



Implementasi Pengelompokan Citra Batik dengan Pendekatan Metode Graph-Based Multi-View Clustering

Budi Hartono*, Veronica Lusiana

Fakultas Teknologi Informasi dan Industri, Prodi Teknik Informatika, Universitas Stikubank, Semarang, Indonesia

Email: ¹*budihartono@edu.unisbank.ac.id, ²vero@edu.unisbank.ac.id

Email Penulis Korespondensi: budihartono@edu.unisbank.ac.id

Abstrak—Batik merupakan salah satu warisan budaya bangsa Indonesia yang memiliki kekayaan motif, warna, pola geometris, serta tekstur yang kompleks. Kompleksitas visual menjadikan citra Batik menarik untuk dikaji menggunakan pendekatan pengolahan citra dan pembelajaran mesin, khususnya untuk pengelompokan citra Batik tanpa label. Tantangan utama dalam penelitian ini adalah bagaimana karakteristik visual batik direpresentasikan dengan baik agar kemiripan antarpola dapat dikenali. Tiga fitur tekstur, yaitu kontras, entropi, dan energi, digunakan sebagai tiga view yang merepresentasikan karakteristik batik. Untuk memperoleh nilai ketiga fitur ini, dilakukan ekstraksi fitur menggunakan metode Gray-Level Co-occurrence Matrix (GLCM). Penelitian ini menggunakan pendekatan metode Graph-based Multi-View Clustering untuk memperoleh kelompok citra batik berdasarkan kemiripan antar-citra. Graf konsensus gabungan disusun melalui penggabungan fitur kontras, energi, dan entropi, yang terdiri dari 30 node dan 219 edge. Graf ini memiliki densitas sebesar 0,503 dan membentuk satu komponen graf terhubung. Hasil densitas menunjukkan bahwa 50,3% dari seluruh kemungkinan pasangan citra memiliki hubungan. Graf yang dihasilkan memperlihatkan terbentuknya satu struktur graf terhubung yang mengakomodasi informasi dari ketiga view serta menghasilkan representasi pengelompokan yang lebih komprehensif dibandingkan dengan penggunaan satu view secara terpisah. Graf konsensus gabungan membentuk struktur graf yang saling terhubung dan menghasilkan pengelompokan citra batik yang representatif.

Kata Kunci: Fitur Tekstur; Batik; GLCM; Multi-View Clustering; Graph-based Clustering

Abstract—Batik is a cultural heritage of Indonesia characterized by a rich array of motifs, colors, geometric patterns, and complex textures. This visual complexity makes Batik images compelling subjects for analysis using image processing and machine learning approaches, particularly for unsupervised clustering. A primary challenge in this research is effectively representing Batik's visual characteristics so pattern similarities can be accurately identified. Three texture features contrast, entropy, and energy serve as distinct "views" of Batik characteristics. These feature values are obtained by extracting them using the Gray-Level Co-occurrence Matrix (GLCM) method. The study utilizes a Graph-based Multi-View Clustering approach to group Batik images based on inter-image similarity. The study constructs a combined consensus graph with 30 nodes and 219 edges by integrating contrast, energy, and entropy features. This graph exhibits a density of 0.503 and forms a single connected graph component. The density result indicates that 50.3% of all possible image pairs share a connection. The resulting graph forms a connected structure that incorporates information from all three views, yielding a more comprehensive clustering representation than any single view. The combined consensus graph establishes an interconnected structure that produces a representative clustering of Batik images.

Keywords: Texture Feature; Batik; GLCM; Multi-View Clustering; Graph-based Clustering

1. PENDAHULUAN

Batik merupakan salah satu warisan budaya Indonesia yang memiliki keragaman motif, warna, dan karakteristik tekstur. Keragaman tersebut menjadikan citra batik sebagai objek yang menarik untuk dikaji, khususnya dalam proses pengelompokan atau clustering. Pengelompokan citra batik bertujuan untuk menemukan kesamaan antar-citra berdasarkan karakteristik visual tertentu, sehingga citra dengan motif yang mirip dapat ditempatkan dalam kelompok yang sama. Proses ini penting untuk mendukung pengarsipan digital atau pengembangan pengenalan pola batik berbasis komputer. Berbagai penelitian terdahulu menunjukkan bahwa pengolahan citra digital banyak digunakan untuk mendukung proses identifikasi dan pengelompokan objek berdasarkan karakteristik visual. Ekstraksi fitur warna, bentuk, dan tekstur dapat menjadi dasar untuk membedakan suatu objek. Selanjutnya, metode clustering, seperti K-Means clustering, dapat digunakan untuk mengelompokkan citra berdasarkan kemiripan fitur yang diekstraksi.

Beberapa penelitian tentang pengenalan objek menggunakan data citra. Identifikasi buah tomat kondisi segar dan busuk, mengembangkan sistem klasifikasi citra tomat menggunakan metode K-Means Clustering berdasarkan fitur warna, bentuk, dan tekstur (Aznawi et al., 2025). Klasifikasi citra biota laut komoditas perikanan bernilai tinggi, yaitu gurita, lobster, dan kerang laut, dilakukan menggunakan metode clustering K-Means (Imansyah dan Ramadhanu, 2025). Aplikasi berbasis Android untuk pengelompokan tingkat kematangan buah kopi menggunakan clustering K-Means. Tingkat kematangan kopi dibagi menjadi dua yaitu kopi mentah dan matang (Pambudi et al., 2021). Mendeteksi penyakit bulai pada komoditas jagung Madura menggunakan metode K-Means Clustering (Rosyadi NR et al., 2023). Hal ini dapat diketahui dari perubahan warna daun jagung akibat terserang penyakit bulai.

