

KLASIFIKASI JENIS KAIN BERDASARKAN EKSTRAKSI FITUR TEKSTUR MENGGUNAKAN METODE GRAY LEVEL CO-OCCURRENCE MATRICES (GLCM)

CLASSIFICATION OF FABRIC TYPES BASED ON TEXTURE FEATURE EXTRACTION USING THE GRAY LEVEL CO-OCCURRENCE MATRICES (GLCM) METHOD

FX Arinto Setyawan¹, Helmy Fitriawan¹, Sri Ratna Sulistiyanti¹, Mutia Aini Lutfia¹, Tiya Muthia^{1*}

Program Studi Teknik Elektro, Universitas Lampung, Indonesia

Riwayat Artikel

Submitted : 1/10/2025
Published : 28/01/2026

* Email Korespondensi:
tiyamuthia@eng.unila.ac.id



Abstrak: Klasifikasi jenis kain secara manual berdasarkan karakteristik tekstur melalui indra peraba bersifat subjektif dan dapat menghasilkan identifikasi yang tidak konsisten. Pengolahan citra dan *machine learning* dapat digunakan sebagai pendekatan untuk melakukan klasifikasi jenis kain secara otomatis berdasarkan karakteristik teksturnya. Penelitian ini bertujuan untuk mengklasifikasikan lima jenis kain, yaitu drill, katun, polyester, satin, dan wool, menggunakan ekstraksi fitur tekstur *Gray Level Co-Occurrence Matrix* (GLCM) dan algoritma *K-Nearest Neighbor* (K-NN). Citra kain diperoleh menggunakan mikroskop digital yang terhubung dengan komputer. Tahapan pengolahan citra meliputi *resizing* dan konversi citra RGB menjadi *grayscale*. Ekstraksi fitur GLCM menggunakan enam fitur tekstur, yaitu *dissimilarity*, *homogeneity*, *correlation*, *contrast*, *angular second moment* (ASM), dan *energy*, dengan empat orientasi sudut, yaitu 0°, 45°, 90°, dan 135°. Data penelitian terdiri atas 250 citra data latih dan 50 citra data uji. Pengujian dilakukan menggunakan variasi jarak piksel GLCM dari 1 hingga 5 dengan K=13 pada K-NN. Hasil pengujian menunjukkan bahwa konfigurasi terbaik diperoleh pada jarak 4 dengan *accuracy* sebesar 46%, *precision* sebesar 50,41%, *recall* sebesar 46%, dan *F1-score* sebesar 46,18%. Waktu komputasi tercepat diperoleh sebesar 0,044 detik dengan rata-rata 0,047 detik. Hasil ini menunjukkan bahwa variasi jarak GLCM memengaruhi kinerja klasifikasi, dengan jarak 4 memberikan hasil terbaik pada dataset yang digunakan.

Kata kunci: *Machine learning, K-NN, GLCM, Fitur tekstur, Klasifikasi, Jenis kain.*

Abstract: Manual classification of fabric types based on texture characteristics through tactile perception is subjective and may result in inconsistent identification. Image processing and machine learning can be used as an approach to automatically classify fabric types based on their texture characteristics. This study aims to classify five types of fabric, namely drill, cotton, polyester, satin, and wool, using texture feature extraction with the Gray Level Co-Occurrence Matrix (GLCM) and the K-Nearest Neighbor (K-NN) algorithm. Fabric images were acquired using a digital microscope connected to a computer. The image processing stages included resizing and conversion of RGB images into grayscale images. GLCM texture feature extraction used six features, namely dissimilarity, homogeneity, correlation, contrast, angular second moment (ASM), and energy, with four angular orientations of 0°, 45°, 90°, and 135°. The dataset consisted of 250 training images and 50 test images. Testing was performed using GLCM pixel-distance variations from 1 to 5 with K=13 in the K-NN algorithm. The results showed that the best configuration was obtained at a distance of 4, with an accuracy of 46%, precision of 50.41%, recall of 46%, and F1-score of 46.18%. The fastest processing time was 0.044 seconds, with an average processing time of 0.047 seconds. These results indicate that variations in GLCM pixel distance affect classification performance, with a distance of 4 providing the best performance on the dataset used.

