p-ISSN : 2406-7733
e-ISSN : 2597-9922

TREN DAN EVALUASI METODE *TEXTURE FEATURE EXTRACTION* PADA CITRA DIGITAL

Sinta Sulastri[1], Wulidah Kafah[2]
Informatika, Fakultas Teknik, Universitas Majalengka
Jl. KH. Abdul Halim No. 103, Majalengka Kulon, Kec. Majalengka, Kabupaten Majalengka, Jawa Barat 45418.
E-mail: @sintasulastri505@gmail.com[1], wulidahkafah@gmail.com[2]

Abstrak - Perkembangan teknologi analisis citra digital meningkatkan kebutuhan terhadap metode *texture feature extraction* untuk memperoleh karakteristik tekstur pada berbagai bidang, seperti citra medis, *remote sensing*, deteksi cacat industri, dan *image retrieval*. Perkembangan metode ekstraksi fitur tekstur menyebabkan perlunya kajian untuk memetakan tren penelitian, mengevaluasi performa metode, serta mengidentifikasi peluang pengembangan penelitian. Penelitian ini bertujuan menganalisis tren dan mengevaluasi kinerja metode texture *feature extraction* pada analisis citra digital menggunakan pendekatan *Systematic Literature Review* (SLR) berbasis *PRISMA* melalui tahapan identifikasi, penyaringan, evaluasi kelayakan, dan seleksi artikel. Sebanyak 45 artikel dari basis data *SCOPUS* dianalisis berdasarkan metode yang digunakan, bidang penerapan, parameter evaluasi, dan performa metode. Hasil penelitian menunjukkan bahwa metode *Gray Level Co-occurrence Matrix* (GLCM) dan *Local Binary Pattern* (LBP) masih banyak digunakan karena kompleksitas komputasi yang rendah dan performa yang baik pada dataset tertentu. Selain itu, metode berbasis *deep learning*, khususnya *Convolutional Neural Network* (CNN), menunjukkan tren peningkatan karena mampu melakukan ekstraksi fitur otomatis dengan tingkat akurasi lebih tinggi. Penelitian ini menyimpulkan bahwa integrasi metode konvensional dan *deep learning* menjadi arah pengembangan yang potensial untuk meningkatkan performa analisis citra digital.

Kata Kunci: analisis citra digital, *deep learning*, *systematic literature review*, *texture feature extraction*, tren penelitian

I. PENDAHULUAN

Teknologi pengolahan citra digital (*digital image processing*) berkembang pesat dan banyak dimanfaatkan dalam *computer vision*, kecerdasan buatan (*artificial intelligence*), serta analisis data visual. Salah satu proses penting dalam analisis citra digital adalah *texture feature extraction*, yaitu teknik untuk mengekstraksi karakteristik tekstur citra yang digunakan pada klasifikasi, segmentasi, deteksi objek, dan pengenalan pola (Gonzalez & Woods, 2018; Szeliski, 2022). Informasi tekstur berperan penting dalam merepresentasikan pola permukaan dan karakteristik objek sehingga banyak diterapkan pada citra medis, *remote sensing*, deteksi cacat industri*, image retrieval*, dan klasifikasi citra satelit (Tuceryan & Jain, 1998; Humeau-Heurtier, 2019).

Perkembangan metode ekstraksi fitur tekstur mengalami perubahan signifikan, mulai dari metode konvensional seperti *Gray Level Co-occurrence Matrix* (GLCM), *Local Binary Pattern* (LBP), dan *Histogram of Oriented Gradients* (HOG), hingga metode berbasis deep learning seperti *Convolutional Neural Network* (CNN), *Vision Transformer* (ViT), dan metode *hybrid* (Liu et al., 2019; Ojala et al., 2002). Metode konvensional memiliki kompleksitas komputasi rendah dan implementasi sederhana, namun masih terbatas dalam menangani tekstur kompleks, perubahan pencahayaan, dan noise. Sebaliknya, metode *deep learning* mampu melakukan ekstraksi fitur otomatis dengan performa lebih tinggi, tetapi membutuhkan dataset besar dan sumber daya komputasi tinggi (LeCun et al., 2015; Litjens et al., 2017). Beberapa penelitian menunjukkan perkembangan metode *texture feature extraction* menuju *multi-scale feature extraction*, *attention mechanism*, dan *transfer learning* untuk meningkatkan performa analisis citra digital. Namun, penelitian sebelumnya umumnya berfokus pada pengembangan metode tertentu tanpa memberikan gambaran menyeluruh mengenai tren perkembangan, evaluasi performa, serta peluang penelitian pada berbagai bidang penerapan. Selain itu, masih terdapat tantangan seperti sensitivitas terhadap noise dan pencahayaan, tingginya kompleksitas komputasi, serta belum adanya standar *dataset* dan parameter evaluasi yang seragam (LeCun et al., 2015; Liu et al., 2019).

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk menganalisis tren perkembangan metode *texture feature extraction*, mengevaluasi performanya pada berbagai bidang analisis citra digital, serta mengidentifikasi tantangan dan peluang penelitian di masa mendatang menggunakan pendekatan *Systematic Literature Review* (SLR) berbasis PRISMA.

II. TINJAUAN PUSTAKA

Penelitian mengenai *texture feature extraction* pada analisis citra digital telah berkembang pesat dan diterapkan pada berbagai bidang, seperti citra medis, *remote sensing*, deteksi cacat industri, dan *image retrieval*. Beberapa penelitian menunjukkan

p-ISSN : 2406-7733
e-ISSN : 2597-9922

bahwa metode konvensional, seperti *Gray Level Co-occurrence Matrix* (GLCM), *Local Binary Pattern* (LBP), dan *Histogram of Oriented Gradients* (HOG), masih banyak digunakan karena memiliki kompleksitas komputasi yang relatif rendah dan efektif pada dataset berukuran kecil hingga menengah (Dong et al., 2025; Li et al., 2025). Seiring perkembangan teknologi, metode berbasis *deep learning*, seperti *Convolutional Neural Network* (CNN) dan *Vision Transformer* (ViT), mulai banyak digunakan karena mampu melakukan ekstraksi fitur secara otomatis dengan tingkat akurasi yang lebih tinggi (Lahraichi et al., 2025; Lu et al., 2025). Selain itu, beberapa penelitian juga mengembangkan metode *hybrid* yang menggabungkan pendekatan konvensional dan *deep learning* untuk meningkatkan representasi fitur tekstur dan mengatasi keterbatasan metode tunggal (Page et al., 2021; Kitchenham & Charters, 2007).

Meskipun penelitian mengenai *texture feature extraction* terus berkembang, sebagian besar penelitian sebelumnya masih berfokus pada pengembangan metode tertentu pada domain aplikasi yang spesifik sehingga belum memberikan gambaran menyeluruh mengenai tren perkembangan metode, bidang penerapan dominan, serta evaluasi performa antar metode pada berbagai konteks analisis citra digital. Selain itu, masih terdapat tantangan seperti sensitivitas terhadap *noise* dan pencahayaan, tingginya kompleksitas komputasi, serta belum adanya standar evaluasi yang seragam (Haralick et al., 1973).

