clustering* dilakukan dengan metrik *Silhouette Score* untuk memastikan bahwa pengelompokkan tersebut dapat dihasilkan dalam tingkat akurasi dan pemisahan *cluster* yang baik.

4.2 Hasil Pengujian

Bagian hasil pengujian ini menguraikan tahapan-tahapan dalam menilai tingkat kategori bangunan akibat bencana alam melalui suatu proses segmentasi citra dengan pendekatan *Law's Texture Energy Measures* (LTEM) serta analisis *clustering* menggunakan *Principal Component Analysis* (PCA). Penelitian ini terdiri dari lima tahapan utama, yaitu pra-pemrosesan citra, Ekstraksi fitur LTEM, PCA, *Silhouette Score*.

4.2.1 Proses Algoritma LTEM

Proses penggunaan *Law's Texture Energy Measures* (LTEM) melalui beberapa langkah yang berurutan. Setiap langkah penting karena akan berpengaruh pada hasil akhirnya, yaitu seberapa baik tekstur kerusakan bangunan yang bisa dikenali dari citra tersebut. Data citra yang digunakan seperti berikut:



Gambar 4.1 Gambar citra yang digunakan

Pada gambar di atas merupakan proses *resize* citra awal yang semula berukuran 216x186 piksel dan diubah menjadi 184x184 piksel. Perubahan ukuran ini dilakukan supaya perhitungan rata-rata nilai piksel pada setiap blok hasil *resize* menghasilkan nilai bilangan bulat. Pada percobaan sebelumnya, ukuran *resize* lama menyebabkan pembagian blok tidak merata sehingga menghasilkan nilai desimal pada hasil peretaan. Dengan menyesuaikan ukuran menjadi 184x184, pembagian blok menjadi lebih proporsional dan memudahkan proses perhitungan rata-rata pada tahap analisis berikutnya.

a) Pra-pemrosesan Citra

Pra-pemrosesan citra merupakan tahap awal dari pengolahan citra digital yang bertujuan untuk meningkatkan kualitas visual citra agar siap dianalisis lebih lanjut, khususnya dalam proses ekstraksi fitur menggunakan metode *Law's Texture*

Energy Measures (LTEM). Pada penelitian ini, pra-pemrosesan dilakukan melalui beberapa langkah, yaitu mengonversi citra (*Red, Green, Blue*) RGB menjadi *grayscale* untuk menyederhanakan informasi warna ke dalam intensitas cahaya tunggal, melakukan resize citra menjadi 46×46 piksel guna menyamakan dimensi seluruh data citra. Tahapan ini penting untuk memastikan bahwa citra memiliki kualitas dan konsistensi yang memadai sebelum digunakan dalam analisis fitur dan proses klusterisasi.



Gambar 4.2 Hasil pemrosesan citra

Gambar 4.1 menunjukkan hasil dari tahap pra-pemrosesan citra yang meliputi konversi citra ke format (*Red, Green, Blue*) RGB, transformasi ke grayscale, serta perubahan ukuran citra dari resolusi awal 216×186 piksel menjadi 46×46 piksel.

b) Ekstraksi fitur LTEM

Pada ekstraksi fitur dilakukan untuk mendapatkan representasi tekstur dari citra kategori bangunan pasca bencana. Pada penelitian ini digunakan metode *Law's Texture Energy Measures* (LTEM) dengan 25 kombinasi fitur masker yang berukuran 5×5 .

1. Konvolusi citra dengan kombinasi masker *Law's*

Masker *Law's* merupakan kernel berukuran 5x5 yang dibentuk dari kombinasi lima vektor, yaitu *Level* (L5) untuk mendeteksi area homogen, *Edge* (E5) mendeteksi pola titik, *Wave* (W5) mendeteksi pola gelombang, dan *Ripple* (R5) mendeteksi riak atau osilasi halus. Kombinasi kelima vektor ini menghasilkan 25 masker *Law's* yang masing-masing mampu menonjolkan karakteristik tekstur tertentu pada citra.

Tabel 4.1 Hasil masker *Law's*

L5L5 [[1 4 6 4 1] [4 16 24 16 4] [6 24 36 24 6] [4 16 24 16 4] [1 4 6 4 1]]	L5E5 [[-1 -4 -6 -4 -1] [-2 -8 -12 -8 -2] [0 0 0 0 0] [2 8 12 8 2] [1 4 6 4 1]]	L5S5 [[-1 -4 -6 -4 -1] [0 0 0 0 0] [2 8 12 8 2] [0 0 0 0 0] [-1 -4 -6 -4 -1]]	L5W5 [[-1 -4 -6 -4 -1] [2 8 12 8 2] [0 0 0 0 0] [-2 -8 -12 -8 -2] [1 4 6 4 1]]	L5R5 [[1 4 6 4 1] [-4 -16 -24 -16 -4] [6 24 36 24 6] [-4 -16 -24 -16 -4] [1 4 6 4 1]]
E5L5 [[-1 -2 0 2 1] [-4 -8 0 8 4] [-6 -12 0 12 6] [-4 -8 0 8 4] [-1 -2 0 2 1]]	E5E5 [[1 2 0 -2 -1] [2 4 0 -4 -2] [0 0 0 0 0] [-2 -4 0 4 2] [-1 -2 0 2 1]]	E5S5 [[1 2 0 -2 -1] [0 0 0 0 0] [-2 -4 0 4 2] [0 0 0 0 0] [1 2 0 -2 -1]]	E5W5 [[1 2 0 -2 -1] [-2 -4 0 4 2] [0 0 0 0 0] [2 4 0 -4 -2] [-1 -2 0 2 1]]	E5R5 [[-1 -2 0 2 1] [4 8 0 -8 -4] [-6 -12 0 12 6] [4 8 0 -8 -4] [-1 -2 0 2 1]]
S5L5 [[-1 0 2 0 -1] [-4 0 8 0 -4] [-6 0 12 0 -6] [-4 0 8 0 -4] [-1 0 2 0 -1]]	S5E5 [[1 0 -2 0 1] [2 0 -4 0 2] [0 0 0 0 0] [-2 0 4 0 -2] [-1 0 2 0 -1]]	S5S5 [[1 0 -2 0 1] [0 0 0 0 0] [-2 0 4 0 -2] [0 0 0 0 0] [1 0 -2 0 1]]	S5W5 [[1 0 -2 0 1] [-2 0 4 0 -2] [0 0 0 0 0] [2 0 -4 0 2] [-1 0 2 0 -1]]	S5R5 [[-1 0 2 0 -1] [4 0 -8 0 4] [-6 0 12 0 -6] [4 0 -8 0 4] [-1 0 2 0 -1]]
W5L5 [[-1 2 0 -2 1] [-4 8 0 -8 4] [-6 12 0 -12 6] [-4 8 0 -8 4] [-1 2 0 -2 1]]	W5E5 [[1 -2 0 2 -1] [2 -4 0 4 -2] [0 0 0 0 0] [-2 4 0 -4 2] [-1 2 0 -2 1]]	W5S5 [[1 -2 0 2 -1] [0 0 0 0 0] [-2 4 0 -4 2] [0 0 0 0 0] [1 -2 0 2 -1]]	W5W5 [[1 -2 0 2 -1] [-2 4 0 -4 2] [0 0 0 0 0] [2 -4 0 4 -2] [-1 2 0 -2 1]]	W5R5 [[-1 2 0 -2 1] [4 -8 0 8 -4] [-6 12 0 -12 6] [4 -8 0 8 -4] [-1 2 0 -2 1]]
R5L5 [[1 -4 6 -4 1] [4 -16 24 -16 4] [6 -24 36 -24 6] [4 -16 24 -16 4] [1 -4 6 -4 1]]	R5E5 [[-1 4 -6 4 -1] [-2 8 -12 8 -2] [0 0 0 0 0] [2 -8 12 -8 2] [1 -4 6 -4 1]]	R5S5 [[-1 4 -6 4 -1] [0 0 0 0 0] [2 -8 12 -8 2] [0 0 0 0 0] [-1 4 -6 4 -1]]	R5W5 [[-1 4 -6 4 -1] [2 -8 12 -8 2] [0 0 0 0 0] [-2 8 -12 8 -2] [1 -4 6 -4 1]]	R5R5 [[1 -4 6 -4 1] [-4 16 -24 16 -4] [6 -24 36 -24 6] [-4 16 -24 16 -4] [1 -4 6 -4 1]]