Pengenalan emosi wajah banyak diterapkan dalam interaksi manusia dan komputer, penelitian ini membandingkan tiga algoritma, yaitu clustering K-Means, Gaussian Mixture Model (GMM), dan Spectral Clustering untuk mengelompokkan ekspresi wajah. Evaluasi dilakukan menggunakan Silhouette Score, Davies-Bouldin Index (Totti dan Setiyawati, 2025). Identifikasi jenis ikan Nila dengan ekstraksi ciri tekstur menggunakan metode Gray Level Co-Occurrence Matrix (GLCM) melalui nilai kontras, korelasi, energi, dan homogenitas, serta metode K-Means Clustering (Nuraini, 2022). Penelitian ini bertujuan untuk mengetahui ciri citra wajah menggunakan metode GLCM untuk mengekstraksi ciri tekstur wajah (Ramadhani et al., 2025). Penelitian oleh Zamzani (Zamzani et al., 2025) mengevaluasi

klasifikasi kualitas Cabai Rawit menggunakan algoritma XGBoost dengan tiga jenis fitur, yaitu Local Binary Pattern (LBP), GLCM, dan Hue, Saturation, Value (HSV). Pengembangan sistem identifikasi keaslian uang kertas rupiah menggunakan K-Means Clustering dengan dua fitur yaitu LBP dan Laplacian of Gaussian (Faddilah et al., 2026).

Penelitian mengenai pengenalan dan pengelompokan motif batik. Mendeteksi motif kain tradisional Bali menggunakan algoritma Learning Vector Quantization. Motif kain yang bervariasi dan hampir serupa, menggunakan pendekatan ekstraksi fitur tepi dengan metode Sobel (Kadyanan et al., 2024). Penerapan Content-Based Image Retrieval (CBIR) dengan metode GLCM, LBP, dan Euclidean Distance untuk pencarian motif Batik Parang, Truntum, dan Kawung (Ramadhan et al., 2025). Penelitian menggunakan metode Convolutional Neural Network (CNN) untuk pengenalan motif batik. Penelitian klasifikasi Batik Semarang dan ikon kota Semarang seperti motif Warak Ngendok, Tugu Muda, Lawang Sewu, dan Jembatan Mberok, menggunakan metode CNN (Afifah dan Lusiana, 2025). Pengembangan sistem pengenalan corak batik Nusantara menggunakan metode Convolutional Neural Network (CNN) berbasis Android. Corak batik terdiri dari 10 jenis yaitu: Batik Betawi, Ciamis, Garutan, Kawung, Lasem, Pekalongan, Priangan, Sidomukti, Sogan, dan Batik Tambal (Aziz dan Saefurrohman, 2023). Motif batik memiliki kompleksitas visual karena tersusun dari variasi pola dan tekstur. Penelitian masih berfokus pada pengenalan motif dengan pendekatan representasi fitur tunggal. Penggunaan satu fitur saja sering kali tidak mampu menangkap keseluruhan struktur kemiripan antar citra. Penelitian sebelumnya yang terkait dengan pengenalan dan pengelompokan motif batik tidak menggunakan multi-view.

Salah satu tantangan dalam pengelompokan citra batik adalah bagaimana merepresentasikan karakteristik visualnya. Citra batik memiliki pola geometris, warna tertentu, serta tekstur yang kompleks. Ekstraksi fitur tekstur menggunakan metode Gray-Level Co-occurrence Matrix (GLCM). Fitur tekstur seperti kontras (*contrast*), entropi (*entropy*), dan energi (*energy*) digunakan untuk menggambarkan karakteristik citra dari sudut pandang yang berbeda. Kontras merepresentasikan tingkat perbedaan intensitas lokal, entropi adalah tingkat ketidakteraturan atau kompleksitas tekstur, sedangkan energi menggambarkan tingkat keseragaman atau keteraturan pola. Pada penelitian ini, proses pengelompokan citra batik berdasarkan ciri kontras, entropi, dan energi, dilakukan dengan pendekatan Graph-Based Multi-View Clustering. Melalui proses pengelompokan, ditemukan pula pola hubungan dalam setiap kelompok.


2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Tahapan penelitian adalah sebagai berikut:

1. Persiapan dataset citra, yaitu mengumpulkan citra motif batik.
2. Pra-pemrosesan citra dengan proses grayscale dan resize dimensi citra.
3. Ekstraksi fitur citra menggunakan metode Gray-Level Co-occurrence Matrix (GLCM).
4. Membentuk graf lokal view fitur kontras, entropi, dan energi, menggunakan Euclidean distance, similarity matrix.
5. Penggabungan graf
6. Visualisasi hasil kluster.

Pada Gambar 1 adalah alur tahapan penelitian. Melalui penelitian ini maka dapat diperoleh hasil pengelompokan citra batik menggunakan multi-view clustering dengan pendekatan graf.



Gambar 1. Alur Tahapan Penelitian



Data uji pada penelitian ini menggunakan 30 citra motif Batik Nitik 960 (Minarno, Nugroho, & Soesanti, 2023). Batik Nitik adalah salah satu motif batik khas dari daerah Yogyakarta, memiliki pola geometris kecil yang membentuk motif lebih besar. Pola ini tersusun atas banyak titik, garis, dan balok, sehingga membentuk ruang dan sudut geometris. Batik Nitik melambangkan keanekaragaman alam, seperti bunga, daun, dan sulur.