Keywords: *Machine Learning, K-NN, GLCM, Texture Features, Classification, Fabric Types*

1. PENDAHULUAN

Kain merupakan salah satu material yang banyak digunakan dalam kebutuhan sandang dan berbagai produk tekstil. Setiap jenis kain memiliki karakteristik permukaan yang berbeda, seperti pola tenunan, tingkat kehalusan, kekasaran, dan distribusi serat. Karakteristik tersebut dapat digunakan sebagai informasi untuk membedakan jenis kain. Identifikasi jenis kain secara konvensional umumnya dilakukan melalui pengamatan visual dan perabaan,

sehingga hasilnya dapat dipengaruhi oleh pengalaman dan subjektivitas pengamat. Pengolahan citra dapat digunakan sebagai pendekatan untuk memperoleh karakteristik permukaan kain secara lebih objektif melalui informasi yang terdapat pada citra.

Tekstur merupakan salah satu karakteristik penting dalam analisis citra karena dapat merepresentasikan pola dan hubungan spasial antar piksel. Salah satu metode yang banyak digunakan untuk memperoleh karakteristik

tekstur adalah Gray Level Co-Occurrence Matrix (GLCM). GLCM merepresentasikan distribusi kemunculan pasangan tingkat keabuan pada posisi spasial tertentu dan menghasilkan sejumlah fitur statistik yang dapat digunakan untuk menggambarkan tekstur citra [1], [2]. Fitur GLCM telah digunakan dalam berbagai penelitian klasifikasi citra berbasis tekstur, termasuk pada objek material yang memiliki karakteristik permukaan yang berbeda [5], [10], [11].

Penerapan GLCM pada klasifikasi kain telah dilakukan oleh Wahyudi dan Maulida menggunakan kombinasi GLCM dan K-Nearest Neighbor (K-NN) untuk mengenali pola citra kain tradisional [3]. Penelitian tersebut menunjukkan bahwa karakteristik tekstur yang diperoleh dari GLCM dapat digunakan sebagai informasi untuk membedakan pola kain. Pendekatan serupa juga dilakukan oleh Sapkale dan Patil dalam klasifikasi material kain dengan memanfaatkan fitur tekstur GLCM bersama fitur lainnya dan algoritma K-NN [4], [8], [9]. Selain pada kain, GLCM juga telah digunakan untuk mengekstraksi fitur tekstur pada berbagai objek citra. Praseptiyana dkk. memanfaatkan fitur GLCM untuk mendeteksi melasma pada citra wajah dengan mempertimbangkan hubungan spasial antar piksel [2], sedangkan Arifin menggunakan GLCM dan Local Binary Pattern (LBP) bersama K-NN untuk klasifikasi citra tekstur kayu [5].

K-NN merupakan salah satu metode klasifikasi yang dapat digunakan untuk mengelompokkan data berdasarkan kedekatan karakteristik fitur. Metode ini menentukan kelas data uji berdasarkan sejumlah data latih yang memiliki jarak terdekat. Penggunaan K-NN bersama fitur tekstur memberikan pendekatan klasifikasi yang relatif sederhana karena proses klasifikasi dilakukan berdasarkan kedekatan vektor fitur tanpa membentuk model yang kompleks [3], [4], [6], [16], [17]. Perkembangan penerapan *machine learning* pada berbagai permasalahan klasifikasi juga menunjukkan pemanfaatan metode pembelajaran mesin untuk mengenali pola dari data secara otomatis [7].

Meskipun penelitian sebelumnya telah menerapkan GLCM dan K-NN pada klasifikasi kain dan berbagai objek bertekstur, terdapat perbedaan pada jenis kain, karakteristik citra, serta konfigurasi ekstraksi fitur yang digunakan. Penelitian Wahyudi dan Maulida berfokus pada kain tradisional, sedangkan Sapkale dan Patil menggunakan kombinasi beberapa karakteristik untuk klasifikasi material kain [3], [4]. Penelitian mengenai karakterisasi permukaan kain juga menunjukkan bahwa perbedaan tekstur permukaan merupakan permasalahan yang dapat memiliki tingkat kemiripan visual cukup tinggi sehingga pemilihan representasi fitur menjadi penting [8], [10]-[15]. Oleh karena itu, diperlukan pengujian metode berbasis fitur tekstur yang sederhana untuk mengklasifikasikan


jenis kain dengan mempertimbangkan hubungan spasial antar piksel pada pembentukan GLCM.