Berdasarkan kondisi tersebut, penelitian ini menggunakan pendekatan *Systematic Literature Review* (SLR) berbasis PRISMA untuk memberikan pemetaan yang lebih komprehensif mengenai perkembangan metode *texture feature extraction*. Kebaruan penelitian ini terletak pada analisis terintegrasi terhadap tren penelitian, performa metode, bidang aplikasi dominan, serta identifikasi *research gap* sebagai dasar rekomendasi pengembangan penelitian selanjutnya.

III. METODE PENELITIAN

Penelitian ini menggunakan metode *Systematic Literature Review* (SLR) dengan pendekatan PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses)* untuk menganalisis tren perkembangan, evaluasi kinerja, serta arah penelitian metode *texture feature extraction* pada analisis citra digital. Pendekatan ini digunakan untuk memperoleh kajian yang sistematis, terstruktur, dan transparan melalui proses identifikasi, seleksi, hingga analisis artikel ilmiah (Page et al., 2021). Tahapan penelitian pada studi ini ditunjukkan pada Gambar 1.



Gambar 1. *Flowchart* Tahapan Penelitian

A. *Research Question*

Secara khusus, penelitian ini dirancang untuk menjawab lima *Research Questions (RQ)* berikut:
RQ1: Metode *texture feature extraction* apa yang paling banyak digunakan pada penelitian analisis citra digital?
RQ2: Bagaimana tren perkembangan penelitian metode *texture feature extraction* berdasarkan publikasi artikel yang dianalisis?
RQ3: Bidang aplikasi apa yang paling banyak menerapkan metode *texture feature extraction* pada analisis citra digital?
RQ4: Bagaimana performa metode *texture feature extraction* berdasarkan parameter evaluasi yang digunakan pada penelitian sebelumnya?
RQ5: Apa saja kelebihan, keterbatasan, dan *research gap* dari masing-masing metode *texture feature extraction* pada penelitian sebelumnya?

B. *Search Process*

Tahap *search process* dilakukan untuk memperoleh artikel ilmiah yang relevan terkait *texture feature extraction* pada analisis citra digital. Pencarian literatur dilakukan melalui database SCOPUS sebagai sumber utama artikel ilmiah karena memiliki cakupan luas pada bidang *computer vision*, *image processing*, dan *artificial intelligence*. Proses pencarian menggunakan kata kunci seperti *texture feature extraction*, *texture analysis*, *digital image analysis*, *feature extraction*, dan *computer vision*. Artikel yang dipilih merupakan jurnal dan prosiding konferensi pada rentang tahun 2017–2025. Pada tahap awal diperoleh sebanyak 1.292 artikel yang selanjutnya diproses melalui tahapan seleksi berbasis PRISMA (Page et al., 2021).

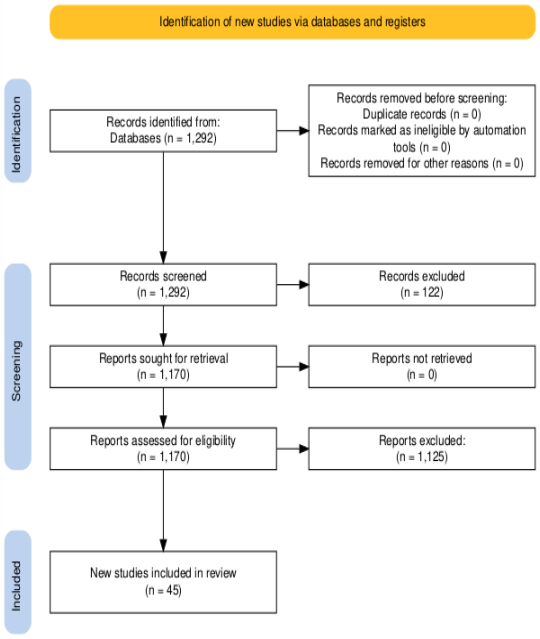
C. *Inclusion and Exclusion*

Tahap *inclusion and exclusion* dilakukan melalui proses *screening* dan seleksi artikel berdasarkan kriteria inklusi dan eksklusi untuk memastikan kualitas serta relevansi artikel terhadap tujuan penelitian. Proses *screening* dilakukan dengan meninjau judul, abstrak, kata kunci, dan isi artikel untuk memastikan keterkaitan dengan metode *texture feature extraction*. Artikel duplikat, tidak relevan, atau tidak membahas ekstraksi fitur tekstur secara spesifik dieliminasi dari proses seleksi.

Berdasarkan identifikasi awal diperoleh 1.292 artikel, kemudian 122 artikel dieliminasi karena tidak sesuai dengan topik penelitian. Selanjutnya, sebanyak 1.170 artikel masuk ke tahap evaluasi *full text*. Hasil evaluasi menunjukkan 1.125 artikel dikeluarkan karena tidak memenuhi kriteria, seperti

p-ISSN : 2406-7733
e-ISSN : 2597-9922

tidak membahas ekstraksi fitur tekstur secara spesifik atau tidak memiliki evaluasi metode yang jelas. Setelah proses seleksi, diperoleh 45 artikel utama yang digunakan dalam penelitian. Diagram seleksi artikel berbasis *PRISMA* ditunjukkan pada Gambar 2 (Page et al., 2021).



Gambar 2. Diagram PRISMA.

Untuk memastikan kualitas dan relevansi artikel yang digunakan, penelitian ini menerapkan kriteria inklusi dan eksklusi sebagaimana ditunjukkan pada Tabel 1.

Tabel 1. Kriteria Inklusi dan Eksklusi Penelitian

Kriteria Inklusi	Kriteria Eksklusi
Artikel membahas metode *texture feature extraction*	Artikel tidak relevan dengan *texture analysis*
Menggunakan dataset citra digital	Artikel hanya membahas pengolahan citra secara umum
Dipublikasikan pada jurnal atau konferensi ilmiah terindeks	Artikel tidak memiliki evaluasi metode
Publikasi tahun 2017–2025	Artikel duplikat
Artikel tersedia dalam bentuk *full text*	Artikel tidak dapat diakses secara lengkap

Artikel yang memenuhi kriteria inklusi selanjutnya digunakan dalam proses ekstraksi data dan analisis metode *texture feature extraction*.

D. *Quality Assessment*

Tahap *quality assessment* dilakukan untuk menilai kualitas artikel yang telah lolos proses seleksi. Penilaian dilakukan berdasarkan kesesuaian topik penelitian, kejelasan metodologi, kelengkapan evaluasi metode, serta relevansi hasil penelitian terhadap tujuan penelitian. Tahap ini bertujuan memastikan artikel yang digunakan memiliki kualitas ilmiah yang memadai sehingga hasil analisis dapat dilakukan secara lebih objektif dan sistematis.

E. *Data Extraction*

Tahap *data extraction* dilakukan terhadap 45 artikel terpilih dengan mengumpulkan informasi penting yang berkaitan dengan penelitian. Informasi yang diekstraksi meliputi metode *texture feature extraction* yang digunakan, jenis dataset citra, bidang penerapan, parameter evaluasi, serta kontribusi penelitian yang ditawarkan. Bidang penerapan yang dianalisis mencakup citra medis, *remote sensing*, deteksi objek, *surface defect detection*, *image retrieval*, dan klasifikasi citra digital.