2.2 Gray Level Co-occurrence Matrix (GLCM)

Tekstur adalah karakteristik penting untuk mengidentifikasi objek atau region pada citra. Gagasan utamanya yaitu informasi tekstur tidak cukup dijelaskan oleh nilai intensitas piksel secara tunggal, melainkan oleh hubungan spasial antartingkat keabuan (gray level) dalam citra. Metode Gray-Level Co-occurrence Matrix (GLCM) adalah metode statistik orde dua untuk menganalisis tekstur pada citra. Metode ini menghitung frekuensi kemunculan pasangan piksel dengan nilai gray level tertentu pada jarak dan arah tertentu, tidak hanya menghitung distribusi intensitas piksel seperti histogram biasa (Iqbal, Mumtaz, Shafi, & Zaidi, 2021). GLCM dapat dihitung pada arah 0° , 45° , 90° , dan 135° dengan jarak piksel $d=1$, $d=2$, atau jarak lain sesuai kebutuhan. Dari matriks ko-okurensi ini kemudian dihitung beberapa fitur tekstur atau mengekstraksi fitur tekstur seperti kontras, korelasi, energi, homogenitas, dan entropi.

Citra motif batik memiliki karakter berupa variasi tekstur, pola berulang, garis, bentuk geometris, serta kontras antara motif dan latar. Metode GLCM yang relevan digunakan untuk memperoleh ciri motif batik melalui ekstraksi fitur tekstur. Metode ini mampu menangkap hubungan antar piksel yang berdekatan yaitu perbedaan pola seperti motif yang rapat, teratur, kompleks, atau yang sebaliknya (Utaminigrum, et al., 2023). Dengan demikian, GLCM memberikan dasar kuantitatif untuk menjelaskan perbedaan tekstur antar citra.

$$Contrast = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i-j)^2 P(i,j) \quad (1)$$

$$Entropy = - \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P(i,j) \log(P(i,j)) \quad (2)$$

$$Energy = \sqrt{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P(i,j)^2} \quad (3)$$

Pemilihan fitur kontras, entropi, dan energi sebagai kombinasi fitur yang representatif untuk penelitian ini. Fitur Kontras menggunakan persamaan (1), dapat menangkap perbedaan intensitas lokal gelap-terang atau transisi antara motif dan latar. Fitur Entropi menggunakan persamaan (2), sesuai untuk membedakan motif yang sederhana dengan motif yang lebih kompleks, atau ketidakteraturan tekstur. Fitur Energi menggunakan persamaan (3), sesuai untuk melihat tingkat keteraturan pola, terutama pada motif geometris atau pola yang berulang. Dengan tiga fitur ini, citra dapat direpresentasikan melalui tiga sudut pandang tekstur yaitu perbedaan intensitas, kompleksitas pola, dan keteraturan motif. Oleh karena itu, GLCM dengan fitur kontras, entropi, dan energi layak digunakan sebagai metode ekstraksi fitur awal dalam penelitian pengelompokan citra batik, dengan tahap selanjutnya berupa clustering, similarity graph, dan graph-based multi-view clustering (Dornaika & Charafeddine, 2025).

2.3 Multi-View Clustering

Multi-view clustering (MVC) merupakan salah satu teknik pembelajaran mesin tanpa pengawasan (*unsupervised learning*) yang dirancang untuk mengatasi keterbatasan representasi fitur tunggal (*single-view*) pada data citra berdimensi tinggi dan kompleks. Citra batik memiliki karakteristik visual yang kaya, sehingga satu jenis ekstraksi fitur, seperti ekstraksi distribusi warna saja, sering kali tidak cukup untuk mendeskripsikan objek secara menyeluruh. MVC memecahkan masalah ini dengan mengintegrasikan berbagai representasi fitur dari objek yang sama. Algoritma MVC memodelkan variasi data secara lebih komprehensif, sehingga dapat menghasilkan pengelompokan citra yang lebih baik.

Citra Batik memiliki kompleksitas visual (*view*) yang tinggi, disusun oleh kombinasi warna, tekstur, dan bentuk motif, sehingga pendekatan *view* tunggal sering kali gagal menangkap informasi citra Batik secara utuh. Dalam ruang lingkup data citra, data sering direpresentasikan sebagai hasil proses ekstraksi fitur. Metode ekstraksi fitur dapat diperoleh dari fitur warna, tekstur, atau bentuk. Pada citra batik, ekstraksi fitur tekstur antara lain fitur kontras, entropi, dan energi, yang dihasilkan oleh metode GLCM. Setiap fitur ini menjadi sebuah *view* (Li & Yang, 2025). Apabila proses pengelompokan data menggunakan masing-masing *view*, maka disebut sebagai *single-view clustering*.

Pada penelitian ini, proses clustering menggunakan pendekatan beberapa *view* secara bersamaan. Prinsip multi-view clustering (MVC) memiliki dua pengertian utama, yaitu:

- Komplementer (*complementarity*) yaitu setiap *view* mengandung informasi unik yang tidak dimiliki oleh *view* lain.
- Konsistensi (*consistency*) yaitu meskipun representasi fiturnya berbeda, semua *view* mendeskripsikan objek citra batik yang sama, sehingga menghasilkan label kluster yang seragam.

2.4 Membentuk Graf Lokal

Pembentukan graf lokal berfungsi memetakan struktur dataset sebelum dilakukan pengelompokan. Dalam citra batik, pendekatan graf lokal diformulasikan untuk merepresentasikan setiap citra sebagai simpul (*node*) dan kedekatan antar citra sebagai sisi (*edge*). Simpul-simpul data yang berada dalam ketetanggaan terdekat memiliki probabilitas tinggi untuk berasal dari kelompok atau kluster yang sama.