Hasil dari tabel di atas dari perhitungan perkalian luar (*outer product*) dari dua vektor dasar.

1. Kernel L5L5


$$L5 = [1, 4, 6, 4, 1]$$

$$L5 \otimes L5 = \begin{bmatrix} 1 \cdot 1 & 1 \cdot 4 & 1 \cdot 6 & 1 \cdot 4 & 1 \cdot 1 \\ 4 \cdot 1 & 4 \cdot 4 & 4 \cdot 6 & 4 \cdot 4 & 4 \cdot 1 \\ 6 \cdot 1 & 6 \cdot 4 & 6 \cdot 6 & 6 \cdot 4 & 6 \cdot 1 \\ 4 \cdot 1 & 4 \cdot 4 & 4 \cdot 6 & 4 \cdot 4 & 4 \cdot 1 \\ 1 \cdot 1 & 1 \cdot 4 & 1 \cdot 6 & 1 \cdot 4 & 1 \cdot 1 \end{bmatrix} = \begin{bmatrix} 1 & 4 & 6 & 4 & 1 \\ 4 & 16 & 24 & 16 & 4 \\ 6 & 24 & 36 & 24 & 6 \\ 4 & 16 & 24 & 16 & 4 \\ 1 & 4 & 6 & 4 & 1 \end{bmatrix}$$

✓ Hasil ini sesuai dengan kernel L5L5 di tabel.

Gambar 4.3 Contoh perhitungan *masker Law's*

Setelah membuat *masker Law's* dilakukan konvolusi terhadap gambar yang sudah di *Grayscale*. Konvolusi adalah proses perkalian antara *masker Law's* dan citra gambar.



Gambar 4.4 Hasil ekstraksi fitur

Gambar di baris pertama sebelah kiri merupakan citra asli. Sementara itu, gambar-gambar lainnya menunjukkan hasil ekstraksi dari masing-masing masker

Law's seperti L5E5, E5S5, S5W, dan sebagainya. Setiap hasil ekstraksi menyoroti karakteristik tekstur yang berbeda. Setiap hasil ekstraksi akan menyoroti karakteristik tekstur yang berbeda, yang selanjutnya digunakan untuk fitur dalam proses klasifikasi tingkat kategori bangunan.

Ekstraksi ini bertujuan untuk menghasilkan representasi fitur tekstur yang lebih informatif sehingga membantu dalam membedakan antara tingkat kategori *cluster 0*, *cluster 1*, *cluster 2* secara visual dan statistik.

Tabel 4.2 Nilai konvolusi L5L5

7647	8942	8468	8792	10122	...	13140	20889	28293	25145
13171	17671	19200	21009	23952	...	15535	23363	32400	30144
19651	29190	34256	37804	41508	...	14124	19000	26023	25106
27229	41216	48647	52611	55478	...	13335	15842	19748	18544
34282	50553	57906	60602	61917	...	13472	14786	16420	14174
...	...	...	...	...	...	...	...	...	...
17205	25944	27416	23690	17205	...	22638	22584	21388	15840
15246	22598	22533	17509	15246	...	29171	27558	24086	16581
11737	16987	16393	12211	11737	...	31728	28865	23820	15526
7089	9958	9589	7453	7089	...	24543	21501	17025	10732

2. Perhitungan Energi Konvolusi

Nilai energi tekstur pada fitur LTEM diperoleh melalui tahapan proses konvolusi citra dengan masker *Law's* berukuran 5x5, yang dirancang masing-masing untuk menangkap pola tekstur seperti (L5, E5, S5, W5, R5). Setelah citra dikonvolusi dengan setiap masker, maka konvolusi tersebut akan dihitung energinya dengan mengambil rata-rata dari kuadrat nilai piksel pada citra hasil filter. Nilai inilah yang disebut dengan energi tekstur. Energi tekstur menggambarkan seberapa kuat suatu pola tekstur yang muncul pada citra, misalnya area homogen yang bisa menghasilkan energi tinggi pada filter L5L5, sedangkan area dengan detail halus atau retakan kecil akan lebih menonjol pada filter seperti S5S5 atau W5S5.

Tabel 4.3 Nilai Energi Ekstraksi Fitur

Masker	Energi Tekstur
L5L5	427800000.0000
L5E5	4184804.0000
L5S5	890403.0625
L5W5	673400.0000
L5R5	3231446.5000
E5L5	2921035.0000
E5E5	96527.5156
E5S5	31631.8457
E5W5	32032.9141
E5R5	147666.1250
S5L5	585201.6875
S5E5	22473.0625
S5S5	8411.0488
S5W5	9406.0850
S5R5	43871.7734
W5L5	480443.9375
W5E5	18891.8867
W5S5	7247.7661
W5W5	8389.9395
W5R5	38854.6758
R5L5	2362486.5000
R5E5	93973.2969
R5S5	30654.1934
R5W5	34187.7148
R5R5	200272.5156

4.2.2 Implementasi *Principal Component Analysis* (PCA)

Tahap akhir dari proses ini adalah penerapan *Principal Component Analysis* (PCA), yang digunakan untuk mereduksi dimensi data dan melakukan pengelompokan bagian area kategori bangunan berdasarkan suatu karakteristik nilai piksel.

a) Normalisasi Data

Langkah pertama dalam penerapan PCA adalah normalisasi data untuk memastikan bahwa semua fitur memiliki skala yang sama. Normalisasi ini dilakukan guna menggunakan fungsi *StandardScaler* dari pustaka *scikit-learn*. Proses ini mengubah setiap fitur Dalam dataset menjadi memiliki rata-rata nol dan deviasi standar satu agar fitur dengan skala besar tidak mendominasi perhitungan

PCA. Pada sistem ini, data yang dinormalisasikan berasal dari suatu hasil konversi algoritma LTEM dan ekstraksi fitur LTEM. Proses ini menghasilkan data numerik yang lebih teratur dan seragam dalam bentuk angka-angka standar seperti yang ditampilkan pada tabel 4.2.