Informasi yang diekstraksi dari artikel terpilih meliputi metode *texture feature extraction*, jenis dataset citra, bidang penerapan, parameter evaluasi, serta kontribusi penelitian. Ringkasan aspek analisis artikel yang digunakan dalam penelitian ini ditunjukkan pada Tabel 2.

Tabel 2. Aspek Analisis Artikel Penelitian

Aspek Analisis	Deskripsi
Metode	Teknik *texture feature extraction* yang digunakan
Dataset	Jenis dataset citra yang digunakan
Bidang penerapan	Domain penggunaan metode
Parameter evaluasi	Akurasi, presisi, *robustness*, kompleksitas komputasi, dan metrik lainnya
Kontribusi penelitian	Inovasi atau pengembangan metode yang ditawarkan

Berdasarkan aspek analisis tersebut, dilakukan proses ekstraksi data terhadap 45 artikel yang lolos seleksi PRISMA. Hasil ekstraksi data digunakan untuk mengidentifikasi metode texture feature extraction, bidang penerapan, tren penelitian, serta temuan utama pada masing-masing penelitian. Ringkasan hasil mapping artikel penelitian ditunjukkan pada Tabel 3.

Tabel 3. Ekstraksi Data Artikel

No	Penulis/ Tahun	Metode	Bidang Penerapan	Temuan Utama
1	Alhassan et al. (2022)	*Shape Index, Texture Feature*	Klasifikasi Tekstur	Metode meningkatkan akurasi klasifikasi tekstur multi-arah.

p-ISSN : 2406-7733
e-ISSN : 2597-9922

No	Penulis/ Tahun	Metode	Bidang Penerapan	Temuan Utama
2	Liu et al. (2024)	*Improved SIFT*	Analisis Citra Digital	Meningkatkan kecepatan dan akurasi *image stitching*.
3	Bai et al. (2021)	*Adversarial Shape Learning*	*Remote Sensing*	Memberikan segmentasi objek yang lebih akurat.
4	Chen et al. (2025)	*Dynamic Texture Feature*	*Surface Defect Detection*	Meningkatkan deteksi cacat tekstur kain.
5	Kim et al. (2024)	*Texture Feature Fusion*	*Image Retrieval*	Meningkatkan performa *retrieval* citra.
6	Dong et al. (2025)	*Wavelet Convolution*	Klasifikasi Citra	Pendekatan *multi-scale* meningkatkan akurasi klasifikasi.
7	Li et al. (2025)	*Improved Feature Extraction*	Analisis Tekstur	Strategi dua tahap meningkatkan performa ekstraksi fitur.
8	Lahraichi et al. (2025)	*Vision Transformer (ViT)*	Deteksi Anomali	ViT efektif pada tekstur kompleks.
9	Li et al. (2024)	*Autoencoder Feature Extraction*	Klasifikasi Tekstur	*Autoencoder* meningkatkan representasi fitur tekstur.
10	Li et al. (2025)	*Wavelet-based Texture Mining*	Analisis Biometrik	Meningkatkan deteksi manipulasi wajah.
11	Li et al. (2023)	*Diffusion-based Compression*	Analisis Citra	Mendukung kompresi fitur secara *scalable*.
12	Li et al. (2018)	*Statistical Texture Model*	*Remote Sensing*	Meningkatkan *retrieval* citra satelit.
13	Litjens et al. (2017)	*CNN-based Feature Extraction*	Citra Medis	CNN menunjukkan performa tinggi pada citra medis.
14	Liu et al. (2019)	*Bag of Words, CNN*	Klasifikasi Tekstur	CNN mendominasi perkembangan *texture representation*.
15	Lu et al. (2025)	*YOLOv8 dan Texture Feature*	Deteksi Objek	Memberikan akurasi tinggi pada *multi-scale object detection*.
16	Mishra & Silakari (2021)	*Texture Feature Retrieval*	*Image Retrieval*	*Texture feature* efektif pada *retrieval* citra.
17	Mohanaiah et al. (2014)	*Texture-based Classification*	Citra Medis	Tekstur membantu klasifikasi lesi hati.
18	Ojala et al. (2002)	*Local Binary Pattern (LBP)*	Klasifikasi Tekstur	LBP efektif pada pola tekstur lokal.
19	Reddy & Kumar (2020)	*GLCM dan PCA*	Citra Medis	GLCM meningkatkan ekstraksi fitur citra medis.
20	Singh et al. (2024)	*Extended Binary Pattern*	Klasifikasi Tekstur	Memberikan *robustness* lebih baik terhadap variasi tekstur.
21	Wang et al. (2020)	*Statistical & Local Pattern Feature*	*Image Retrieval*	Kombinasi fitur meningkatkan performa *retrieval*.
22	Wang et al. (2025)	*Rotation-equivariant Feature Extraction*	Analisis Tekstur	Robust terhadap rotasi tekstur.

p-ISSN : 2406-7733
e-ISSN : 2597-9922

No	Penulis/ Tahun	Metode	Bidang Penerapan	Temuan Utama
23	Zhang et al. (2024)	*LT-LBP dan Deep Learning*	Citra Medis	Kombinasi LBP dan *deep learning* meningkatkan akurasi.
24	Zhou et al. (2022)	*MSCNet Texture Enhancement*	*Surface Defect Detection*	*Texture enhancement* meningkatkan deteksi retakan.
25	Zhang et al. (2017)	*GLCM Fusion Algorithm*	*Remote Sensing*	Efektif untuk ekstraksi tekstur citra satelit.
26	Zhao et al. (2019)	*Adaptive LBP*	Klasifikasi Tekstur	Adaptif terhadap variasi tekstur.
27	Humeau-Heurtier (2019)	*Survey Texture Extraction*	Analisis Tekstur	Menjelaskan perkembangan metode *texture extraction*.
28	Karthikeyan & Poongodi (2018)	*GLCM, LBP, GLRLM*	Citra Medis	Kombinasi metode meningkatkan klasifikasi citra.
29	Kiani (2022)	*Texture Classification Review*	Analisis Tekstur	Menunjukkan tren penelitian *texture classification*.
30	Kumar & Singh (2021)	*Review Feature Extraction*	Analisis Tekstur	Membahas perkembangan metode *texture extraction*.
31	Alhichri et al. (2021)	*Deep Learning & Entropy Texture*	Klasifikasi Citra	Kombinasi entropy dan CNN meningkatkan performa klasifikasi.
32	Chen & Li (2008)	*Wavelet Transformation*	Klasifikasi Tekstur	*Wavelet* efektif pada tekstur multi-skala.
33	Chen et al. (2024)	*Multi-wavelet dan Autoencoder*	Surface Defect Detection	Meningkatkan akurasi klasifikasi cacat baja.
34	Do & Vetterli (2010)	*Statistical Wavelet Modeling*	Image Retrieval	Meningkatkan diskriminasi fitur tekstur.
35	Farella et al. (2020)	*Texture-based Image Analysis*	Analisis Citra Digital	Mendukung digitalisasi objek *heritage*.
36	Gletsos et al. (2007)	*Texture Feature & Ensemble Classifier*	Citra Medis	*Texture feature* efektif untuk diagnosis lesi hati.
37	Gonzalez & Woods (2018)	*Pengolahan Citra Digital*	Analisis Citra Digital	Menjadi dasar teori *texture feature extraction*.
38	Haralick et al. (1973)	*Gray Level Co-occurrence Matrix (GLCM)*	Analisis Tekstur	Menjadi dasar pengembangan metode GLCM.
39	Kitchenham & Charters (2007)	*Systematic Literature Review*	Metodologi Penelitian	Menjadi acuan metode SLR.
40	Lazebnik et al. (2012)	*Patch-based Texture Sampling*	Klasifikasi Tekstur	Sampling patch meningkatkan klasifikasi tekstur.
41	LeCun et al. (2015)	*Convolutional Neural Network (CNN)*	*Artificial Intelligence*	CNN mendukung *automatic feature learning*.
42	Paragios & Deriche (2008)	*Generative Texture Model*	Segmentasi Citra	Segmentasi tekstur menjadi lebih adaptif.
43	Szeliski (2022)	*Computer Vision Feature Analysis*	Analisis Citra Digital	Menjadi referensi utama *computer vision* modern.
44	Tuceryan & Jain (1998)	*Texture Analysis*	Analisis Tekstur	Menjadi dasar teori