Proses ini diawali dengan menghitung jarak kemiripan antar pasangan data pada masing-masing representasi view secara independen. Komputasi jarak umumnya menggunakan metrik jarak Euclidean. Menghitung jarak Euclidean antara dua titik menggunakan persamaan (4). Pengukuran geometris ini dilakukan untuk seluruh kemungkinan pasangan citra, yang menghasilkan matriks jarak sebagai dasar penentuan struktur ketetanggaan secara lokal.

$$d(x, y) = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (4)$$

Graf yang terbentuk berfokus pada struktur view lokal dengan membatasi ketetanggaan menggunakan algoritma K-Nearest Neighbors (K-NN). Langkah ini dapat memutus koneksi antara citra batik yang secara visual berbeda atau yang memiliki jarak jauh dalam ruang fitur. Tahap selanjutnya adalah pemberian bobot pada sisi-sisi yang telah melewati seleksi ketetanggaan untuk menghasilkan matriks afinitas. Pemberian bobot berfungsi untuk mengonversi nilai metrik jarak menjadi tingkat kemiripan dalam rentang [0, 1]. Jika bernilai 0, kedua simpul tidak memiliki sisi penghubung. Dengan nilai mendekati 1, kedua simpul ini dekat. Matriks afinitas dapat merepresentasikan graf lokal setiap view.


2.5 Penggabungan Graf

Penggabungan graf (*graph fusion*) berfungsi untuk menyatukan beberapa view menjadi graf konsensus (Li & Yang, 2025). Setiap ruang fitur, seperti kontras, entropi, dan energi, pada citra batik diproyeksikan ke dalam matriks afinitas. Saat graf lokal digabungkan, sistem akan mengevaluasi graf mana yang paling terstruktur. Sebagai contoh, jika fitur kontras pada sekumpulan batik menjadi kacau akibat variasi pencahayaan, algoritma akan menurunkan bobot atau pengaruh graf warna tersebut dan memberikan bobot yang lebih tinggi pada graf entropi atau energi yang lebih stabil. Proses penggabungan graf lokal bekerja dengan saling mengoreksi dan melengkapi antarfitur. Jika fitur citra digabungkan secara langsung, fitur dengan dimensi yang lebih besar akan lebih mendominasi fitur dengan dimensi yang lebih kecil.


3. HASIL DAN PEMBAHASAN

3.1 Pra-proses Citra

Pra-proses citra diawali dengan mengubah dimensi citra dan mengonversi citra RGB ke skala abu-abu. Citra *dataset* asli adalah citra berwarna RGB berdimensi 512x512 piksel yang dikonversi menjadi citra 16 tingkat keabuan berdimensi 128x128 piksel. Citra batik RGB dan abu-abu dapat dilihat pada Gambar 2 dan Gambar 3.



Gambar 2. Citra Batik RGB



Gambar 3. Citra Batik 16 derajat keabuan



3.2 Matriks Kemiripan

Matriks kemiripan atau *similarity matrix* adalah tabel yang dapat digunakan untuk membandingkan tingkat kemiripan setiap potongan citra batik satu sama lain. Dalam penelitian ini terdapat 30 citra, maka dimensi tabel adalah 30 baris dan 30 kolom. Isi tabel ini untuk mengukur tingkat kemiripan atau kedekatan antara dua citra dengan rentang nilai 0 sampai 1. Angka mendekati 1 berarti fitur kedua citra tersebut sangat mirip, sebaliknya jika mendekati angka 0, maka fitur kedua citra tersebut sangat tidak mirip atau tidak memiliki hubungan (Zhang, Wang, & Li, 2025). Melalui matriks ini, dapat dilihat fitur atau ciri citra yang rumit sebagai nilai yang menggambarkan kedekatan antara satu citra dan citra lainnya. Pada penelitian ini terdapat tiga matriks kemiripan seperti dicatat pada Tabel 1 untuk view kontras, Tabel 2 untuk view energi, dan Tabel 3 untuk view entropi, yang masing-masing menampilkan sebagian isi matriks dari ketiga view tersebut. Pada diagonal utama matriks, perbandingan kemiripan dua citra yang sama menghasilkan nilai kemiripan 1.

Tabel 1. Matriks kemiripan view kontras

No	Data	01_1	01_2	01_3	02_1	02_2	02_3	...	31_3
1	01_1	1.0000	0.5153	0.4953	0.5966	0.5241	0.8416	...	0.3233
2	01_2	0.5153	1.0000	0.3379	0.3822	0.3510	0.5706	...	0.4645
3	01_3	0.4953	0.3379	1.0000	0.7448	0.9004	0.4531	...	0.2432
4	02_1	0.5966	0.3822	0.7448	1.0000	0.8116	0.5364	...	0.2653
5	02_2	0.5241	0.3510	0.9004	0.8116	1.0000	0.4770	...	0.2499
6	02_3	0.8416	0.5706	0.4531	0.5364	0.4770	1.0000	...	0.3442
7	...	...	...	...	...	...	...	...	...
8	31_3	0.3233	0.4645	0.2432	0.2653	0.2499	0.3442	...	1.0000