Berdasarkan permasalahan tersebut, penelitian ini menggunakan pendekatan berbasis pengolahan citra dan pembelajaran mesin untuk mengklasifikasikan lima jenis kain, yaitu drill, katun, polyester, satin, dan wool, berdasarkan karakteristik teksturnya. Ekstraksi fitur tekstur dilakukan menggunakan GLCM dan proses klasifikasi menggunakan algoritma K-NN. Penelitian ini bertujuan untuk mengklasifikasikan lima jenis kain berdasarkan fitur tekstur GLCM menggunakan algoritma K-NN serta menganalisis pengaruh variasi jarak piksel terhadap kinerja klasifikasi dan waktu pemrosesan.

2. BAHAN DAN METODE PENELITIAN

2.1. Pengambilan Data Sampel

Data penelitian berupa citra lima jenis kain, yaitu drill, katun, polyester, satin, dan wool. Pengambilan citra dilakukan menggunakan kamera *digital microscope* dengan kain ditempatkan tegak lurus terhadap lensa. Pencahayaan selama proses akuisisi citra menggunakan lampu LED yang tersedia pada perangkat *digital microscope*. Citra hasil akuisisi selanjutnya digunakan sebagai dataset untuk proses ekstraksi fitur tekstur dan klasifikasi jenis kain.



Gambar 1. Pengambilan Data Citra

Dataset yang digunakan dalam penelitian terdiri dari 250 citra data latih dan 50 citra data uji. Setiap jenis kain terdiri atas 50 citra untuk data latih dan 10 citra untuk data uji.

2.2 Pengolahan Awal Citra

Pengolahan awal dilakukan terhadap citra hasil akuisisi sebelum proses ekstraksi fitur tekstur. Tahapan pengolahan awal meliputi pengubahan ukuran citra (*resizing*) dan konversi citra RGB menjadi *grayscale*.

A. Pengubahan Ukuran Citra

Citra hasil akuisisi diubah ukurannya dari 1094x615 piksel menjadi 300x225 piksel. Proses *resizing* dilakukan untuk menyeragamkan ukuran citra yang digunakan dalam proses ekstraksi fitur dan klasifikasi.



Gambar 2. Perubahan ukuran citra

B. Konversi RGB ke Grayscale

Citra hasil akuisisi berupa citra RGB dikonversi menjadi citra *grayscale* sebelum dilakukan ekstraksi fitur GLCM. Konversi tersebut menghasilkan satu kanal tingkat keabuan yang digunakan dalam pembentukan matriks kookurensi. Citra *grayscale* selanjutnya digunakan sebagai masukan pada tahap ekstraksi fitur tekstur.



Gambar 3. Konversi RGB ke *Grayscale*

2.3 Ekstraksi Fitur Tekstur GLCM

Gray Level Co-Occurrence Matrix (GLCM) digunakan untuk memperoleh karakteristik tekstur dari citra *grayscale*. GLCM merepresentasikan hubungan spasial antara pasangan piksel berdasarkan tingkat keabuan pada jarak dan orientasi tertentu [1], [2], [5]. Pendekatan GLCM banyak digunakan untuk merepresentasikan karakteristik tekstur pada berbagai objek citra, termasuk material dan kain [3], [4].


Pada penelitian ini digunakan enam fitur tekstur GLCM, yaitu:

- Dissimilarity* digunakan untuk mengukur perbedaan tingkat keabuan antara pasangan piksel pada matriks GLCM. Nilai yang lebih tinggi menunjukkan adanya perbedaan tingkat keabuan yang lebih besar pada pasangan piksel.
- Homogeneity* menunjukkan tingkat keseragaman distribusi tingkat keabuan pada citra. Nilai *homogeneity* yang lebih tinggi menunjukkan distribusi pasangan tingkat keabuan yang lebih terkonsentrasi pada nilai yang berdekatan.
- Correlation* mengukur hubungan linear antara tingkat keabuan pada pasangan piksel yang terdapat dalam matriks GLCM.
- Contrast* digunakan untuk mengukur perbedaan tingkat keabuan antara piksel-piksel yang berpasangan. Nilai *contrast* yang lebih besar menunjukkan perbedaan tingkat keabuan yang lebih tinggi.