Tabel 4.4 Hasil normalisasi data

[[-1.23522114 -1.59455804 -0.85973325 -1.16260996 -0.83228621 -2.08765200 -1.73278004 -0.31853878 -0.88670240 -0.34172869 -0.43909354 0.08324560 -0.63490262 -1.51471923 -0.77662460 -1.73110590 1.60437889 -0.19576293 -1.92360443 -0.33863996 0.30660607 -0.94505405 -0.31116309 -1.19855181]
[-1.19721161 -1.56723934 -1.12044795 -1.31899096 -0.93870505 -1.76936662 -1.44761861 -1.15131143 -1.18261178 -0.86872410 -1.96050001 0.20184809 -0.47874008 -1.01052967 -0.54784675 -0.88801411 1.57974854 -0.47975203 -2.25632244 -0.34576366 -0.32955061 -0.41887151 -2.23148386 -1.78288441]
[-1.24816055 -1.25102546 -0.68563473 -0.85702872 0.02222547 0.95494042 0.88798930 -0.52976178 -1.03563692 0.22706066 -0.12934612 -0.03535690 -0.74586022 -0.02743023 0.10227098 -1.43304315 0.51448575 1.52570186 -0.81998509 -0.53810347 -0.18760896 -0.42804911 0.88733498 -0.68904742]
...
[-0.35394675 -1.50980706 0.09962716 -0.43135268 -1.02080579 -0.09631949 -1.11247779 0.29382171 0.89829854 -0.47106115 -0.32054957 0.17644204 -1.16133785 -0.62391940 1.01918673 0.87051538 0.29532090 -0.46192403 0.32715844 0.04931510 0.15240381 0.77059626 -0.17460051 -0.87500598]
[3.75664113 0.11250459 -0.40892319 0.02287972 0.00961825 0.08728243 -0.16151332 -0.05490986 -0.38127904 -0.37571816 0.00678816 -0.43043718 -0.29541163 -0.24698309 0.08926315 -0.85359856 -0.09117479 -0.43942102 -0.32458384 -0.40818252 -0.34431190 -0.57505906 -0.38655742 -0.29460163 -0.29118868]]

b) Penentuan *Variance Ration* dan *Eigenvalue*

Hasil pada tabel 4.4 menunjukkan matriks komponen utama (*principal component*) yang dihasilkan setelah proses reduksi dimensi menggunakan PCA. Pada setiap baris tabel merepresentasikan observasi atau sampel dimensi citra

bangunan rusak, sementara setiap kolom menunjukkan adanya nilai proyeksi dari sampel tersebut terhadap masing-masing komponen utama (PC). Nilai positif dan negative yang muncul merupakan representasi baru data dalam ruang PCA, yang terbentuk dari adanya kombinasi linear fitur awal.

Dari hasil tersebut dapat dilihat bahwa distribusi nilai cukup beragam, mulai dari negatif hingga positif dengan rentang yang cukup lebar. Hal ini menunjukkan bahwa PCA berhasil memisahkan variasi pada data citra kategori bangunan menjadi komponen-komponen baru yang lebih sederhana. Dengan klasifikasi dapat dilakukan lebih efisien karena dimensi data yang berkurang tanpa kehilangan banyak informasi penting.

Tabel 4.5 Nilai Ratio dan *Eigenvalue*

No	PC	Explained Variance (%)	Eigen Value
0	PC1	30.06	7.33
1	PC2	21.80	5.32
2	PC3	12.43	3.03
3	PC4	5.16	1.26
4	PC5	3.56	0.87
5	PC6	3.15	0.77
6	PC7	3.13	0.76
7	PC8	2.66	0.65
8	PC9	2.51	0.61
9	PC10	2.18	0.53
10	PC11	1.93	0.47
11	PC12	1.78	0.43
12	PC13	1.58	0.39
13	PC14	1.50	0.37
14	PC15	1.47	0.36
15	PC16	1.06	0.26
16	PC17	0.80	0.20
17	PC18	0.71	0.17
18	PC19	0.58	0.14

Hasil perhitungan PCA pada Tabel 4.3 menunjukkan nilai *Explained Variance (%)* dan *Eigen Value (%)* untuk masing-masing komponen utama.

Explained Variance menggambarkan seberapa besar proporsi variasi data yang mampu dijelaskan oleh setiap komponen, sedangkan *eigen Value* menunjukkan seberapa besar bobot pada kontribusi komponen tersebut terhadap representasi data asli. Dari tabel terlihat bahwa PC1 memiliki *explained variance* sebesar 30,06% dengan *eigen value* 7,33, sehingga komponen ini memegang peran paling dominan dalam menjelaskan data. PC2 dan PC3 juga memberikan kontribusi besar dengan nilai masing-masing 21,80% (5,32) dan 12,43% (3,03).

Secara keseluruhan terlihat adanya penurunan bertahap baik pada nilai *explained variance* maupun *eigen value* di setiap komponen berikutnya. Pada komponen utama dengan nilai *explained variance* yang lebih tinggi dianggap lebih penting, karena mampu menjelaskan variasi data dalam jumlah yang lebih besar. Dengan demikian, hanya beberapa komponen utama pertama (misalnya PC1 hingga PC5) yang bisa digunakan untuk mewakili data secara efektif, sementara komponen dengan nilai *variance ratio* dan *eigen value* yang kecil dapat diabaikan tanpa mengurangi banyak informasi.

c) Komponen Utama PCA

Komponen utama yang dihasilkan dari proses *Principal Component Analysis* (PCA) merupakan representasi baru dari data yang telah direduksi dimensinya. Pada penelitian ini digunakan tiga komponen utama, yaitu PC1, PC2, dan PC3. Komponen utama pertama (PC1) menjelaskan variasi terbesar dalam data, sehingga memiliki kontribusi paling dominan dalam membedakan pola citra bangunan. Komponen utama kedua (PC2) menangkap variasi terbesar kedua yang tidak dapat dijelaskan oleh PC1, sedangkan komponen utama ketiga (PC3) merepresentasikan

variasi tambahan yang masih cukup signifikan meskipun lebih kecil dari kontribusinya.

Proses dalam pembentukan komponen utama ini dilakukan dengan memanggil fungsi PCA dengan menggunakan perintah $pca = PCA(n_components=3)$, yang berarti sistem hanya mengambil tiga komponen utama dari keseluruhan fitur. Selanjutnya, fungsi *fit_transform()* digunakan untuk mentransformasikan data awal ke dalam ruang PCA sehingga akan menghasilkan nilai baru yang tersimpan pada variabel PC1, PC2, dan PC3. Hasil transformasi ini kemudian dapat digunakan sebagai dasar analisis lebih lanjut, seperti visualisasi distribusi data maupun proses *clustering* tingkat kategori.

Tabel 4.6 Hasil nilai komponen utama PCA


Index	PC1	PC2	PC3
0	-3.985003408	-2.463796316	-1.224982040
1	-4.655965561	-2.902557884	-1.722908002
2	-1.703643984	-0.511897437	0.610009836
3	-1.125958023	-3.837895424	1.633625071
4	-2.682673759	-2.573044214	1.701484478
5	-2.797394455	-2.524308062	1.819073604
6	-2.655358320	-1.497816133	3.361794111
7	-2.374177374	-1.901613028	1.194931105
8	-3.517938121	-2.834487677	-1.332835962
9	-4.397924730	-2.684937101	-2.312676264
10	-0.332009575	-1.614210628	-1.579578016
11	2.149329682	-2.426608199	2.106003973
12	0.674771385	-1.570701656	2.828835190
13	0.608740470	-1.959797729	1.302984986
14	-2.336802984	-0.139816538	1.519417422
15	-3.230363751	-1.149229395	1.699871569
16	-2.172814040	-2.547706665	-2.670175086
17	-4.737184262	-2.263241892	-3.993376990
18	-1.885602477	-0.753628700	-1.236285337

d) Visualisasi Data

Setelah proses ekstraksi fitur dengan metode *Law's Texture Energy Measures* (LTEM) dan reduksi dimensi dengan menggunakan *Principal Component Analysis*

(PCA). Tujuannya untuk melihat pola distribusi data hasil transformasi PCA sehingga dapat diamati dalam kecenderungan pengelompokan berdasarkan tingkat kerusakan bangunan. Komponen utama yang dihasilkan oleh PCA, seperti PC1, PC2, dan PC3, digunakan untuk mempresentasikan variasi terbesar dari data sehingga informasi penting tetap terjaga meskipun dimensi berkurang.