Tabel 2. Matriks kemiripan view energi

No	Data	01_1	01_2	01_3	02_1	02_2	02_3	...	31_3
1	01_1	1.0000	0.9940	0.9891	0.9932	0.9805	0.9840	...	0.9643
2	01_2	0.9940	1.0000	0.9832	0.9873	0.9748	0.9782	...	0.9699
3	01_3	0.9891	0.9832	1.0000	0.9958	0.9912	0.9948	...	0.9541
4	02_1	0.9932	0.9873	0.9958	1.0000	0.9871	0.9906	...	0.9580
5	02_2	0.9805	0.9748	0.9912	0.9871	1.0000	0.9964	...	0.9462
6	02_3	0.9840	0.9782	0.9948	0.9906	0.9964	1.0000	...	0.9494
7	...	...	...	...	...	...	...	...	...
8	31_3	0.9643	0.9699	0.9541	0.9580	0.9462	0.9494	...	1.0000

Tabel 3. Matriks kemiripan view entropi

No	Data	01_1	01_2	01_3	02_1	02_2	02_3	...	31_3
1	01_1	1.0000	0.9316	0.9154	0.8431	0.8117	0.8748	...	0.7396
2	01_2	0.9316	1.0000	0.8578	0.7940	0.7661	0.8220	...	0.7821
3	01_3	0.9154	0.8578	1.0000	0.9143	0.8775	0.9517	...	0.6923
4	02_1	0.8431	0.7940	0.9143	1.0000	0.9561	0.9587	...	0.6501
5	02_2	0.8117	0.7661	0.8775	0.9561	1.0000	0.9183	...	0.6313
6	02_3	0.8748	0.8220	0.9517	0.9587	0.9183	1.0000	...	0.6688
7	...	...	...	...	...	...	...	...	...
8	31_3	0.7396	0.7821	0.6923	0.6501	0.6313	0.6688	...	1.0000

Ketiga view memiliki karakteristik yang berbeda. View kontras menggambarkan kedekatan citra berdasarkan variasi intensitas atau tekstur kasar. Tabel 1 view kontras paling kuat membedakan citra karena rentang nilainya lebar atau variatif. Tabel 2 view energi menggambarkan kedekatan berdasarkan homogenitas atau keteraturan tekstur, nilai similaritas relatif rapat mendekati 1. View entropi menggambarkan kedekatan berdasarkan ketidakteraturan tekstur. Tabel 3 view entropi bervariasi namun tidak sekuat view kontras dan serapat view energi.

3.3 Membentuk Matriks Ketetangaan

Matriks ketetangaan atau adjacency matrix adalah tabel yang digunakan untuk mencatat hubungan antarsimpul (node) pada sebuah graf. Matriks ketetangaan per-view merepresentasikan hubungan antardata citra pada setiap fitur yang digunakan dalam proses clustering multi-view. Dalam penelitian ini, setiap citra batik direpresentasikan sebagai node, sedangkan hubungan kemiripan antar citra direpresentasikan sebagai edge.

Matriks ketetangaan per-view bersumber dari matriks kemiripan fitur kontras, energi, dan entropi. Setiap fitur diperlakukan sebagai satu view yang membentuk struktur graf tersendiri. Matriks ketetangaan per-view berfungsi untuk mengubah informasi matriks kemiripan menjadi struktur relasional yang menunjukkan citra mana saja yang memiliki tingkat kemiripan yang kuat berdasarkan fitur tertentu. Penelitian ini menggunakan nilai kuartil 75% sebagai batas setiap view secara adaptif dari distribusi data yang tidak berada pada diagonal utama. Pendekatan ini dipilih karena setiap fitur tekstur memiliki rentang dan sebaran kemiripan yang berbeda-beda. Hanya 25% dari hubungan kemiripan tertinggi pada

setiap view yang dipertahankan sebagai edge dalam matriks ketetanggaan, sedangkan hubungan yang lebih lemah dihapus. Pendekatan ini bertujuan untuk membentuk graf lokal yang lebih mewakili untuk setiap view.

Setiap nilai kemiripan dibandingkan dengan nilai batas, jika nilainya lebih besar atau sama dengan nilai batas, maka hubungan antar citra dipertahankan sebagai edge. Sebaliknya, jika nilai kemiripan lebih kecil dari nilai batas maka hubungan antar citra dihapus. Diagonal utama diberi nilai 0 karena membandingkan kemiripan citra dengan dirinya sendiri. Nilai batas adaptif untuk view kontras=0.464, energi=0.992, dan entropi=0.881. Tabel 4 menampilkan sebagian isi matriks ketetanggaan view kontras yang bersumber dari matriks kemiripan view yang sama. Nilai kemiripan kedua citra yang lebih kecil dari 0.464 diganti dengan 0. Jika nilai kemiripan lebih besar atau sama dengan 0.464, maka nilainya tidak berubah. Tabel 5 menampilkan sebagian isi matriks ketetanggaan view energi yang bersumber dari matriks kemiripan view yang sama. Nilai kemiripan kedua citra yang lebih kecil dari 0.992 diganti dengan 0, jika sebaliknya maka nilai tidak diganti. Tabel 6 menampilkan sebagian isi matriks ketetanggaan view entropi yang bersumber dari matriks kemiripan view yang sama. Nilai kemiripan kedua citra yang lebih kecil dari 0.881 diganti dengan 0, apabila sebaliknya maka nilai tidak berubah.