p-ISSN : 2406-7733
e-ISSN : 2597-9922

No	Penulis/ Tahun	Metode	Bidang Penerapan	Temuan Utama
		Framework		*texture analysis*.
45	Wouwer et al. (2006)	*Wavelet Gaussian Distribution*	*Image Retrieval*	*Wavelet* meningkatkan *discriminative feature* tekstur.

F. *Analysis*

Tahap *analysis* dilakukan dengan mengelompokkan metode berdasarkan karakteristik algoritma, pendekatan ekstraksi fitur, bidang penerapan, serta parameter evaluasi yang digunakan. Metode yang dianalisis mencakup pendekatan konvensional seperti *Gray Level Co-occurrence Matrix* (GLCM), *Local Binary Pattern* (LBP), *Histogram of Oriented Gradients* (HOG), dan *wavelet transform*, serta metode berbasis *deep learning* seperti *Convolutional Neural Network* (CNN), *Vision Transformer* (ViT), *attention mechanism*, dan metode *hybrid* (*Humeau-Heurtier*, 2019; Liu et al., 2019). Analisis dilakukan untuk mengidentifikasi tren perkembangan metode, performa, serta efektivitas penerapan pada berbagai konteks analisis citra digital.

G. *Result*

Tahap terakhir adalah *result*, yaitu penyajian hasil analisis penelitian untuk mengevaluasi performa metode *texture feature extraction* berdasarkan parameter seperti akurasi, sensitivitas terhadap *noise*, kompleksitas komputasi, efisiensi ekstraksi fitur, dan kemampuan generalisasi model pada berbagai dataset citra digital. Selain itu, dilakukan identifikasi *research gap* berdasarkan tantangan yang masih ditemukan, seperti sensitivitas terhadap *noise*, kebutuhan dataset besar pada metode *deep learning*, tingginya kompleksitas komputasi, serta belum adanya standar dataset dan evaluasi yang seragam. Hasil evaluasi ini digunakan sebagai dasar dalam menganalisis tren perkembangan penelitian serta peluang pengembangan metode *texture feature extraction* di masa mendatang.

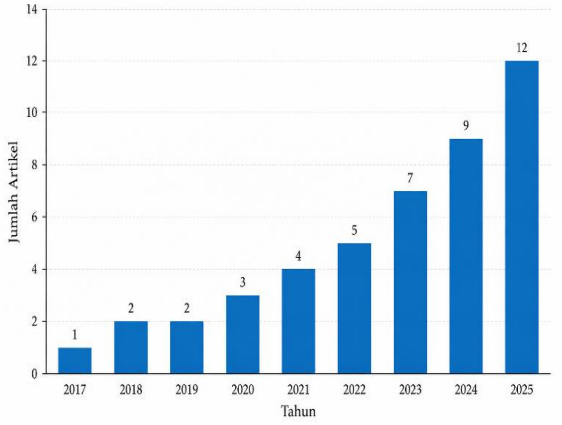
IV. HASIL DAN PEMBAHASAN

Bagian ini memaparkan hasil analisis terhadap 45 artikel penelitian yang telah lolos proses seleksi berdasarkan metode PRISMA. Analisis dilakukan untuk mengidentifikasi perkembangan metode *texture feature extraction*, tren penelitian, bidang penerapan, performa metode, serta berbagai tantangan dan *research gap* pada penelitian analisis citra digital (Liu et al., 2024).

Hasil penelitian disusun berdasarkan *Research Question* (RQ) yang telah dirumuskan sebelumnya dan disajikan dalam bentuk tabel serta penjelasan deskriptif untuk mempermudah interpretasi hasil (Page et al., 2021).

A. Karakteristik Artikel Penelitian

Berdasarkan proses seleksi PRISMA, diperoleh 45 artikel penelitian yang dianalisis berdasarkan tahun publikasi, metode *texture feature extraction*, dan bidang penerapan. Hasil analisis menunjukkan bahwa penelitian terkait *texture feature extraction* mengalami peningkatan dalam beberapa tahun terakhir, terutama sejak berkembangnya metode berbasis *deep learning* (*Humeau-Heurtier*, 2019; Liu et al., 2019). Distribusi publikasi artikel berdasarkan artikel yang dianalisis ditunjukkan pada Gambar 3.



Gambar 3. Distribusi publikasi artikel berdasarkan tahun.

Berdasarkan Gambar 3, jumlah publikasi penelitian terkait *texture feature extraction* menunjukkan tren peningkatan dari tahun ke tahun. Peningkatan tertinggi terjadi pada periode 2023–2025, yang menunjukkan bahwa topik ekstraksi fitur tekstur masih aktif dikembangkan, khususnya pada analisis citra digital berbasis *deep learning* (Liu et al., 2019).

Selain berdasarkan tahun publikasi, artikel juga dianalisis berdasarkan bidang penerapan. Hasil analisis menunjukkan bahwa citra medis menjadi bidang yang paling banyak menerapkan metode *texture feature extraction*. Distribusi bidang penerapan ditunjukkan pada Tabel 4.

Tabel 4. Distribusi Bidang Penerapan *Texture Feature Extraction*.

Bidang Penerapan	Jumlah Artikel
Citra medis	12
Remote sensing	8
Surface defect detection	7
Image retrieval	6
Deteksi objek	5

p-ISSN : 2406-7733
e-ISSN : 2597-9922

Bidang Penerapan	Jumlah Artikel
Klasifikasi citra umum	4
Analisis biometrik	3

Berdasarkan Tabel 4, bidang citra medis menjadi domain penelitian yang paling dominan. Hal ini menunjukkan bahwa karakteristik tekstur memiliki peran penting dalam membantu proses klasifikasi dan identifikasi objek pada citra medis (Litjens et al., 2017).

B. Pembahasan Berdasarkan *Research Questions*

RQ1 : Metode *texture feature extraction* apa yang paling banyak digunakan pada penelitian analisis citra digital?