Hasil visualisasi menunjukkan bahwa data citra bangunan dengan karakteristik tekstur serupa cenderung akan berdekatan, sedangkan data dengan perbedaan tekstur terlihat lebih berjauhan. Hal ini menandakan terbentuknya kelompok alami pada data yang selanjutnya yang digunakan dalam proses *clustering*. Dengan demikian, visualisasi ini membuktikan bahwa PCA mampu menyederhanakan data sekaligus memperlihatkan pemisahan antar kategori tingkat kerusakan bangunan secara lebih jelas.



Gambar 4.5 Visualisasi *cluster* 2D

Visualisasi PCA dalam bentuk 2D menggunakan komponen utama PC1 dan PC2 yang memperlihatkan data citra bangunan setelah dilakukan reduksi dimensi. Setiap titik akan terlihat pada grafik yang merepresentasikan satu data citra yang

sudah di proses. Dari hasil ini terlihat bahwa data terdistribusi dengan cukup menyebar pada kedua sumbu, yang menunjukkan adanya variasi pola tekstur antar citra yang bisa dijadikan dasar dalam pengelompokan lebih lanjut.



Gambar 4.6 Visualisasi *cluster* 3D

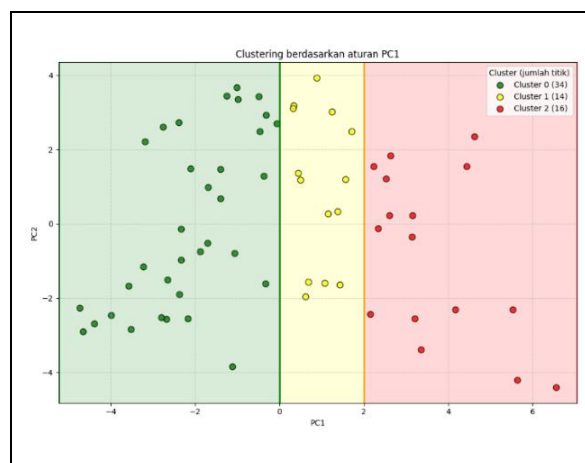
Visualisasi PCA dalam bentuk 3D menggunakan PC1, PC2, dan PC3 yang memberikan gambaran yang lebih komprehensif dibandingkan dengan tampilan 2D. Pada grafik ini terlihat adanya distribusi data yang lebih jelas dengan dimensi tambahan, sehingga polanya akan terpisah antar kelompok data yang lebih mudah diamati. Hal ini membantu proses identifikasi potensi *cluster* yang tidak sepenuhnya terlihat pada visualisasi 2D.

4.1.1 *Clustering* Data

Dalam penelitian ini, *clustering* data digunakan untuk mengelompokkan citra bangunan rusak pasca bencana ke dalam beberapa kategori. Proses *clustering* dilakukan setelah data citra melewati tahap ekstraksi fitur dengan menggunakan metode *Law's Texture Energy Measures* (LTEM) dan reduksi dimensi dengan

Principal Component Analysis (PCA). LTEM berfungsi mengekstraksi pola tekstur dari citra, misalnya retakan halus, keruntuhan besar, atau permukaan bergelombang, sedangkan PCA mereduksi dimensi fitur agar data lebih ringkas namun tetap *representative*.

Hasil reduksi pada PCA kemudian divisualisasikan dalam ruang 2D maupun 3D untuk melihat pola distribusi data. Pada tahap ini, *clustering* berperan penting untuk mengelompokkan citra berdasarkan kemiripan tekstur yang dihasilkan LTEM. Proses pengelompokan ini menghasilkan tiga kategori utama, yaitu *cluster* 0, *cluster* 1, *cluster* 2, yang merepresentasikan tingkat kategori bangunan.



Gambar 4.7 Cluster 3


Hasil Pada gambar 4.7 menunjukkan hasil *clustering* berdasarkan aturan PC1 dari hasil reduksi dimensi dengan menggunakan *Principal Component Analysis* (PCA). Pada sumbu horizontal ditampilkan nilai PC1, sedangkan sumbu *vertical* menampilkan nilai PC2. Data citra bangunan yang telah diekstraksi menggunakan LTEM kemudian diproyeksikan ke dalam ruang PCA sehingga terbentuk distribusi titik-titik. Aturan dalam pengelompokan dilakukan berdasarkan

rentang nilai di PC1, yang kemudian membagi data menjadi tiga *cluster* yang berbeda.

Dengan pembagian ini, dapat dilihat bahwa PCA mampu memisahkan data yang berdasarkan variasi tekstur LTEM, sehingga setiap *cluster* menunjukkan kecenderungan tingkat kategori yang berbeda secara visual maupun *statistic*.

Tabel 4.7 Rentang nilai 3cluster

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



Gambar 4.8 Cluster 3D

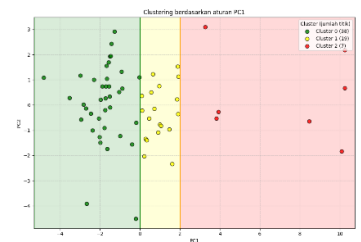
Gambar 4.8 menampilkan hasil *clustering* 3D berdasarkan PCA dengan memanfaatkan tiga komponen utama, yaitu PC1, PC2, dan PC3. Setiap titik pada grafik tersebut mewakili satu data citra bangunan yang telah diekstraksi menggunakan metode LTEM dan direduksi dimensinya melalui PCA. Visualisasi


tiga dimensi ini memungkinkan pola distribusi antar data supaya terlihat lebih jelas dibandingkan grafik 2D.

Dari visualisasi ini terlihat bahwa PCA mampu memisahkan data berdasarkan hasil variasi tekstur secara komprehensif. Titik-titik yang berada di dalam satu *cluster* memiliki karakteristik, sedangkan *cluster* yang berjauhan menandakan perbedaan tingkat kategori yang cukup jelas.

Selain menggunakan satu kombinasi parameter energi, penelitian ini juga melakukan beberapa percobaan dengan variasi parameter pada proses perhitungan energi *Law's Texture Energy Measures* (LTEM). Variasi parameter tersebut dilakukan untuk mengetahui pengaruhnya terhadap hasil *clustering* tingkat kerusakan bangunan. Setiap hasil *clustering* kemudian dievaluasi menggunakan nilai *Silhouette Score* untuk menentukan kombinasi parameter yang mampu menghasilkan kualitas *cluster* terbaik.