Tabel 4. Matriks ketetanggaan view kontras

No	Data	01_1	01_2	01_3	02_1	02_2	02_3	...	31_3
1	01_1	0	0.5153	0.4953	0.5966	0.5241	0.8416	...	0
2	01_2	0.5153	0	0	0	0	0.5706	...	0.4645
3	01_3	0.4953	0	0	0.7448	0.9004	0	...	0
4	02_1	0.5966	0	0.7448	0	0.8116	0.5364	...	0
5	02_2	0.5241	0	0.9004	0.8116	0	0.4770	...	0
6	02_3	0.8416	0.5706	0	0.5364	0.4770	0	...	0
7	...	...	...	...	...	...	...	...	...
8	31_3	0	0.4645	0	0	0	0	...	0

Tabel 5. Matriks ketetanggaan view energi

No	Data	01_1	01_2	01_3	02_1	02_2	02_3	...	31_3
1	01_1	0	0.9940	0	0.9932	0	0	...	0
2	01_2	0.9940	0	0	0	0	0	...	0
3	01_3	0	0	0	0.9958	0	0.9948	...	0
4	02_1	0.9932	0	0.9958	0	0	0	...	0
5	02_2	0	0	0	0	0	0.9964	...	0
6	02_3	0	0	0.9948	0	0.9964	0	...	0
7	...	...	...	...	...	...	...	...	...
8	31_3	0	0	0	0	0	0	...	0


Tabel 6. Matriks ketetanggaan view entropi

No	Data	01_1	01_2	01_3	02_1	02_2	02_3	...	31_3
1	01_1	0	0.9316	0.9154	0	0	0	...	0
2	01_2	0.9316	0	0	0	0	0	...	0
3	01_3	0.9154	0	0	0.9143	0	0.9517	...	0
4	02_1	0	0	0.9143	0	0.9561	0.9587	...	0
5	02_2	0	0	0	0.9561	0	0.9183	...	0
6	02_3	0	0	0.9517	0.9587	0.9183	0	...	0
7	...	...	...	...	...	...	...	...	...
8	31_3	0	0	0	0	0	0	...	0

Kegunaan matriks ketetanggaan adalah untuk mempertahankan informasi dari masing-masing fitur sebelum dilakukan proses penggabungan graph. Setiap fitur tekstur memiliki karakteristik yang berbeda dalam merepresentasikan citra batik. Matriks ini sebagai dasar pembentukan graf lokal sebelum proses penggabungan graf pada graph-based multi-view clustering. Hubungan antara citra dapat dianalisis secara terstruktur berdasarkan pola keterhubungan antara node.

3.4 Graf Setiap View dan Konsensus Gabungan

Setiap citra batik direpresentasikan sebagai node, sedangkan edge menunjukkan hubungan kemiripan antara citra. Nilai diagonal utama pada matriks ketetanggaan adalah nol untuk menghilangkan self-loop. Matriks ketetanggaan per view hanya memuat hubungan kemiripan yang kuat antar citra. Matriks ini kemudian digunakan sebagai dasar pembentukan graf lokal sebelum proses graf fusion dilakukan. Grafis graf view kontras dapat dilihat pada Gambar 4 dengan 109 edge dan satu komponen graf yang terhubung. Gambar 5 menampilkan graf view energi dengan 111 edge dan tiga komponen graf terhubung. Gambar 6 adalah graf view entropi dengan 109 edge dan dua komponen graf yang terhubung.




Gambar 4. Graf view kontras



Gambar 5. Graf view energi

Graf kontras memiliki satu komponen graf yang terhubung. Seluruh node berada dalam satu graf yang saling terhubung, meskipun tidak semua node terhubung secara langsung. Fitur kontras cukup baik dalam menjaga keterhubungan global antar citra. Terdapat beberapa node yang berkumpul membentuk sub-struktur lokal. Meskipun ada kelompok-kelompok kecil, semuanya tetap tersambung menjadi satu komponen yang besar. Fitur kontras dapat menjadi jembatan antara kelompok citra. Graf energi memiliki tiga komponen yang saling terhubung. Graf ini terpecah menjadi tiga bagian yang tidak semuanya saling terhubung. Ada satu graf besar yang memuat 27 node, satu graf kecil dengan 2 node, dan satu graf lain dengan 1 node. Fitur energi menghasilkan struktur hubungan yang lebih selektif. Graf entropi memiliki dua komponen graf yang saling terhubung. Graf ini lebih terhubung dibanding energi tetapi tidak seutuh kontras. Sebagian besar node berada pada satu komponen besar yaitu 24 node, dan satu graf lain yang terpisah dengan 6 node.




Gambar 6. Graf view entropi

Graf dari setiap view digabungkan untuk membentuk fused graph atau consensus graph yang memuat informasi komplementer dari view kontras, energi, dan entropi. Fitur kontras menggambarkan perbedaan intensitas lokal, energi menggambarkan keteraturan atau keseragaman pola, sedangkan entropi menggambarkan tingkat kompleksitas atau ketidakteraturan tekstur. Dengan cara ini, proses clustering dapat menghasilkan kelompok citra batik yang lebih representatif dibandingkan dengan penggunaan satu fitur saja.

$$A^{fused} = \frac{A^{contrast} + A^{energy} + A^{entropy}}{3} \quad (5)$$

Graf konsensus dibentuk dari tiga matriks ketetanggaan yang diintegrasikan dengan bobot yang setara, lalu disimpan dalam matriks ketetanggaan gabungan. Matriks ketetanggaan gabungan diperoleh melalui rata-rata matriks ketetanggaan kontras, energi, dan entropi. Pembentukan matriks gabungan menggunakan persamaan (5) bertujuan untuk menggabungkan informasi dari beberapa view menjadi satu graf konsensus. Graf konsensus yang dihasilkan disusun oleh 30 node dengan 219 edge serta memiliki density sebesar 0,503, dan membentuk sebuah graf terhubung. Hasil ini menunjukkan bahwa 50,3% dari seluruh kemungkinan pasangan citra memiliki hubungan.



Gambar 7. Graf konsensus gabungan.