Berdasarkan hasil analisis terhadap 45 artikel, metode berbasis *deep learning* menjadi pendekatan yang paling banyak digunakan pada penelitian terbaru. Metode seperti CNN, Vision Transformer (ViT), dan metode *hybrid* mendominasi karena mampu melakukan ekstraksi fitur otomatis dan menghasilkan performa tinggi (LeCun et al., 2015; Liu et al., 2019). Di sisi lain, metode konvensional seperti GLCM, LBP, dan HOG masih digunakan karena memiliki kompleksitas komputasi rendah dan lebih mudah diterapkan pada dataset berukuran kecil (Humeau-Heurtier, 2019). Distribusi metode *texture feature extraction* ditunjukkan pada Tabel 5.

Tabel 5. Distribusi Metode *Texture Feature Extraction*.

Metode	Jumlah Artikel
CNN dan *deep learning*	16
Metode *hybrid*	10
GLCM	6
LBP	5
Wavelet transform	4
HOG	2
Vision Transformer (ViT)	2

Berdasarkan Tabel 5, metode berbasis *deep learning* mendominasi penelitian *texture feature extraction* pada analisis citra digital. Hal tersebut menunjukkan adanya pergeseran pendekatan penelitian dari metode konvensional menuju metode pembelajaran mendalam yang lebih adaptif terhadap kompleksitas tekstur citra digital (Liu et al., 2019).

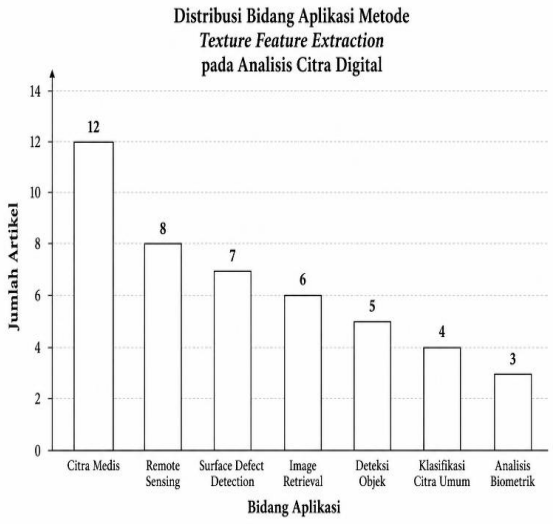
RQ2: Bagaimana tren perkembangan penelitian metode *texture feature extraction* berdasarkan publikasi artikel yang dianalisis?

Hasil analisis menunjukkan bahwa penelitian awal masih didominasi metode konvensional seperti GLCM, LBP, dan HOG karena kompleksitas komputasi yang rendah dan implementasi yang sederhana (Humeau-Heurtier, 2019). Namun, perkembangan teknologi kecerdasan buatan mendorong pergeseran menuju metode berbasis *deep learning* seperti CNN, ViT, dan metode *hybrid* yang mampu melakukan ekstraksi fitur otomatis dan memberikan performa lebih baik pada tekstur kompleks (LeCun et al., 2015; Liu et al., 2019). Selain itu, penelitian terbaru mulai mengembangkan pendekatan berbasis *attention mechanism*, *multi-scale feature extraction*, serta kombinasi metode konvensional dan *deep learning* untuk meningkatkan akurasi dan stabilitas model.

Arah perkembangan penelitian saat ini cenderung berfokus pada metode yang lebih adaptif, efisien, dan mampu menangani kompleksitas data citra digital yang semakin tinggi. Pergeseran menuju metode berbasis *deep learning* menunjukkan meningkatnya kebutuhan terhadap ekstraksi fitur otomatis (LeCun et al., 2015; Liu et al., 2019).

RQ3: Bidang aplikasi apa yang paling banyak menerapkan metode *texture feature extraction* pada analisis citra digital?

Metode *texture feature extraction* diterapkan pada berbagai bidang analisis citra digital, dengan citra medis sebagai bidang yang paling dominan, diikuti *remote sensing*, *surface defect detection*, dan *image retrieval* (Litjens et al., 2017). Dominasi citra medis menunjukkan bahwa informasi tekstur berperan penting dalam klasifikasi penyakit, deteksi tumor, analisis radiologi, dan identifikasi kelainan jaringan. Pada bidang *remote sensing*, metode ini digunakan untuk klasifikasi citra satelit, identifikasi objek berbasis citra udara, dan analisis lingkungan (Humeau-Heurtier, 2019). Selain itu, metode *texture feature extraction* juga diterapkan pada *surface defect detection* untuk mendeteksi cacat material industri dan pada *image retrieval* untuk meningkatkan pencarian citra berdasarkan karakteristik visual tertentu. Distribusi bidang aplikasi ditunjukkan pada Gambar 4.



Gambar 4. Distribusi Bidang Aplikasi.

p-ISSN : 2406-7733
e-ISSN : 2597-9922

Berdasarkan Gambar 5, bidang citra medis menjadi domain yang paling dominan dalam penerapan *texture feature extraction*. Hal ini menunjukkan bahwa karakteristik tekstur memiliki pengaruh besar dalam mendukung analisis dan pengambilan keputusan pada sistem berbasis kecerdasan buatan (Litjens et al., 2017).

RQ4: Bagaimana performa metode *texture feature extraction* berdasarkan parameter evaluasi yang digunakan pada penelitian sebelumnya?

Berdasarkan hasil analisis terhadap 45 artikel penelitian yang diperoleh dari proses seleksi PRISMA, ditemukan bahwa evaluasi performa metode *texture feature extraction* dilakukan menggunakan beberapa parameter pengukuran yang berbeda, bergantung pada tujuan penelitian, jenis dataset, dan domain aplikasi. Parameter evaluasi yang paling sering digunakan meliputi *accuracy, precision, recall, F1-score, specificity*, AUC, serta efisiensi komputasi. Hasil analisis menunjukkan bahwa *accuracy* menjadi parameter evaluasi yang paling dominan digunakan pada penelitian *texture feature extraction*, khususnya pada penelitian klasifikasi citra medis, *remote sensing*, dan deteksi cacat industri. Hal ini menunjukkan bahwa sebagian besar penelitian berfokus pada kemampuan metode dalam membedakan karakteristik tekstur antar kelas citra secara tepat.

Selain *accuracy*, beberapa penelitian juga menggunakan *precision, recall*, dan *F1-score* untuk mengevaluasi kestabilan model klasifikasi, terutama pada *dataset* yang memiliki distribusi kelas tidak seimbang. Pada penelitian berbasis citra medis, penggunaan metrik evaluasi tambahan seperti specificity dan sensitivity juga cukup sering ditemukan untuk mengukur kemampuan sistem dalam mendeteksi objek abnormal secara lebih akurat.

Berdasarkan hasil kajian artikel, metode berbasis *deep learning*, khususnya *Convolutional Neural Network* (CNN), menunjukkan kecenderungan performa yang lebih baik dibandingkan metode konvensional pada citra dengan kompleksitas tekstur tinggi. Kemampuan CNN dalam melakukan *automatic feature learning* memungkinkan proses ekstraksi fitur berlangsung tanpa memerlukan perancangan fitur manual, sehingga menghasilkan representasi tekstur yang lebih optimal.