Tabel 4.8 Hasil modifikasi parameter

Citra bangunan & Modifikasi parameter	Nilai energi	Cluster	Silhouette Score
 L5= ([1,2,3,2,1] E5= ([-2,-1,0,1,2]) S5= ([-2,-1,6,-1,2]) W5= ([-1,3,0,-3,1]) R5= ([1,-2,2,-2,1])	📄 Energi Tekstur (25 Fitur LTEM): - L5L5: 125779040.0000 - L5E5: 1877935.5000 - L5S5: 2279978.0000 - L5W5: 775812.6875 - L5R5: 228600.9219 - E5L5: 2424271.2500 - E5E5: 285142.1250 - E5S5: 454236.2188 - E5W5: 157448.7656 - E5R5: 35817.4961 - S5L5: 2680401.2500 - S5E5: 500357.6875 - S5S5: 1143183.2500 - S5W5: 416249.2188 - S5R5: 142781.7969 - W5L5: 927175.9375 - W5E5: 176102.4688 - W5S5: 428898.9375 - W5W5: 156525.3125 - W5R5: 58425.4727 - R5L5: 274562.7500 - R5E5: 49447.6523 - R5S5: 168807.8125 - R5W5: 66334.6016 - R5R5: 33970.4492		0.5741

Citra bangunan & Modifikasi parameter	Nilai energi	Cluster	Silhouette Score
 $L5 = ([5, 32, 48, 32, 5])$ $E5 = ([-16, -8, 0, 8, 16])$ $S5 = ([-8, -8, 32, -8, -8])$ $W5 = ([-12, 24, 0, -24, 12])$ $R5 = ([5, -20, 36, -20, 5])$	☒ Energi Tekstur (25 Fitur LTEM): - L5L5: 3597947371520.0000 - L5E5: 22143418368.0000 - L5S5: 10231100416.0000 - L5W5: 8079752704.0000 - L5R5: 7816319488.0000 - E5L5: 27985002496.0000 - E5E5: 1167942144.0000 - E5S5: 679494080.0000 - E5W5: 562622976.0000 - E5R5: 472829728.0000 - S5L5: 11881676800.0000 - S5E5: 762889728.0000 - S5S5: 701179584.0000 - S5W5: 646722944.0000 - S5R5: 681835520.0000 - W5L5: 9367552000.0000 - W5E5: 655163008.0000 - W5S5: 676130176.0000 - W5W5: 627568960.0000 - W5R5: 699433024.0000 - R5L5: 9131390976.0000 - R5E5: 610644736.0000		0.5375

Pada tabel 4.8 koefisien *kernel Law's* memberikan pengaruh terhadap proses ekstraksi fitur tekstur. Perbedaan fitur yang dihasilkan menyebabkan perubahan distribusi data pada ruang PCA sehingga menghasilkan nilai *Silhouette Score* yang berbeda pada setiap skenario pengujian.

Selain menggunakan 3 *cluster*, penelitian ini juga melakukan pengujian dengan jumlah *cluster* 2, 4, dan 5 sebagai pembandingan. Tujuannya adalah untuk mengetahui jumlah *cluster* yang paling optimal berdasarkan nilai *Silhouette Score* yang diperoleh dari masing-masing hasil *clustering*.




Gambar 4.9 Cluster 2

Berdasarkan hasil Gambar 4.9 merupakan hasil pengelompokan *cluster* 2, yang dimana data terbagi menjadi dua kelompok yang cukup jelas berdasarkan nilai PC1. *Cluste* 0 berisi data yang berada di sisi kiri grafik dengan nilai yang lebih rendah, sedangkan *cluster* 1 berada pada sisi kanan grafik dengan nilai yang lebih tinggi. Rentang nilai pada *cluster* 2 ditentukan berdasarkan nilai komponen utama yang digunakan sebagai batas pemisah antar kelompok. Pengelompokan dilakukan dengan mempertimbangkan posisi dan sebaran data pada sumbu PC1 sehingga diperoleh rentang nilai untuk setiap *cluster* sebagai berikut:

Tabel 4.9 Rentang nilai *cluster* 2

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



Gambar 4.10 *Cluster* 4


Pada pengelompokan 4 *cluster*, struktur data menjadi semakin rinci dibandingkan pada 2 atau 3 *cluster*. *Cluster* utama yang sebelumnya mencakup sebagian besar titik tetap mendominasi, namun data yang berada di sisi kanan sumbu PC1 terpecah menjadi beberapa kelompok yang lebih spesifik. Pemisahan ini menunjukkan bahwa terdapat adanya variasi karakteristik yang cukup jelas di

dalam data sehingga beberapa titik yang sebelumnya berada dalam satu kelompok kini dipisahkan ke *cluster* yang berbeda.

Dalam pengelompokan 4 *cluster*, rentang nilai ditentukan berdasarkan posisi titik sumbu PC1 yang dibagi menjadi empat bagian. Berdasarkan rentang tersebut, *Cluster 0* merepresentasikan data nilai PC1 rendah, *Cluster 1* dan *Cluster 2* menggambarkan kelompok transisi dengan tingkat perbedaan bertahap, sedangkan *Cluster 3* mencakup data nilai PC1 paling tinggi. Pembagian ini menghasilkan pemisahan yang lebih detail sehingga pola variasi data dapat diamati lebih jelas dibandingkan pengelompokan dengan jumlah *cluster* yang lebih sedikit.

Tabel 4.10 Rentang nilai *cluster 5*

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



Gambar 4.11 *Cluster 5*

Pada pengelompokan 5 *cluster*, struktur data menjadi semakin terperinci dibandingkan pada pengelompokan 4 *cluster*. Kelompok data yang sebelumnya masih tergabung dalam satu *cluster* dan kembali dipecah menjadi beberapa kelompok yang lebih kecil berdasarkan kedekatan nilai pada sumbu PC1.

Pemisahan ini menunjukkan bahwa terdapat variasi karakteristik yang lebih detail di dalam data, sehingga beberapa titik yang sebelumnya berada pada *cluster* yang sama kini ditempatkan pada *cluster* yang berbeda.

Dalam pengelompokan 5 *cluster*, rentang nilai ditetapkan berdasarkan pola sebaran data pada PC1. Pembagian 5 *cluster* menghasilkan representasi data yang lebih rinci dibandingkan pengelompokan sebelumnya. Akan tetapi, semakin banyak *cluster* yang dibentuk menyebabkan jumlah anggota pada beberapa *cluster* menjadi semakin sedikit. Hal ini menunjukkan bahwa meskipun variasi data dapat terlihat lebih detail, pemisahan yang terlalu banyak mulai menghasilkan *cluster-cluster* kecil yang tidak selalu memiliki tingkat kekompakan yang kuat.

Tabel 4.11 Rentang nilai 5 *cluster*

<i>Cluster</i>	Rentang Nilai (n)
<i>Cluster 0</i>	$n < 0$
<i>Cluster 1</i>	$0 \leq n < 4$
<i>Cluster 2</i>	$4 \leq n < 5$
<i>Cluster 3</i>	$5 \leq n < 6$
<i>Cluster 4</i>	$n \geq 6$

4.2.3 Evaluasi Sistem

Evaluasi kualitas hasil *clustering* pada penelitian ini dilakukan menggunakan metode *Silhouette Score*. Pada implementasi, evaluasi dilakukan berdasarkan nilai PC1 digunakan untuk dasar pembentukan *cluster*, kemudian disimpan dalam variabel *x* melalui perintah `principalDF[['PC1']].values`. selanjutnya, label pada *cluster* yang berbentuk teks, yaitu *cluster 0*, *cluster 1*, *cluster 2*, dikonversi menjadi label numerik menggunakan *label_mapping* agar dapat diproses oleh fungsi evaluasi dari library *scikit-learn*.