- Angular Second Moment* (ASM) digunakan untuk mengukur keseragaman distribusi tingkat keabuan pada matriks GLCM.
- Energy* merupakan akar kuadrat dari ASM dan digunakan untuk menggambarkan keseragaman tekstur citra.

Keenam fitur tersebut digunakan untuk merepresentasikan karakteristik tekstur permukaan kain.

GLCM dihitung menggunakan empat orientasi, yaitu 0° , 45° , 90° , dan 135° . Penggunaan beberapa orientasi memungkinkan karakteristik hubungan spasial piksel dari arah yang berbeda untuk direpresentasikan dalam proses ekstraksi fitur [2]. Selain orientasi, penelitian ini menggunakan variasi jarak piksel sebesar 1, 2, 3, 4, dan 5 untuk mengetahui pengaruh jarak ketetanggaan piksel terhadap hasil klasifikasi. Pendekatan GLCM dengan variasi orientasi dan jarak juga telah digunakan dalam penelitian klasifikasi citra berbasis tekstur. Dengan enam fitur dan empat orientasi, setiap citra menghasilkan 24 nilai fitur yang digunakan sebagai representasi karakteristik tekstur.



Gambar 4. Ilustrasi sudut dengan jarak ketetanggaan 1 piksel

2.4 Klasifikasi K-Nearest Neighbor

Fitur tekstur hasil ekstraksi GLCM selanjutnya digunakan sebagai masukan untuk proses klasifikasi menggunakan K-Nearest Neighbor (K-NN). K-NN menentukan kelas suatu data berdasarkan kedekatan data tersebut terhadap sejumlah data latih. Metode ini telah digunakan bersama GLCM pada klasifikasi objek berbasis tekstur, termasuk kain dan material tekstil [3], [4], [8], [9], [16], [17].

Pada penelitian ini digunakan *Euclidean distance* sebagai fungsi untuk menghitung jarak antara data uji dan data latih.

Persamaan *Euclidean distance* dituliskan sebagai:

$$Euclidean = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

Dimana:

n : jumlah atribut

x_i dan y_i : atribut ke i dari objek data x dan y

Nilai jarak yang diperoleh kemudian digunakan untuk menentukan tetangga terdekat pada proses klasifikasi K-NN. Berdasarkan analisis awal terhadap jarak Euclidean, penelitian ini menggunakan nilai $K=13$. Pemilihan nilai tersebut didasarkan pada hasil analisis tetangga terdekat, di mana 13 tetangga terdekat masih berada pada kelas yang sama, sedangkan pada urutan berikutnya mulai ditemukan data dari kelas yang berbeda.

2.5 Pembagian Data

Data penelitian dibagi menjadi data latih dan data uji. Pembagian data dilakukan secara seimbang pada lima jenis kain. Komposisi data yang digunakan ditunjukkan pada Tabel 1

Tabel 1. Pembagian Data Latih dan Data Uji

Jenis Kain	Data Latih	Data Uji
Drill	50	10
Katun	50	10
Polyester	50	10
Satin	50	10
Wool	50	10
Total	250	50

Data latih digunakan sebagai basis klasifikasi K-NN, sedangkan data uji digunakan untuk mengevaluasi kemampuan sistem dalam mengklasifikasikan jenis kain berdasarkan karakteristik tekstur.

2.6 Evaluasi Kinerja

Evaluasi dilakukan menggunakan *confusion matrix* untuk membandingkan kelas aktual dengan kelas hasil prediksi. Berdasarkan *confusion matrix*, kinerja klasifikasi dievaluasi menggunakan *accuracy*, *precision*, dan *recall* [18].

$$akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

$$presisi = \frac{TP}{TP+FP} \quad (3)$$

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

Dengan:

- TP (*True Positive*) adalah data yang diprediksi benar sebagai kelas tertentu;
- TN (*True Negative*) adalah data yang bukan termasuk kelas tertentu dan diprediksi bukan sebagai kelas tersebut;
- FP (*False Positive*) adalah data yang bukan termasuk kelas tertentu tetapi diprediksi sebagai kelas tersebut;
- FN (*False Negative*) adalah data yang termasuk kelas tertentu tetapi diprediksi sebagai kelas lainnya.