Di sisi lain, metode konvensional seperti *Gray Level Co-occurrence Matrix* (GLCM) dan Local Binary Pattern (LBP) masih menunjukkan performa yang kompetitif pada dataset berukuran kecil hingga menengah. Metode GLCM diketahui efektif dalam menangkap hubungan spasial antar piksel, sedangkan LBP memiliki keunggulan dalam mendeteksi pola tekstur lokal dengan kompleksitas komputasi yang lebih rendah.

Tabel 6. Evaluasi Performa Metode *Texture Feature Extraction*.

Metode	Parameter Evaluasi Dominan	Temuan Performa
GLCM	*Accuracy, Precision*	Baik pada tekstur terstruktur, sensitif terhadap noise dan pencahayaan
LBP	*Accuracy, Recall*	Efektif untuk pola tekstur lokal dan komputasi ringan
Wavelet-based	*Accuracy, Robustness*	Mampu menangkap tekstur multi-skala
CNN / Deep Learning	*Accuracy, F1-score*, AUC	Performa tinggi pada citra kompleks
Hybrid Method	*Accuracy, Precision, Recall*	Memberikan representasi fitur yang lebih stabil

Berdasarkan hasil evaluasi tersebut, dapat disimpulkan bahwa metode berbasis CNN dan *hybrid feature extraction* menunjukkan kecenderungan performa terbaik pada berbagai penelitian, terutama pada klasifikasi citra dengan pola tekstur kompleks. Namun demikian, metode tersebut memerlukan sumber daya komputasi yang lebih tinggi dan dataset pelatihan dalam jumlah besar. Oleh karena itu, pemilihan metode *texture feature extraction* perlu mempertimbangkan karakteristik data, kebutuhan penelitian, serta kapasitas komputasi yang tersedia.

RQ5: Apa saja kelebihan, keterbatasan, dan *research gap* dari masing-masing metode *texture feature extraction* pada penelitian sebelumnya?

Berdasarkan analisis terhadap 45 artikel, ditemukan bahwa setiap metode *texture feature extraction* memiliki kelebihan dan keterbatasan yang dipengaruhi oleh jenis citra, kompleksitas tekstur, ukuran dataset, dan tujuan penelitian. Secara umum, penelitian menunjukkan adanya pergeseran dari metode konvensional menuju pendekatan berbasis *deep learning* dan metode *hybrid* untuk meningkatkan performa ekstraksi fitur (LeCun et al., 2015; Liu et al., 2019). Metode konvensional seperti *Gray Level Co-occurrence Matrix* (GLCM) masih banyak digunakan karena mampu merepresentasikan hubungan spasial antar piksel dengan kompleksitas komputasi rendah. Metode ini efektif pada citra medis dan tekstur terstruktur, tetapi sensitif terhadap perubahan pencahayaan, rotasi, dan *noise* (Bai et al., 2021). Metode *Local Binary Pattern* (LBP) unggul dalam ekstraksi pola tekstur lokal dengan implementasi sederhana dan efektif pada *dataset* kecil hingga menengah. Namun, metode ini kurang optimal dalam merepresentasikan hubungan spasial global dan tekstur kompleks (Ojala et al., 2002).

p-ISSN : 2406-7733
e-ISSN : 2597-9922

Pada *Wavelet Transform*, metode mampu menangkap informasi tekstur multi-skala melalui representasi frekuensi citra dan banyak diterapkan pada citra medis serta *remote sensing*. Namun, efektivitasnya dipengaruhi oleh konfigurasi parameter transformasi sehingga optimasi masih menjadi tantangan (Humeau-Heurtier, 2019). Sementara itu, *Convolutional Neural Network* (CNN) menjadi metode yang paling dominan pada penelitian terbaru karena mampu melakukan *automatic feature learning* dan menghasilkan performa lebih baik pada tekstur kompleks. Namun, CNN membutuhkan dataset besar, waktu pelatihan lama, dan sumber daya komputasi tinggi (LeCun et al., 2015; Liu et al., 2019). Selain CNN, beberapa penelitian mulai menerapkan *Vision Transformer* (ViT) dan metode *hybrid feature extraction*. Pendekatan *hybrid* mengombinasikan metode konvensional dan *deep learning* untuk meningkatkan representasi fitur dan stabilitas model, meskipun implementasinya lebih kompleks (Humeau-Heurtier, 2019; Liu et al., 2019). Berdasarkan hasil kajian, keterbatasan yang masih sering ditemukan meliputi sensitivitas metode terhadap perubahan pencahayaan dan *noise*, tingginya kompleksitas komputasi, serta rendahnya kemampuan generalisasi model pada dataset yang berbeda (LeCun et al., 2015; Liu et al., 2019).

Tabel 7. Kelebihan, Keterbatasan, dan *Research Gap* Metode *Texture Feature Extraction*.

Metode	**Kelebihan**	**Keterbatasan**	***Research Gap***
GLCM	Mampu menangkap hubungan spasial tekstur, komputasi rendah	Sensitif terhadap *noise*, rotasi, dan pencahayaan	Pengembangan metode yang lebih *robust* terhadap variasi citra
LBP	Efektif pada pola tekstur lokal, implementasi sederhana	Kurang optimal pada tekstur kompleks dan global	Integrasi *multi-scale texture analysis*
Wavelet Transform	Representasi tekstur multi-skala	Sensitif terhadap konfigurasi parameter	Optimasi parameter otomatis
CNN	Ekstraksi fitur otomatis, performa tinggi pada tekstur kompleks	Membutuhkan *dataset* besar dan komputasi tinggi	Pengembangan *lightweight* model dan efisiensi komputasi
Vision Transformer (ViT)	Representasi hubungan global fitur	Membutuhkan data pelatihan besar	Adaptasi pada *dataset* terbatas
Hybrid Method	Menggabungkan keunggulan berbagai metode	Implementasi lebih kompleks	Standardisasi *framework hybrid*

Hasil analisis menunjukkan bahwa *research gap* utama masih berkaitan dengan *robustness* terhadap *noise* dan pencahayaan, keterbatasan generalisasi model, tingginya kebutuhan komputasi pada metode *deep learning*, serta belum adanya standar *dataset* dan evaluasi yang seragam antar penelitian. Selain itu, sebagian besar penelitian masih berfokus pada domain citra medis sehingga peluang pengembangan pada domain lain masih terbuka luas (LeCun et al., 2015; Liu et al., 2019).