Tabel 4.12 Hasil *Silhouette Score*

Jumlah Cluster	<i>Silhouette score</i>
2 Cluster	0.588535
3 Cluster	0.4723
4 Cluster	0.5150
5 Cluster	0.5144

Tabel 4.12 menampilkan nilai silhouette score untuk setiap jumlah *cluster* yang diuji, yaitu 2 *cluster*, 3 *cluster*, 4 *cluster*, dan 5 *cluster*. Berdasarkan hasil pengujian, 2 *cluster* menghasilkan nilai silhouette score tertinggi sebesar 0.588535, yang menunjukkan bahwa struktur *cluster* terbentuk paling kuat dan memiliki pemisahan data terbaik dibandingkan jumlah *cluster* lainnya. Pada 3 *cluster*, nilai silhouette score menurun menjadi 0.4723, yang menunjukkan bahwa kualitas pemisahan *cluster* mulai melemah dibandingkan skenario 2 *cluster*. Selanjutnya, 4 *cluster* memperoleh nilai silhouette score sebesar 0.5150, yang menunjukkan adanya peningkatan dibandingkan 3 *cluster*, namun masih belum melampaui hasil terbaik pada 2 *cluster*. Adapun 5 *cluster* menghasilkan nilai silhouette score sebesar 0.5144, yang nilainya hampir sama dengan 4 *cluster* tetapi tetap lebih rendah dibandingkan 2 *cluster*.

Secara keseluruhan, hasil evaluasi menunjukkan bahwa jumlah *cluster* yang paling optimal pada penelitian ini adalah 2 *cluster*, karena menghasilkan nilai silhouette score tertinggi dan termasuk dalam kategori struktur *cluster* yang paling baik. Hal ini mengindikasikan bahwa data memiliki pola pemisahan yang lebih jelas dan tingkat kekompakan serta keterpisahan antar *cluster* yang lebih optimal pada skenario 2 *cluster* dibandingkan jumlah *cluster* lainnya.

4.3 Pembahasan

Berdasarkan hasil pengujian yang telah dilakukan, metode *Law's Texture Energy Measures* (LTEM) mampu mengekstraksi karakteristik tekstur pada citra bangunan pascabencana dengan baik. Tahap pra-pemrosesan berupa *resize* dan konversi *grayscale* berhasil menghasilkan citra yang seragam sehingga proses ekstraksi fitur dapat dilakukan secara konsisten pada seluruh data. Ukuran citra yang diseragamkan menjadi 46×46 piksel memudahkan proses perhitungan tekstur, sedangkan konversi ke *grayscale* mampu menyederhanakan informasi citra tanpa menghilangkan karakteristik tekstur yang dibutuhkan dalam analisis.

Pada tahap ekstraksi fitur, LTEM menggunakan kombinasi masker *Law's* yang terdiri dari *Level* (L5), *Edge* (E5), *Spot* (S5), *Wave* (W5), dan *Ripple* (R5). Kombinasi *masker* tersebut menghasilkan 25 fitur tekstur yang mampu merepresentasikan pola permukaan bangunan berdasarkan distribusi intensitas piksel pada citra. Setiap masker memberikan respons yang berbeda terhadap karakteristik tekstur tertentu, seperti area homogen, tepi objek, pola titik, gelombang, maupun variasi tekstur yang lebih kompleks. Hasil ekstraksi ini menghasilkan nilai energi tekstur yang digunakan sebagai representasi numerik dari kondisi bangunan.

Fitur-fitur yang diperoleh kemudian dinormalisasi dan direduksi menggunakan *Principal Component Analysis* (PCA). Proses reduksi dimensi dilakukan untuk mengurangi kompleksitas data tanpa menghilangkan informasi penting yang terkandung dalam fitur tekstur. Hasil PCA menunjukkan bahwa data

dapat direpresentasikan dalam beberapa komponen utama yang mampu mempertahankan sebagian besar variasi data. Selain meningkatkan efisiensi pengolahan data, PCA juga membantu memvisualisasikan pola penyebaran data sehingga hubungan antar citra bangunan dapat diamati dengan lebih jelas.

Selanjutnya, data hasil reduksi PCA digunakan dalam proses *clustering* untuk mengelompokkan bangunan berdasarkan kemiripan karakteristik teksturnya. Hasil pengelompokan menunjukkan bahwa citra bangunan dapat dipisahkan ke dalam beberapa kelompok yang memiliki pola tekstur serupa. Perbedaan pola tekstur tersebut mencerminkan tingkat kerusakan yang berbeda pada bangunan pascabencana. Dengan demikian, kombinasi LTEM dan PCA mampu memberikan representasi fitur yang cukup baik dalam mendukung proses pengelompokan tingkat kerusakan bangunan secara otomatis.

Hasil pengujian menunjukkan bahwa perubahan parameter energi pada LTEM memengaruhi kualitas pengelompokan data yang dihasilkan. Parameter dengan nilai yang lebih kecil mampu menghasilkan nilai *Silhouette Score* yang lebih tinggi dibandingkan parameter dengan nilai yang lebih besar. Hal ini menunjukkan bahwa peningkatan nilai energi tidak selalu menghasilkan kualitas *cluster* yang lebih baik. Parameter dengan nilai yang terlalu besar cenderung menghasilkan respons tekstur yang seragam sehingga perbedaan antar data menjadi kurang terlihat dan proses pemisahan *cluster* menjadi kurang optimal. Sebaliknya, parameter dengan nilai yang lebih kecil mampu menghasilkan variasi tekstur yang lebih jelas sehingga data dapat dikelompokkan dengan lebih baik. Oleh karena itu, pemilihan parameter yang

tepat sangat berpengaruh terhadap kemampuan LTEM dalam merepresentasikan karakteristik tekstur dan meningkatkan kualitas *clustering* tingkat kerusakan bangunan.

Secara keseluruhan, hasil penelitian menunjukkan bahwa LTEM efektif dalam menangkap karakteristik tekstur citra bangunan, sedangkan PCA mampu menyederhanakan data tanpa mengurangi informasi yang signifikan. Kombinasi kedua metode tersebut menghasilkan proses *clustering* yang lebih terstruktur sehingga dapat membantu proses identifikasi tingkat kerusakan bangunan pascabencana secara lebih objektif dan efisien.

4.4 Integrasi Islam

Integrasi antara perkembangan ilmu pengetahuan dan teknologi dengan nilai-nilai Islam menjadi sangat penting agar lahir penerus penelitian yang cerdas secara ilmiah, tetapi juga berakhlak mulia dan berpihak pada kemaslahatan manusia. Islam mendorong umatnya untuk mengembangkan ilmu pengetahuan dan memanfaatkannya demi kesejahteraan bersama, sebagaimana penelitian ini yang menggabungkan metode LTEM dan PCA untuk membantu mengidentifikasi kerusakan bangunan secara lebih cepat dan objektif.