Graf konsensus gabungan dapat dilihat di Gambar 7. Node merepresentasikan citra batik, edge menunjukkan hubungan similarity gabungan, sedangkan warna node menunjukkan hasil pengelompokan. Struktur graf memperlihatkan terbentuknya beberapa kelompok lokal dengan tingkat keterhubungan yang berbeda serta masih adanya hubungan lintas kelompok, yang menunjukkan keberadaan informasi tekstur yang bersifat komplementer.

3.5 Pembahasan

Motif batik memiliki kompleksitas visual karena tersusun dari pola yang bervariasi. Penelitian sebelumnya masih berfokus pada pengenalan motif dengan pendekatan representasi fitur tunggal (Aziz dan Saefurrohman, 2023), (Kadyanan et al., 2024), (Ramadhan et al., 2025), dan (Afifah dan Lusiana, 2025). Penelitian yang terkait dengan pengenalan dan pengelompokan motif batik tidak menggunakan multi-view. Penggunaan satu fitur saja sering tidak mampu menangkap keseluruhan struktur kemiripan antarcitra.

Hasil penelitian ini menunjukkan bahwa setiap karakteristik fitur membentuk struktur hubungan antarcitra yang berbeda. Hal ini menunjukkan bahwa fitur kontras, energi, dan entropi tidak memberikan informasi struktur yang identik pada citra batik. Dengan demikian, apabila hanya satu fitur yang digunakan sebagai dasar pengelompokan, sebagian informasi hubungan antarcitra pada fitur lainnya dapat tidak terwakili.

Pada Tabel 7 menampilkan sebagian isi matriks ketetanggaan gabungan. Citra 01_3 dan 02_1 memiliki bobot sebesar 0.8849, nilai yang relatif tinggi menunjukkan adanya hubungan kemiripan yang kuat berdasarkan kombinasi



ketiga view. Oleh karena itu, kedua citra direpresentasikan oleh edge yang kuat. Citra 02_1 dan 01_1 memiliki bobot sebesar 0,5299 yang menunjukkan adanya hubungan kemiripan yang relatif sedang. Hubungan antara citra 31_3 dan 01_2 memiliki bobot sebesar 0.1548. Dibandingkan pasangan citra 01_3 dan 02_1, serta citra 02_1 dan 01_1, menunjukkan kemiripan yang jauh lebih lemah.

Tabel 7. Matriks ketetangaan gabungan

No	Data	01 1	01 2	01 3	02 1	02 2	02 3	...	31 3
1	01_1	0	0.8136	0.4702	0.5299	0.1747	0.2805	...	0
2	01_2	0.8136	0	0	0	0	0.1902	...	0.1548
3	01_3	0.4702	0	0	0.8849	0.3001	0.6488	...	0
4	02_1	0.5299	0	0.8849	0	0.5892	0.4984	...	0
5	02_2	0.1747	0	0.3001	0.5892	0	0.7972	...	0
6	02_3	0.2805	0.1902	0.6488	0.4984	0.7972	0	...	0
7	...	...	...	...	...	...	...	...	...
8	31_3	0	0.1548	0	0	0	0	...	0

Keberadaan sejumlah edge dan tumpang tindih posisi node menunjukkan bahwa karakteristik tekstur pada beberapa citra batik memiliki kemiripan yang cukup tinggi. Visualisasi graf ini merupakan bukti adanya struktur hubungan antara citra. Kedekatan geometris pada gambar graf membantu interpretasi visual. Beberapa kelompok motif batik memiliki kemiripan antarmotif. Terdapat kelompok citra yang memiliki tingkat kemiripan tekstur yang lebih kuat dibandingkan dengan kelompok lainnya.

4. KESIMPULAN

Graf berbasis kontras menghasilkan struktur yang saling terhubung dalam satu komponen. Graf berbasis energi menghasilkan relasi yang selektif pada tiga komponen. Graf berbasis entropi menggambarkan keterhubungan antar citra yang lebih seimbang dalam dua komponen. Graf konsensus gabungan disusun melalui penggabungan fitur kontras, energi, dan entropi, yang disusun dari 30 node dan 219 edge. Graf ini memiliki densitas sebesar 0,503 dan membentuk satu komponen graf terhubung. Hasil densitas menunjukkan bahwa 50,3% dari seluruh kemungkinan pasangan citra memiliki hubungan, dengan menggunakan nilai kuartil 75% sebagai batas adaptif untuk setiap view. Terbentuknya sebuah graf menunjukkan bahwa seluruh citra berada dalam satu struktur graf yang saling terhubung. Graf konsensus gabungan memperlihatkan terbentuknya satu struktur graf terhubung yang mengakomodasi informasi dari kontras, energi, dan entropi serta menghasilkan representasi pengelompokan yang lebih komprehensif dibandingkan dengan penggunaan satu view secara terpisah.