V. KESIMPULAN DAN SARAN

Kesimpulan

Berdasarkan hasil *Systematic Literature Review* (SLR) terhadap penelitian mengenai *texture feature extraction* pada analisis citra digital, diperoleh beberapa kesimpulan sebagai berikut:

1. Metode *texture feature extraction* mengalami perkembangan yang signifikan dari pendekatan konvensional, seperti *Gray Level Co-occurrence Matrix* (GLCM), *Local Binary Pattern* (LBP), dan *Histogram of Oriented Gradients* (HOG), menuju metode berbasis *deep learning*, seperti *Convolutional Neural Network* (CNN), *Vision Transformer* (ViT), *attention mechanism*, serta metode *hybrid* yang menunjukkan peningkatan performa pada berbagai bidang analisis citra digital.
2. Hasil penelitian menunjukkan bahwa metode konvensional masih efektif digunakan pada dataset berukuran kecil dengan kompleksitas komputasi yang relatif rendah, sedangkan metode berbasis *deep learning* memiliki kemampuan ekstraksi fitur yang lebih baik dan tingkat akurasi yang lebih tinggi, namun membutuhkan dataset besar serta sumber daya komputasi yang tinggi.
3. Bidang penerapan metode *texture feature extraction* didominasi oleh citra medis, *remote sensing*, deteksi objek, *surface defect detection*, dan *image retrieval*, yang menunjukkan bahwa ekstraksi fitur tekstur memiliki peran penting dalam berbagai konteks analisis citra digital.
4. Penelitian ini menemukan beberapa tantangan utama, seperti sensitivitas terhadap *noise*, tingginya kompleksitas komputasi, kebutuhan dataset dalam jumlah besar, serta belum adanya standar evaluasi dan dataset yang seragam sehingga menyulitkan perbandingan performa antar metode secara objektif.

p-ISSN : 2406-7733
e-ISSN : 2597-9922

5. Penelitian selanjutnya disarankan untuk mengembangkan pendekatan *hybrid*, meningkatkan efisiensi komputasi metode berbasis *deep learning*, serta menerapkan standar evaluasi yang lebih konsisten agar hasil penelitian dapat dibandingkan secara lebih komprehensif.

Saran

Berdasarkan hasil penelitian yang telah dilakukan, pengembangan penelitian selanjutnya disarankan untuk mengarah pada metode *hybrid* yang mengombinasikan pendekatan konvensional, seperti *Gray Level Co-occurrence Matrix* (GLCM) dan *Local Binary Pattern* (LBP), dengan metode berbasis *deep learning* guna meningkatkan performa ekstraksi fitur tekstur sekaligus mengurangi keterbatasan masing-masing metode. Selain itu, diperlukan pengembangan metode berbasis *deep learning*, seperti *Convolutional Neural Network* (CNN) dan *Vision Transformer* (ViT), yang lebih efisien dalam penggunaan sumber daya komputasi dan tidak terlalu bergantung pada dataset berukuran besar.

Penelitian selanjutnya juga diharapkan dapat menggunakan dataset citra yang lebih beragam dan terstandarisasi agar evaluasi performa metode *texture feature extraction* dapat dilakukan secara lebih objektif dan konsisten pada berbagai konteks analisis citra digital. Di samping itu, pengembangan metode yang lebih *robust* terhadap *noise*, perubahan pencahayaan, dan variasi tekstur perlu diperhatikan untuk meningkatkan kemampuan generalisasi model.

DAFTAR PUSTAKA

Alhassan, M. M., Abdulrahman, A., & Musa, H. (2022). Multidirectional gradient feature with shape index for effective texture classification. *International Journal of Swarm Intelligence Systems, 13*(1). https://doi.org/10.4018/IJSWIS.312183

Alhichri, H., Kamel, N., & Bazi, Y. (2021). Deep learning and entropy-based texture features for color image classification. *Entropy, 23*(5), 567. https://doi.org/10.3390/e23050567

Backes, A. R., Casanova, D., & Bruno, O. M. (2011). Color texture analysis based on fractal descriptors. *Pattern Recognition, 44*(8), 1983–1992. https://doi.org/10.1016/j.patcog.2011.03.009

Bai, T., Ge, Y., Wang, Y., & Li, Y. (2021). Adversarial shape learning for building extraction in VHR remote sensing images. *IEEE Transactions on Image Processing, 31*, 146–159. https://doi.org/10.1109/TIP.2021.3134455

Chen, W., & Li, X. (2008). SVD-based modeling for image texture classification using wavelet transformation. *International Journal of Wavelets, Multiresolution and Information Processing, 6*(4), 521–533.

Chen, Y., Liu, J., & Huang, X. (2024). A novel feature extraction method based on Legendre multi-wavelet transform and auto-encoder for steel surface defect classification. *IEEE Access, 12*, 114562–114575. https://doi.org/10.1109/ACCESS.2024.3349628

Chen, Z., Liu, Y., & Xu, H. (2025). Fabric defect detection algorithm based on dynamic enhanced texture features. *Proceedings of the ACM International Conference*. https://doi.org/10.1145/3757749.3757780

Do, M. N., & Vetterli, M. (2010). Statistical wavelet subband characterization based on generalized gamma density and its application in texture retrieval. *IEEE Transactions on Image Processing, 19*(2), 496–508.

Dong, R., Jiang, B., Wu, W., Zhao, Z., Zhao, H., Shen, Q., et al. (2025). Wavelet convolution and multi-scale attention for Chinese herbal medicine recognition. *Ecological Informatics, 92*, 103449. https://doi.org/10.1016/j.ecoinf.2025.103449

Farella, E. M., Torresani, A., Remondino, F., & Fitzner, D. (2020). Advanced techniques for fast and accurate heritage digitisation in multiple case studies. *Sustainability, 12*(15), 6123. https://doi.org/10.3390/su12156123

Gletsos, M., Mougiakakou, S., Matsopoulos, G., Nikita, A., Nikita, K., & Kelekis, D. (2007). Differential diagnosis of CT focal liver lesions using texture features, feature selection and ensemble driven classifiers. *Artificial Intelligence in Medicine, 39*(2), 107–119. https://doi.org/10.1016/j.artmed.2006.09.002

Gonzalez, R. C., & Woods, R. E. (2018). *Digital image processing* (4th ed.). Pearson.

Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics, SMC-3*(6), 610–621. https://doi.org/10.1109/TSMC.1973.4309314

Humeau-Heurtier, A. (2019). Texture feature extraction methods: A survey. *IEEE Access, 7*, 8975–9000. https://doi.org/10.1109/ACCESS.2018.2890743

Karthikeyan, T., & Poongodi, P. (2018). Application of feature extraction and classification methods for histopathological image using GLCM, LBP, LBGLCM, GLRLM and SFTA. *Procedia Computer Science, 135*, 82–87. https://doi.org/10.1016/j.procs.2018.08.152

Khan, M. A., & Alqahtani, A. (2023). Osteoporosis detection and classification of femur X-ray

p-ISSN : 2406-7733
e-ISSN : 2597-9922

images through spectral domain analysis using texture features. *International Journal of Advanced Computer Science and Applications, 14*(9), 755–763. https://doi.org/10.14569/IJACSA.2023.0140980

Kiani, F. (2022). Texture classification: A literature review. *BMC Medical Imaging, 22*, 88. https://doi.org/10.1186/s12880-022-00788-2

Kim, J., Lee, S., & Park, H. (2024). Single-stage landmark retrieval with texture feature fusion. *International Journal of Information and Communication Technology, 25*(2), 144–158. https://doi.org/10.1504/IJICT.2024.143328

Kitchenham, B., & Charters, S. (2007). *Guidelines for performing systematic literature reviews in software engineering*. EBSE Technical Report.