Penelitian ini memiliki nilai penting yang tidak hanya dari sisi teknis, tetapi juga dari perspektif Islam. Dalam ajaran agama Islam, menjaga keselamatan jiwa (*ḥifẓ an-nafs*) dan harta (*ḥifẓ al-māl*) merupakan bagian dari *maqāṣid al-syarī'ah* (tujuan utama syariat). Allah telah mengingatkan manusia untuk selalu berhati-hati dan memperhatikan akibat dari setiap tindakan, sebagaimana firman-Nya Q.S. Al-Hashr ayat 18:

يَا أَيُّهَا الَّذِينَ آمَنُوا اتَّقُوا اللَّهَ وَلْتَنْظُرْ نَفْسٌ مَّا قَدَّمَتْ لِغَدٍ وَاتَّقُوا اللَّهَ ۚ إِنَّ اللَّهَ خَبِيرٌ بِمَا تَعْمَلُونَ

"Wahai orang-orang yang beriman! Bertakwalah kepada Allah dan hendaklah setiap diri memperhatikan apa yang telah diperbuatnya untuk hari esok; dan bertakwalah kepada Allah. Sungguh, Allah Maha Mengetahui apa yang kamu kerjakan" (QS Al-Hashr:18).

Ayat ini menegaskan pentingnya perencanaan dan antisipasi terhadap masa depan, termasuk dalam upaya untuk mitigasi risiko bencana. Dengan menggunakan teknologi analisis citra, kita bisa memetakan kerusakan dengan lebih akurat sehingga langkah perbaikan dapat dilakukan lebih cepat dan tepat sasaran.

Para ulama juga menekankan pentingnya menjaga kemaslahatan umum. Imam Al-Ghazali rahimahullāh berkata: "Menjaga kemaslahatan umat yang lebih diutamakan daripada kemaslahatan individu." Hal ini sejalan dengan tujuan pada penelitian ini, yakni memberikan kontribusi nyata dalam Upaya perlindungan Masyarakat luas dari adanya risiko keruntuhan bangunan dan membantu pemerintah dalam menentukan prioritas rekonstruksi pasca bencana alam.

Selain itu, dalam hadis Nabi Muhammad SAW disebutkan:

"Barang siapa yang memudahkan urusan seorang mukmin dari kesulitannya di dunia, niscaya Allah akan memudahkan urusannya di dunia dan akhirat." (HR. Muslim). Hadis ini memberikan motivasi spiritual bahwa adanya penelitian ini akan membantu meringankan beban Masyarakat dengan cara mempercepat proses identifikasi kerusakan dan mengurangi risiko bahaya yang merupakan amal saleh yang bernilai ibadah. Dengan demikian, penelitian ini tidak hanya bermanfaat secara akademis, tetapi juga menjadi bagian dari implementasi dari nilai-nilai Islam yang menekankan pentingnya keamanan, kemaslahatan, dan tanggung jawab.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat diperoleh kesimpulan sebagai berikut:

1. Metode *Law's Texture Energy Measures* (LTEM) terbukti dapat mengekstrak fitur tekstur pada citra bangunan dengan baik, sehingga perbedaan karakteristik antar citra dapat dikenali dan digunakan untuk membantu proses identifikasi tingkat kerusakan bangunan. Kemudian, penerapan *Principal Component Analysis* (PCA) berperan dalam mengurangi dimensi data hasil ekstraksi, sehingga data menjadi lebih sederhana, lebih mudah untuk divisualisasikan, serta lebih mudah dipahami dalam proses analisis.
2. Hasil evaluasi clustering menggunakan Silhouette Score menunjukkan bahwa jumlah cluster yang paling optimal adalah 2 cluster dengan nilai tertinggi sebesar 0,588535. Nilai tersebut menunjukkan bahwa pemisahan data pada skenario tersebut lebih baik dibandingkan penggunaan 3, 4, dan 5 cluster. Selain itu, pengujian variasi parameter energi menunjukkan bahwa parameter dengan nilai yang lebih kecil mampu menghasilkan nilai Silhouette Score yang lebih tinggi dibandingkan parameter yang lebih besar. Hal ini menunjukkan bahwa pemilihan parameter yang tepat berpengaruh terhadap kualitas pengelompokan data. Dengan demikian, kombinasi metode LTEM, PCA, dan clustering mampu

menghasilkan pengelompokan citra bangunan yang lebih terstruktur dan memberikan hasil evaluasi yang baik.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, penelitian selanjutnya disarankan untuk menggunakan jumlah data citra bangunan yang lebih banyak dan beragam agar proses pengelompokan dapat menghasilkan *cluster* yang lebih representatif terhadap berbagai tingkat kerusakan bangunan. Selain itu, variasi jumlah komponen utama pada metode *Principal Component Analysis* (PCA) dapat dieksplorasi lebih lanjut untuk mengetahui konfigurasi yang paling optimal dalam mempertahankan informasi penting dari data hasil ekstraksi fitur.

Penelitian berikutnya juga dapat membandingkan metode ekstraksi fitur maupun metode *clustering* lainnya untuk mengevaluasi performa sistem secara lebih komprehensif. Selain itu, pengujian pada dataset dengan karakteristik yang berbeda perlu dilakukan guna mengetahui tingkat konsistensi dan kemampuan generalisasi metode yang digunakan. Pengembangan sistem ke dalam bentuk aplikasi yang lebih interaktif juga dapat menjadi alternatif agar proses identifikasi dan analisis tingkat kerusakan bangunan dapat dilakukan secara lebih cepat, praktis, dan mudah digunakan oleh pihak terkait.

DAFTAR PUSTAKA

- Abedi, M., Shayanfar, J., & Al-Jabri, K. (2023). Infrastructure damage assessment via machine learning approaches: A systematic review. *Asian Journal of Civil Engineering*, 24(8), 3823–3852. <https://doi.org/10.1007/s42107-023-00748-5>
- Ahsina, N., Fatimah, F., & Rachmawati, F. (2022). ANALISIS SEGMENTASI PELANGGAN BANK BERDASARKAN PENGAMBILAN KREDIT DENGAN MENGGUNAKAN METODE K-MEANS CLUSTERING. *Jurnal Ilmiah Teknologi Infomasi Terapan*, 8(3). <https://doi.org/10.33197/jitter.vol8.iss3.2022.883>
- Almais, A. T. W., Susilo, A., Mujtaidah, 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., Parwatiningtyas, 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>
- Ariyanto, A. S. (2020). ANALISIS JENIS KERUSAKAN PADA BANGUNAN GEDUNG BERTINGKAT (Studi Kasus pada Gedung Apartemen dan Hotel Candiland Semarang). *Bangun Rekaprima*, 6(1), 45. <https://doi.org/10.32497/bangunrekaprima.v6i1.1929>
- Fadhila, K. I., Rofiq, S. A., Setiabudi, B., & Susanti, R. (2023). SISTEM DETEKTOR KERETAKAN SUATU BANGUNAN AKIBAT GEMPA DENGAN MENGGUNAKAN VIBRATION SENSOR. 28(2).
- Faroeq, D. A., Umar, R., & Riadi, I. (2020). Deteksi Keaslian Citra Menggunakan Metode Error Level Analysis (ELA) dan Principal Component Analysis (PCA). *Format: Jurnal Ilmiah Teknik Informatika*, 8(2), 132. <https://doi.org/10.22441/format.2019.v8.i2.006>
- Ganasala, P., & Prasad, A. D. (2020). Medical image fusion based on laws of texture energy measures in stationary wavelet transform domain. *International Journal of Imaging Systems and Technology*, 30(3), 544–557. <https://doi.org/10.1002/ima.22393>
- Gonzalez, R. C., Woods, R. E., & Masters, B. R. (2009). Digital Image Processing, Third Edition. *Journal of Biomedical Optics*, 14(2), 029901. <https://doi.org/10.1117/1.3115362>

