

Classification of Batik Tasikmalaya Using Neural Network With GLCM dan LBP Feature Extraction

Popy Anisa¹, Alam Rahmatulloh²

^{1,2} Informatika, Fakultas Teknik Universitas Siliwangi, Tasikmalaya
Email : popyanisa22@gmail.com, alam@unsil.ac.id

Abstrak

Batik merupakan seni tradisional kain yang berasal dari Indonesia, di mana motif-motifnya diciptakan dengan menggunakan teknik pewarnaan kain yang melibatkan penggunaan lilin untuk mencegah pewarnaan pada bagian tertentu. Ini menciptakan pola-pola yang unik dan khas pada kain. Penelitian ini bertujuan untuk membantu mengatasi kesulitan masyarakat dalam mengidentifikasi motif batik di Tasikmalaya. Dengan menerapkan teknologi Jaringan Syaraf Tiruan (JST) serta ekstraksi fitur GLCM dan LBP, penelitian ini berhasil mencapai tingkat akurasi yang tinggi, yakni sekitar 95% dengan GLCM dan 90% dengan LBP dalam mengklasifikasikan motif-motif batik seperti Merak Ngibing, Lancan Tasik, Sidomukti Payung, dan Sukapura. Hal ini menunjukkan efektivitas metode tersebut dalam membantu mengidentifikasi motif batik dengan tingkat keakuratan yang tinggi.

Kata Kunci: Batik Tasikmalaya, Classification, GLCM, LBP

Abstract

Batik is a traditional Indonesian fabric art, where its motifs are created using a fabric dyeing technique that involves using wax to prevent coloring in specific areas. This creates unique and distinctive patterns on the fabric. This research aims to assist in addressing the difficulties people face in identifying batik motifs in Tasikmalaya. By applying Artificial Neural Network (ANN) technology along with feature extraction using Gray Level Co-Occurrence Matrix (GLCM) and Local Binary Pattern (LBP), this study achieved a high level of accuracy, around 95% with GLCM and 90% with LBP, in classifying batik motifs such as Merak Ngibing, Lancan Tasik, Sidomukti Payung, and Sukapura. This indicates the effectiveness of these methods in aiding the identification of batik motifs with a high level of accuracy.

Keywords: Classification, GLCM, LBP, Tasikmalaya Batik

PENDAHULUAN

Batik merupakan seni tradisional kain yang berasal dari Indonesia, di mana proses pembuatannya melibatkan penggunaan lilin untuk menahan pewarnaan pada area tertentu dari kain. Melalui teknik ini, motif-motif yang khas dan unik terbentuk di atas kain, menciptakan pola-pola yang rumit dan beragam. Batik bukan hanya sekadar kain, tetapi juga sebuah warisan budaya yang sudah mendunia, merepresentasikan kekayaan tradisional Indonesia dalam seni tekstil yang indah dan bermakna (Triprasetyo, A. W, et al., 2018).

Batik Tasikmalaya merupakan jenis batik yang memiliki sejarah panjang

dan kaya akan filosofi. Batik ini diketahui sudah ada sejak masa Kerajaan Tarumanegara. Wilayah Mangunreja, Sukapura, Maranjaya, Wurug, dan Tasikmalaya Kota merupakan area pemerintahan Tarumanegara yang berpusat di Sukapura. Batik Tasikmalaya memiliki beberapa jenis motif populer, yaitu Batik Sukapura, Batik Sawoan, dan Batik Tasik, masing-masing dengan ciri khasnya sendiri. Motif-motif ini sering kali mencerminkan nuansa kota Parahyangan dan memiliki pengaruh dari batik pesisiran. Batik Tasikmalaya juga dikenal juga dengan penggunaan warna yang cerah. Motif-motifnya antara lain motif Merak Ngibing, Lancan Tasik,

Sidomukti Payung, dan Sukapura.