REFERENCES

- Afifah, W. N., & Lusiana, V. (2025). Klasifikasi Jenis Batik Semarang Menggunakan Metode Convolution Neural Network (CNN). *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, 10(1), 542-553. doi:<https://doi.org/10.29100/jupi.v10i1.5873>
- Aziz, F. F., & Saefurrohman. (2023). Deteksi dan Pengenalan Jenis Corak Batik Nusantara Menggunakan Metode CNN Berbasis Android. *Jurnal Teknologi Sistem Informasi dan Aplikasi*, 6(2), 191-201. <https://openjournal.unpam.ac.id/index.php/JTSI/article/view/32142>
- Aznawi, N. M., Setiadi, M. I., Aina, Z., Manullang, S., & Rahmadiyah, S. N. (2025). Implementasi K-Means Clustering pada Citra Digital Tomat untuk Identifikasi Kondisi Segar dan Busuk. *Journal of Students' Research in Computer Science (JSRCS)*, 6(1), 59–68. doi:<https://doi.org/10.31599/srtqmw49>
- Dornaika, F., & Charafeddine, J. (2025). One-phase multi-view clustering with unified graph and data representation convolution. *Soft Computing*, 29, 4335–4356. doi:<https://doi.org/10.1007/s00500-025-10533-y>
- Faddilah, R., Roza, E., Pinardi, S., & Rosalina. (2026). Identifikasi Keaslian Uang Kertas Menggunakan Metode K-Means Clustering. *Jurnal Surya Energy*, 10(2), 60-68. doi:<https://doi.org/10.32502/jse.v10i2.997>
- Imansyah, M. D., & Ramadhanu, A. (2025). Implementasi Algoritma K-Means untuk Klasifikasi Citra Biota Laut: Gurita, Lobster, dan Kerang Laut. *Teksis: Jurnal Teknologi Dan Sistem Informasi Bisnis*, 7(4), 507-513. doi:<https://doi.org/10.47233/jteksis.v7i4.2271>
- Iqbal, N., Mumtaz, R., Shafi, U., & Zaidi, S. M. (2021). Gray level co-occurrence matrix (GLCM) texture based crop classification using low altitude remote sensing platforms. *PeerJ Computer Science*, 7(e536), 1-26. doi:<https://doi.org/10.7717/peerj-cs.536>
- Kadyanan, I. G., Gunantara, N., Manuaba, I. B., & Saputra, K. O. (2024). Deteksi Motif Tradisional Bali dengan Algoritma Learning Vector Quantization. *Jurnal Sains dan Teknologi*, 13(1), 118-125. doi:<https://doi.org/10.23887/jstundiksha.v12i3.50399>
- Li, Q., & Yang, G. (2025). Multi-view clustering via global-view graph learning. *PLoS One*, 20(6)(e0321628), 1-16. doi:<https://doi.org/10.1371/journal.pone.0321628>



- Minarno, A. E., Nugroho, H. A., & Soesanti, I. (2023). Batik Nitik 960. *Mendeley Data*, V3. <https://data.mendeley.com/datasets/sgh484jxzy>
- Nuraini, R. (2022). Implementasi Euclidean Distance dan Segmentasi K-Means Clustering Pada Identifikasi Citra Jenis Ikan Nila. *KLIK: Kajian Ilmiah Informatika dan Komputer*, 3(1), 1-8. <https://djournals.com/klik/article/view/551>
- Pambudi, N. A., Pranoto, Y. A., & Sasmito, A. P. (2021). Pengenalan Tingkat Kematangan Buah Kopi Berdasarkan Fitur Warna Cielab dengan K-Means Clustering. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 5(2), 728-732. <https://ejournal.itn.ac.id/jati/article/view/3781>
- Ramadhan, R. P., Cahya, A. P., Mochtar, D. P., Santri, P., & Puspaningrum, E. Y. (2025). Implementasi GLCM, LBP, Dan Euclidean Distance Untuk Sistem Pencarian Batik Teratur Berbasis Citra. *Seminar Nasional Informatika Bela Negara (SANTIKA)*. 5, hal. 123-130. Surabaya: UPN Veteran Jawa Timur.
- Ramadhani, F. Z., Purwadi, H., & Rizal, A. (2025). Clustering K-Means Berdasarkan Ciri Gray Level Co-occurrence Matrix Pada Foto Wajah. *Komitek: Jurnal Komputer, Informasi dan Teknologi*, 5(1), 1-10. doi:<https://doi.org/10.53697/jkomitek.v5i1.2498>
- Rosyadi, NR, I. R., Prasetyowati, E., & Said, B. (2023). Penerapan Citra Berbasis K-Means Clustering untuk Mendeteksi Penyakit Bulai Pada Komoditas Jagung Madura. *Just IT: Jurnal Sistem Informasi, Teknologi Informasi dan Komputer*, 13(3), 206–211. <https://jurnal.umj.ac.id/index.php/just-it/article/view/16588>
- Totti, F. A., & Setiyawati, N. (2025). Perbandingan Algoritma Clustering K-Means, Gaussian Mixture Model, dan Spectral Clustering untuk Facial Emotion Recognition. *Sistemasi: Jurnal Sistem Informasi*, 14(6), 3007-3019. doi:<https://doi.org/10.32520/stmsi.v14i6.5668>
- Utaminingrum, F., Muhammad Alqadri, A., Somawirata, I. K., Karim, C., Septiarini, A., Lin, C.-Y., & Shih, T. K. (2023). Feature selection of gray-level Cooccurrence matrix using genetic algorithm with Extreme learning machine classification for early detection of Pole roads. *Results in Engineering*, 20(101437), 1-9. doi:<https://doi.org/10.1016/j.rineng.2023.101437>
- Zamzani, Z. M., Puspaningrum, E. Y., & Via, Y. V. (2025). Analisis Ekstraksi Fitur LBP, GLCM dan HSV Untuk Klasifikasi Kualitas Cabai Rawit menggunakan XGBoost. *Jurnal Algoritme*, 6(1), 121-130. doi:DOI: 10.35957/algoritme.v6i1.13307
- Zhang, D., Wang, P., & Li, Q. (2025). Enhanced Similarity Matrix Learning for Multi-View Clustering. *Electronics*, 14(2845), 1-22. doi:<https://doi.org/10.3390/electronics14142845>