Selain kinerja klasifikasi, waktu pemrosesan juga dicatat untuk mengetahui waktu yang diperlukan sistem pada setiap variasi jarak piksel.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pengujian Klasifikasi

Pengujian dilakukan menggunakan 250 data latih dan 50 data uji yang terdiri atas lima jenis kain, yaitu drill, katun, polyester, satin, dan wool. Pengujian dilakukan menggunakan lima variasi jarak ketetanggaan piksel pada GLCM, yaitu jarak 1, 2, 3, 4, dan 5, dengan nilai $K=13$ pada algoritma K-NN. Setiap variasi jarak menghasilkan nilai *accuracy*, *precision*, dan *recall* yang digunakan untuk mengevaluasi kinerja klasifikasi. Hasil pengujian ditunjukkan pada Tabel 2.

Tabel 2. Hasil Evaluasi Klasifikasi Berdasarkan Variasi Jarak

Jarak	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
1	28,00	44,35	28,00	20,01
2	32,00	64,65	32,00	27,08
3	38,00	40,37	38,00	35,60
4	46,00	50,41	46,00	46,18
5	42,00	48,33	42,00	39,03

Berdasarkan Tabel 2, nilai *accuracy* mengalami peningkatan dari jarak 1 hingga jarak 4. Nilai *accuracy* berturut-turut sebesar 28%, 32%, 38%, 46%, dan 42% pada jarak 1 hingga 5. Nilai *accuracy* tertinggi diperoleh pada jarak 4 sebesar 46%, kemudian mengalami penurunan menjadi 42% pada jarak 5.

Hasil evaluasi menunjukkan bahwa nilai *precision* tertinggi diperoleh pada jarak 2 sebesar 64,65%, sedangkan nilai *recall* tertinggi diperoleh pada jarak 4 sebesar 46%. Nilai *F1-score* tertinggi juga diperoleh pada jarak 4 sebesar 46,18%. Dengan mempertimbangkan *accuracy*, *recall*, dan *F1-score*, jarak 4 dipilih sebagai konfigurasi terbaik pada pengujian ini, dengan nilai *accuracy* sebesar 46%, *precision* sebesar 50,41%, *recall* sebesar 46%, dan *F1-score* sebesar 46,18%. Hasil tersebut diperoleh dari pengujian menggunakan 250 data latih dan 50 data uji dengan nilai $K=13$.

3.2 Analisis Hasil Prediksi Berdasarkan Jenis Kain

Untuk mengetahui karakteristik hasil klasifikasi pada masing-masing jenis kain, dilakukan pengamatan terhadap hasil prediksi pada setiap variasi jarak. Setiap jenis kain diuji menggunakan 10 citra sehingga terdapat 50 citra uji pada setiap proses pengujian.

Hasil prediksi pada setiap jarak ditunjukkan pada Tabel 3.

Tabel 3. Hasil Prediksi Berdasarkan Jenis Kain

No	Jenis Kain	Jarak	True	False
1	Drill	1	0	10
2	Katun	1	0	10
3	Polyester	1	10	0
4	Satin	1	1	9
5	Wool	1	3	7
1	Drill	2	0	10
2	Katun	2	2	8
3	Polyester	2	10	0
4	Satin	2	1	9
5	Wool	2	3	7
1	Drill	3	1	9
2	Katun	3	2	8
3	Polyester	3	9	1
4	Satin	3	4	6
5	Wool	3	3	7
1	Drill	4	4	6
2	Katun	4	2	8
3	Polyester	4	9	1
4	Satin	4	5	5
5	Wool	4	3	7
1	Drill	5	4	6
2	Katun	5	0	10
3	Polyester	5	9	1
4	Satin	5	2	8
5	Wool	5	4	6

Berdasarkan Tabel 3, hasil prediksi pada jarak 4 menunjukkan bahwa setiap jenis kain memiliki tingkat keberhasilan klasifikasi yang berbeda. Kain polyester memperoleh jumlah prediksi benar tertinggi, yaitu 9 dari 10 citra uji, sedangkan kain katun memperoleh jumlah prediksi benar terendah, yaitu 2 dari 10 citra uji. Kain drill, satin, dan wool masing-masing memperoleh prediksi benar sebanyak 4, 5, dan 3 citra. Secara keseluruhan, terdapat 23 citra yang berhasil diklasifikasikan dengan benar dari 50 citra uji, sedangkan 27 citra lainnya mengalami kesalahan klasifikasi. Dengan demikian, berdasarkan jumlah prediksi benar terhadap seluruh data uji, diperoleh nilai *accuracy* sebesar 46%.