Kumar, S., & Singh, P. (2021). An analytical review of texture feature extraction approaches. *International Journal of Computer Applications Technology, 66*(3), 245–258. https://doi.org/10.1504/IJCAT.2021.114842

Lahraichi, M., Berroukham, A., & Housni, K. (2025). Anomaly detection based on vision transformer model and texture features. *Journal of Computer Science, 21*(7), 1613–1620. https://doi.org/10.3844/jcssp.2025.1613.1620

Lazebnik, S., Schmid, C., & Ponce, J. (2012). Pixel to patch sampling for texture classification. *Pattern Recognition, 45*(2), 148–159.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature, 521*(7553), 436–444. https://doi.org/10.1038/nature14539

Li, H., Wang, X., & Zhao, Y. (2025). An improved two-step strategy for accurate feature extraction in weak-texture environments. *Sensors, 25*(20), 6309. https://doi.org/10.3390/s25206309

Li, J., Zhang, Y., & Wang, H. (2024). Dynamic texture classification using autoencoder-based local features and Fisher vector encoding. *IEEE Access*. https://doi.org/10.1109/ACCESS.2024.3421666

Li, X., Zhao, H., Xu, B., & Liu, H. (2025). Wavelet-based texture mining and enhancement for face forgery detection. *IET Biometrics*. https://doi.org/10.1049/bme2.2217175

Li, Y., Wang, Z., & Chen, X. (2023). Toward scalable image feature compression: A content-adaptive and diffusion-based approach. *Proceedings of the ACM International Conference*, 355–364. https://doi.org/10.1145/3581783.3611851

Li, Y., Zhang, J., & Huang, X. (2018). A novel retrieval method for remote sensing image based on statistical model. *Multimedia Tools and Applications, 77*(18), 23821–23840. https://doi.org/10.1007/s11042-018-6789-4

Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., et al. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis, 42*, 60–88. https://doi.org/10.1016/j.media.2017.07.005

Liu, K., Zhang, H., & Sun, Y. (2024). A fast image stitching algorithm based on texture classification and improved SIFT. *IEEE Access, 12*, 148822–148835. https://doi.org/10.1109/ACCESS.2024.3443111

Liu, L., Chen, J., Fieguth, P., Zhao, G., Chellappa, R., & Pietikäinen, M. (2019). From BoW to CNN: Two decades of texture representation for texture classification. *International Journal of Computer Vision, 127*, 74–109. https://doi.org/10.1007/s11263-018-1122-1

Lu, Y., Nong, Y., Zhu, D., & Wang, S. (2025). Enhancing YOLOv8 for accurate detection of arbitrarily oriented and multi-scale construction materials. *Engineering Applications of Artificial Intelligence, 161*, 112176. https://doi.org/10.1016/j.engappai.2025.112176

Mishra, N., & Silakari, S. (2021). Content-based image retrieval: A review of recent trends. *Cogent Engineering, 8*(1), 1929033. https://doi.org/10.1080/23311916.2021.1929033

Mohanaiah, P., Sathyanarayana, P., & GuruKumar, L. (2014). Texture feature based liver lesion classification. *Proceedings of SPIE, 9035*, 90352E. https://doi.org/10.1117/12.2043210

Ojala, T., Pietikäinen, M., & Mäenpää, T. (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence, 24*(7), 971–987. https://doi.org/10.1109/TPAMI.2002.1017623

Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., et al. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ, 372*, n71. https://doi.org/10.1136/bmj.n71

Paragios, N., & Deriche, R. (2008). Texture analysis and segmentation using modulation features, generative models, and weighted curve evolution. *IEEE Transactions on Image Processing, 17*(4), 552–571.

Reddy, G. T., & Kumar, Y. (2020). Feature extraction and selection of kidney ultrasound images using GLCM and PCA. *Procedia Computer Science, 167*, 1722–1731. https://doi.org/10.1016/j.procs.2020.03.381

Singh, R., Verma, P., & Sharma, A. (2024).

p-ISSN : 2406-7733
e-ISSN : 2597-9922

Differential shrinkage extended binary pattern for texture classification. *Proceedings of the ACM International Conference*, 233–241. https://doi.org/10.1145/3700003.3700020

Szeliski, R. (2022). *Computer vision: Algorithms and applications* (2nd ed.). Springer.

Tuceryan, M., & Jain, A. K. (1998). Texture analysis. In C. H. Chen, L. F. Pau, & P. S. P. Wang (Eds.), *Handbook of pattern recognition and computer vision* (pp. 207–248). World Scientific.

Unser, M. (1995). A comparative study of texture measures with classification based on featured distributions. *Pattern Recognition, 28*(1), 51–59. https://doi.org/10.1016/0031-3203(95)00067-4

Wang, H., Qu, H., Xu, J., Wang, J., Wei, Y., & Zhang, Z. (2020). Combining statistical features and local pattern features for texture image retrieval. *IEEE Access, 8*, 222611–222624. https://doi.org/10.1109/ACCESS.2020.3043413

Wang, Q., Li, P., & Zhao, H. (2025). A robust rotation-equivariant feature extraction framework for ground texture-based visual localization. *Sensors, 25*(12), 3585. https://doi.org/10.3390/s25123585

Wang, S., & Zhang, D. (2010). Maximum variance difference based embedding approach for facial feature extraction. *International Journal of Pattern Recognition and Artificial Intelligence, 24*(8), 1245–1261. https://doi.org/10.1142/S0218001410008234

Wouwer, G. V., Scheunders, P., & Livens, S. (2006). Wavelet modeling using finite mixtures of generalized Gaussian distributions: Application to texture discrimination and retrieval. *IEEE Transactions on Image Processing, 15*(6), 1452–1461. https://doi.org/10.1109/TIP.2005.864170

Xie, X., & Mirmehdi, M. (2005). Illumination invariant texture retrieval. *IEEE Transactions on Image Processing, 14*(1), 31–41.

Zhang, J., Tan, T., & Ma, Z. (2008). An efficient method for rotation and scaling invariant texture classification. *Pattern Recognition Letters, 29*(10), 1525–1531.

Zhang, L., Chen, Y., & Wu, X. (2024). LT-LBP-based spatial texture feature extraction with deep learning for X-ray images. *Journal of Computer Science, 20*, 106–120. https://doi.org/10.3844/jcssp.2024.106.120

Zhang, X., Cui, J., Wang, W., & Lin, C. (2017). A study for texture feature extraction of high-resolution satellite images based on a direction measure and gray level co-occurrence matrix fusion algorithm. *Sensors, 17*(7), 1474. https://doi.org/10.3390/s17071474

Zhang, Y., & Hong, G. (2015). Image enhancement and feature extraction based on low-resolution satellite data. *IEEE International Geoscience and Remote Sensing Symposium*, 2145–2148.

Zhao, Y., Liu, H., & Wang, X. (2019). Texture feature extraction method based on adaptive local binary mode. *Journal of Image and Graphics, 24*(6), 1021–1030.

Zhou, Y., Li, J., & Chen, H. (2022). MSCNet: A framework with a texture enhancement mechanism and feature aggregation for crack detection. *IEEE Access, 10*, 315660–315672. https://doi.org/10.1109/ACCESS.2022.3156606