- Iqbal, N., Mumtaz, R., Shafi, U., & Zaidi, S. M. H. (2021). Gray level co-occurrence matrix (GLCM) texture based crop classification using low altitude remote sensing platforms. *PeerJ Computer Science*, 7, e536. <https://doi.org/10.7717/peerj-cs.536>
- Jannah, M. Q., & Amalia, Z. (2024). *IMPLEMENTASI ALGORITMA CONVOLUTIONAL NEURAL NETWORK UNTUK IDENTIFIKASI TINGKAT KERUSAKAN STRUKTUR BANGUNAN PASCA GEMPA BUMI*. 6.
- Jellouli, A., El Harti, A., Adiri, Z., Chakouri, M., El Hachimi, J., & Bachaoui, E. M. (2021). Application of optical and radar satellite images for mapping tectonic lineaments in kerdous inlier of the Anti-Atlas belt, Morocco. *Remote Sensing Applications: Society and Environment*, 22, 100509. <https://doi.org/10.1016/j.rsase.2021.100509>
- Kamal, K., Qayyum, R., Mathavan, S., & Zafar, T. (2017). Wood defects classification using laws texture energy measures and supervised learning approach. *Advanced Engineering Informatics*, 34, 125–135. <https://doi.org/10.1016/j.aei.2017.09.007>
- Kvyetnyy, R., Sofina, O., Olesenko, A., Komada, P., Sikora, J., Kalizhanova, A., & Smailova, S. (2017). *Method of image texture segmentation using Laws' energy measures* (R. S. Romaniuk & M. Linczuk, Ed.; hlm. 1044561). <https://doi.org/10.1117/12.2280891>
- Luo, L., Feng, M. Q., & Wu, J. (2020). A comprehensive alleviation technique for optical-turbulence-induced errors in vision-based displacement measurement. *Structural Control and Health Monitoring*, 27(3). <https://doi.org/10.1002/stc.2496>
- Nhat-Duc, H., & Van-Duc, T. (2023). Comparison of histogram-based gradient boosting classification machine, random Forest, and deep convolutional neural network for pavement raveling severity classification. *Automation in Construction*, 148, 104767. <https://doi.org/10.1016/j.autcon.2023.104767>
- Nugraha, D. A., & Wiguna, A. S. (2020). SELEKSI FITUR WARNA CITRA DIGITAL BIJI KOPI MENGGUNAKAN METODE PRINCIPAL COMPONENT ANALYSIS. *RESEARCH: Computer, Information System & Technology Management*, 3(1), 24. <https://doi.org/10.25273/research.v3i1.5352>
- 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/jitcs.12270>
- 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>

Rohman Dijaya, & Dijaya, R. (2023). *Buku Ajar Pengolahan Citra Digital*. Umsida Press. <https://doi.org/10.21070/2023/978-623-464-075-5>

Rose, C. D., Aji, B. A. S., & Rahmanti, F. Z. (2024). Implementasi Aplikasi Web Pemilihan Kelas Berdasarkan Minat Menggunakan Algoritma K-Means Clustering. *Jurnal JTik (Jurnal Teknologi Informasi dan Komunikasi)*, 9(1), 270–276. <https://doi.org/10.35870/jtik.v9i1.3165>

Setiawan, A. S., Elysia, Wesley, J., & Purnama, Y. (2015). Mammogram Classification using Law's Texture Energy Measure and Neural Networks. *Procedia Computer Science*, 59, 92–97. <https://doi.org/10.1016/j.procs.2015.07.341>

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>

Tjen, J. (2022). Algoritma Pendeteksi Kerusakan Struktur Bangunan Berbasis Korelasi Jarak dan Metode Kuadrat Terkecil Parsial. *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, 8(3), 459. <https://doi.org/10.26418/jp.v8i3.56011>

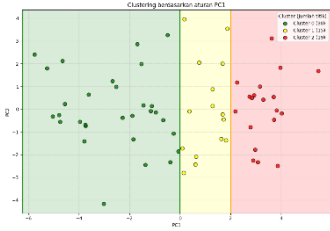







Wibowo, A., & Yulianto, Y. (2023). DETEKSI KERETAKAN JALAN ASPAL MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK. *JURNAL TEKNIK SIPIL CENDEKIA (JTSC)*, 4(2), 581–593. <https://doi.org/10.51988/jtsc.v4i2.132>








Yosia Galih Yudhistira, Albertus Joko Santoso, & Pranowo. (2022). Clustering untuk Efektivitas Promosi Produk Melalui Media Sosial pada UMKM Kota Yogyakarta Menggunakan Fuzzy C-Means. *Jurnal Informatika Atma Jogja*, 3(2), 141–148. <https://doi.org/10.24002/jiaj.v3i2.6788>









Yulisasih, B. N., Herman, H., Sunardi, S., & Yuliansyah, H. (2024). Evaluation of K-Means Clustering Using Silhouette Score Method on Customer Segmentation. *ILKOM Jurnal Ilmiah*, 16(3), 330–342. <https://doi.org/10.33096/ilkom.v16i3.2325.330-342>







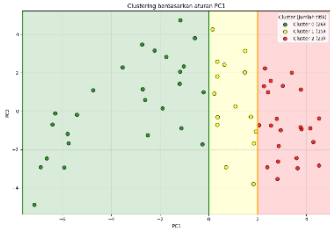

LAMPIRAN




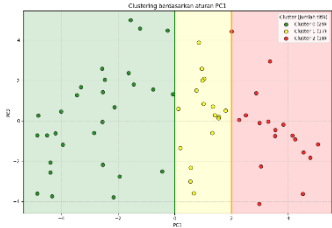





Lampiran 1 Hasil Dataset



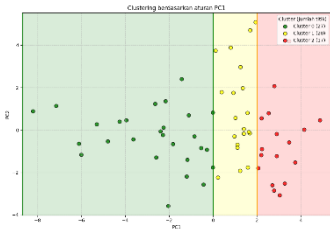

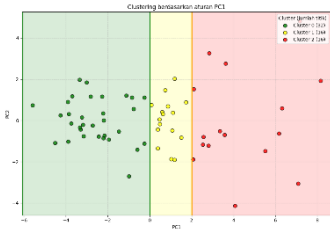

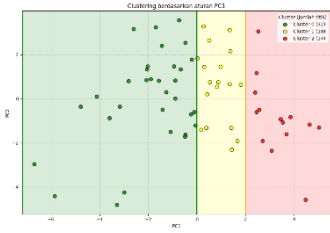

No	Citra Bangunan	Visualisasi		Silhoutte Score
		2D	3D	
1.				0.4863
2.				0.4723
3.				0.3817
4.				0.5150







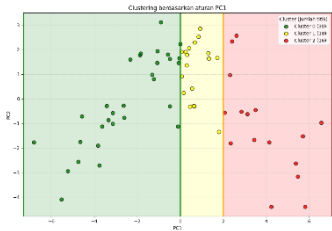

5.				0.5033
6.				0.4183
7.				0.5132
8.				0.3749





9.				0.3810
10.				0.4313
11.				0.3943
12.				0.4339

13.				0.4352
14.				0.4667
15.				0.5068
16.				0.4320

17.				0.3181
18.				0.5554
19.				0.4726
20.				0.5010

21.				0.4594
22.				0.4460
23.				0.4871
24.				0.4384

25.				0.4967
26.				0.4297
27.				0.4671
28.				0.3819

29.				0.3946
30.				0.5066