Pada konfigurasi terbaik, yaitu jarak 4, hasil prediksi benar untuk drill sebanyak 4 citra, katun sebanyak 2 citra, polyester sebanyak 9 citra, satin sebanyak 5 citra, dan wool sebanyak 3 citra. Hasil tersebut menunjukkan bahwa polyester memiliki jumlah prediksi benar tertinggi, sedangkan katun memiliki jumlah prediksi benar terendah pada dataset penelitian.

Tabel 4. Waktu Komputasi pada Setiap Jarak

Jarak	Waktu Komputasi (detik)
1	0,048
2	0,045
3	0,047
4	0,044
5	0,054
Rata-rata	0,047

Waktu komputasi tercepat diperoleh pada jarak 4 sebesar 0,044 detik, sedangkan waktu terlama diperoleh pada jarak 5 sebesar 0,054 detik. Rata-rata waktu komputasi seluruh pengujian adalah 0,047 detik.

3.3 Pembahasan

Hasil pengujian menunjukkan bahwa variasi jarak piksel pada GLCM memengaruhi kinerja klasifikasi. Berdasarkan Tabel 2, nilai *accuracy* meningkat dari 28% pada jarak 1 menjadi 32% pada jarak 2, 38% pada jarak 3, dan mencapai nilai tertinggi sebesar 46% pada jarak 4. Ketika jarak ditingkatkan menjadi 5, nilai *accuracy* menurun menjadi 42%. Sementara itu, nilai *precision* tertinggi diperoleh pada jarak 2 sebesar 64,65%, sedangkan *recall* dan *F1-score* tertinggi diperoleh pada jarak 4, masing-masing sebesar 46% dan 46,18%. Dengan mempertimbangkan *accuracy*, *recall*, dan *F1-score*, jarak 4 memberikan kinerja klasifikasi terbaik pada konfigurasi penelitian ini.

GLCM merepresentasikan hubungan spasial antarpiksel berdasarkan tingkat keabuan pada jarak dan orientasi tertentu. Perubahan jarak piksel menyebabkan pasangan tingkat keabuan yang dianalisis menjadi berbeda sehingga memengaruhi nilai fitur tekstur yang dihasilkan. Pada penelitian ini, jarak 4 menghasilkan representasi tekstur yang memberikan kinerja klasifikasi paling baik berdasarkan *accuracy* dan *F1-score*.

Pada jarak 5, nilai *accuracy* mengalami penurunan menjadi 42% dibandingkan 46% pada jarak 4. Penurunan tersebut dapat dikaitkan dengan karakteristik tekstur kain yang memiliki pola permukaan relatif rapat. Peningkatan jarak piksel menyebabkan hubungan yang dianalisis dalam GLCM menjadi semakin berjauhan, sehingga pasangan tingkat keabuan yang terbentuk dapat merepresentasikan hubungan spasial yang kurang sesuai dengan pola tekstur lokal kain. Kondisi tersebut dapat menyebabkan karakteristik antarjenis kain menjadi kurang terpisah pada ruang fitur yang digunakan oleh K-NN. Akibatnya, kedekatan antarvektor fitur dari kelas yang berbeda dapat meningkat dan menyebabkan lebih banyak kesalahan klasifikasi. Hasil penelitian menunjukkan bahwa pada dataset yang digunakan, jarak 4 memberikan keseimbangan yang lebih baik dalam merepresentasikan hubungan spasial tekstur dibandingkan jarak 5.

Berdasarkan Tabel 3, *polyester* menunjukkan hasil klasifikasi paling baik pada konfigurasi jarak 4, dengan 9 dari 10 citra berhasil dikenali dengan benar. Sebaliknya, *katun* memperoleh jumlah prediksi benar paling rendah, yaitu 2 dari 10 citra. Perbedaan hasil tersebut menunjukkan bahwa karakteristik tekstur permukaan setiap jenis kain memberikan tingkat keterpisahan yang berbeda pada fitur yang digunakan dalam proses klasifikasi. Hasil ini sejalan dengan penelitian

yang menerapkan GLCM pada klasifikasi berbasis tekstur [2], [4]. Penelitian mengenai klasifikasi kain juga menunjukkan bahwa karakteristik permukaan merupakan informasi penting dalam proses identifikasi material kain [8].

Berdasarkan Tabel 4, waktu komputasi tercepat diperoleh pada jarak 4, yaitu 0,044 detik, sedangkan waktu terlama diperoleh pada jarak 5, yaitu 0,054 detik. Rata-rata waktu komputasi seluruh pengujian adalah 0,047 detik. Hasil tersebut menunjukkan bahwa variasi jarak GLCM tidak hanya memengaruhi kinerja klasifikasi, tetapi juga menghasilkan perbedaan waktu pemrosesan pada setiap konfigurasi.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa kombinasi ekstraksi fitur tekstur GLCM dan algoritma K-NN dapat digunakan untuk mengklasifikasikan lima jenis kain, yaitu drill, katun, polyester, satin, dan wool. Berdasarkan pengujian menggunakan 250 data latih dan 50 data uji, konfigurasi terbaik diperoleh pada jarak GLCM 4 dengan nilai *accuracy* sebesar 46%, *precision* sebesar 50,41%, *recall* sebesar 46%, dan *F1-score* sebesar 46,18%. Pada konfigurasi tersebut, sebanyak 23 dari 50 citra uji berhasil diklasifikasikan dengan benar. Waktu komputasi tercepat diperoleh pada jarak 4 sebesar 0,044 detik, dengan rata-rata waktu komputasi seluruh pengujian sebesar 0,047 detik. Hasil tersebut menunjukkan bahwa variasi jarak piksel pada GLCM memengaruhi kinerja klasifikasi, dengan jarak 4 memberikan kinerja terbaik berdasarkan *accuracy*, *recall*, dan *F1-score* pada dataset yang digunakan.

Untuk pengembangan penelitian selanjutnya, disarankan untuk menambah jumlah dan variasi dataset pada setiap jenis kain agar karakteristik tekstur yang digunakan lebih beragam sehingga dapat meningkatkan kemampuan generalisasi sistem dan menghasilkan kinerja klasifikasi yang lebih baik. Selain itu, variasi parameter K-NN dan metode ekstraksi fitur tekstur lainnya dapat dipertimbangkan sebagai pembandingan.

UCAPAN TERIMA KASIH

Ucapan terima kasih disampaikan kepada LPPM Universitas Lampung yang telah memberikan dana hibah melalui skema penelitian Dasar pada tahun 2024 dengan judul Klasifikasi Jenis Kain Berdasarkan Fitur Tekstur Menggunakan Metode Gray Levels Cooccurrence Matrices (GLCM) Dan K-Nearest Neighbour (KNN) dengan nomor kontrak 643/UN26.21/PM/2024.

DAFTAR PUSTAKA

- [1] R. M. Haralick, K. Shanmugam, and I. Dinstein, "Textural Features for Image Classification," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-3, no. 6, pp. 610–621, 1973, doi: 10.1109/TSMC.1973.4309314.
- [2] J. Arifin, "Klasifikasi Citra Tekstur Kayu Menggunakan Gray Level Co-Occurance Matrix dan Local Binary Pattern," *JIKO (Jurnal Informatika dan Komputer)*, vol. 6, no. 1, pp. 34–40, 2022, doi: 10.26798/jiko.v6i1.557.
- [3] J. Wahyudi and I. Maulida, "Pengenalan Pola Citra Kain Tradisional Menggunakan GLCM dan KNN," *Jurnal Teknologi Informasi Universitas Lambung Mangkurat*, vol. 4, no. 2, pp. 43–48, 2019, doi: 10.20527/jtiulm.v4i2.37.
- [4] S. Sapkale and M. Patil, "Texture Based Classification of Fabric Material," in *Artificial Intelligence and Communication Technologies*, S. Hiranwal and G. Mathur, Eds. SCRS, India, 2023, pp. 601–611, doi: 10.52458/978-81-955020-5-9-58.
- [5] W. I. Praseptiyana, A. W. Widodo, and M. A. Rahman, "Pemanfaatan Ciri Gray Level Co-occurrence Matrix (GLCM) untuk Deteksi Melasma pada Citra Wajah," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 3, no. 11, pp. 10402–10409, 2019.
- [6] R. Andrian, M. A. Naufal, B. Hermanto, A. Junaidi, and F. R. Lumbanraja, "k-Nearest Neighbor (k-NN) Classification for Recognition of the Batik Lampung Motifs," *Journal of Physics: Conference Series*, vol. 1338, no. 1, p. 012061, 2019, doi: 10.1088/1742-6596/1338/1/012061.
- [7] R. Maisyaroh, N. Azizah, N. Hidayat, and H. Hozairi, "Tren Penelitian Klasifikasi Sentimen Pelanggan Berbasis Machine Learning," *Jurnal Rekayasa Lampung*, vol. 4, no. 3, pp. 69–78, 2025, doi: 10.23960/jrl.v4i3.69.
- [8] W. K. Oktalao, I. M. B. A. Darmawan, I. W. Santiyasa, I. P. G. H. Suputra, and I. G. N. A. C. Putra, "Klasifikasi Motif Kain Tradisional Cepuk Menggunakan GLCM dan KNN," *JELIKU (Jurnal Elektronik Ilmu Komputer Udayana)*, vol. 11, no. 3, pp. 545–552, 2023, doi: 10.24843/JLK.2023.v11.i03.p10.
- [9] Kevin, J. Hendryli, and D. E. Herwindiati, "Klasifikasi Kain Tenun Berdasarkan Tekstur & Warna dengan Metode K-NN," *Computatio: Journal of Computer Science and Information Systems*, vol. 3, no. 2, pp. 85–95, 2019, doi: 10.24912/computatio.v3i2.6028.
- [10] Y. Ben Salem and M. N. Abdelkrim, "Texture Classification of Fabric Defects Using

- Machine Learning,” *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 10, no. 4, pp. 4390–4399, 2020, doi: 10.11591/ijece.v10i4.pp4390-4399.
- [11] Y. Hu, Z. Long, A. Sundaresan, M. Alfarraj, G. AlRegib, S. Park, and S. Jayaraman, “Fabric Surface Characterization: Assessment of Deep Learning-Based Texture Representations Using a Challenging Dataset,” *Textile Research Journal*, vol. 91, no. 5–6, pp. 568–584, 2021, doi: 10.1177/0040517520919332.
- [12] L. Cheng, J. Yi, A. Chen, Y. Zhang, and C. Hou, “Fabric Material Identification Based on Densenet Variant Networks,” *The Journal of The Textile Institute*, vol. 114, no. 10, pp. 1527–1538, 2023, doi: 10.1080/00405000.2022.2144600.
- [13] P. Tao, Z. Zhang, W. Cao, J. Liu, J. Chen, X. Hu, and X. Lv, “Research on Fabric Classification Based on Graph Neural Network,” *Industria Textila*, vol. 74, no. 1, pp. 3–11, 2023, doi: 10.35530/IT.074.01.202224.
- [14] B. Wei, B. Xu, K. Hao, and L. Gao, “Textile Defect Detection Using Multilevel and Attentional Deep Learning Network (MLMA-Net),” *Textile Research Journal*, vol. 92, no. 19–20, pp. 3462–3477, 2022, doi: 10.1177/00405175211073773.
- [15] K. Gopalakrishnan, V. Karthikeyan, P. Harshini, and N. Ramasabitha, “Texture Image Classification Using Effective Texture Descriptors,” *Journal of Texture Studies*, vol. 56, no. 5, p. e70049, 2025, doi: 10.1111/jtxs.70049.
- [16] Y. Kusumawati, A. Susanto, I. U. W. Mulyono, and D. P. Prabowo, “Klasifikasi Batik Kudus Berdasarkan Pola Menggunakan K-NN dan GLCM,” in *Seminar Nasional Hasil Penelitian dan Pengabdian pada Masyarakat V Tahun 2020*, Universitas Muhammadiyah Purwokerto, 2020, pp. 509–514.
- [17] C. Jatmoko and D. Sinaga, “A Classification of Batik Lasem Using Texture Feature Extraction Based on K-Nearest Neighbor,” *Journal of Applied Intelligent System*, vol. 3, no. 2, pp. 96–107, 2018, doi: 10.33633/jais.v3i2.2151.
- [18] S. Sathyanarayanan and B. R. Tantri, “Confusion Matrix-Based Performance Evaluation Metrics,” *African Journal of Biomedical Research*, vol. 27, no. 4S, pp. 4023–4031, 2024, doi: 10.53555/AJBR.v27i4S.4345.