Seiring berjalannya waktu, motif-motif batik terus berkembang yang mengakibatkan kesulitan bagi masyarakat untuk mengenali motif batik saat ini karena banyaknya pilihan yang tersedia. Dalam upaya mengatasi kesulitan mengidentifikasi motif batik di Tasikmalaya, mengklasifikasi batik Tasikmalaya membantu mengkaji dampak perubahan dan perbedaan dalam desain batik sepanjang waktu, seperti pengaruh kolonial Belanda dan keterlibatan pengusaha batik dari Jawa Tengah (Surya, R. A., et al., 2016).

Penelitian sebelumnya yang berjudul "Klasifikasi Motif Batik Malang Berdasarkan nilai ekstraksi fitur gray level co-occurrence matrix dengan algoritma decision tree". Penelitian menunjukkan bahwa penggunaan banyak decision tree dalam klasifikasi data GLCM besar dapat membantu menyederhanakan data dan mempercepat proses klasifikasi. Dalam studi yang memfokuskan pada pengklasifikasian motif batik Malang dengan menggunakan GLCM, metode Decision Tree mampu mencapai akurasi tertinggi 58% saat proses training dengan criterion entropy dan max depth sebesar 10. Hasil uji pada tahap testing menunjukkan peningkatan akurasi menjadi 62%. Harapannya, penelitian ini dapat memberikan kemudahan bagi masyarakat dalam mengenali batik Malang serta menjadi dasar bagi penerapan sistem lanjutan dalam klasifikasi batik dari Malang (Fahrani, 2023).

Penelitian yang berjudul "Ekstraksi Citra Fitur Pada Pengenalan Pola Motif Batik Sleman Menggunakan Metode Gray Level Co-Occurrence Matrix" mengeksplorasi penggunaan GLCM pada citra batik khas Sleman. Penelitian ini melibatkan 30 citra dengan 3 motif batik berbeda: pariyothon, salak pondoh, dan belut-salak. Metode ekstraksi fitur dilakukan menggunakan MATLAB R2016a dengan fokus pada energi, korelasi, homogenitas, dan kontras.

Tujuan penelitian ini adalah untuk membantu pengenalan motif batik khas Sleman melalui penggunaan GLCM dan algoritma decision tree. Penelitian ini mungkin mengalami kesulitan karena kurangnya pemahaman tentang motif batik, yang mengakibatkan kesulitan bagi masyarakat dalam mengenali motif tersebut (Fauzy, M. N., et al., 2019).

Penelitian yang berjudul "Metode K-Nearest Neighbor dan Ekstraksi Fitur GLCM untuk Mengklasifikasikan Biji Kopi Robusta dan Arabika Lokal" bertujuan untuk membedakan biji kopi Robusta dan Arabika melalui pengolahan citra digital. Penelitian ini, KNN dan GLCM digunakan untuk klasifikasi biji kopi tersebut. Dataset yang terdiri dari 194 gambar biji kopi (97 Robusta dan 97 Arabika) digunakan, dengan 174 data data latih dan 20 data data uji. Eksperimen ini berhasil mencapai akurasi tertinggi dengan ketentuan jarak piksel sebesar 1, nilai K sama dengan 1, dan besar sudut mencapai 45, persentasenya adalah 95%.^o (Jatmoko, C. & Sinaga. D., 2022).

Kedua metode ekstraksi fitur, yaitu Gray Level Co-Occurrence Matrix (GLCM) dan Local Binary Pattern (LBP), memiliki kelebihan masing-masing. GLCM mampu mengekstraksi informasi spasial dan detail tekstur yang mendalam dalam citra, namun sensitif terhadap perubahan orientasi dan membutuhkan komputasi yang memakan waktu. Di sisi lain, LBP efektif dalam mengenali tekstur kasar dan memiliki kecepatan komputasi yang lebih tinggi, tetapi kurang mampu menangkap detail halus serta rentan terhadap perubahan intensitas. Kombinasi atau penggunaan keduanya dalam suatu sistem pengolahan citra dapat meningkatkan keakuratan analisis dan identifikasi pola secara keseluruhan, tergantung pada jenis citra dan kebutuhan analisis yang diinginkan.

METODE

A. Dataset

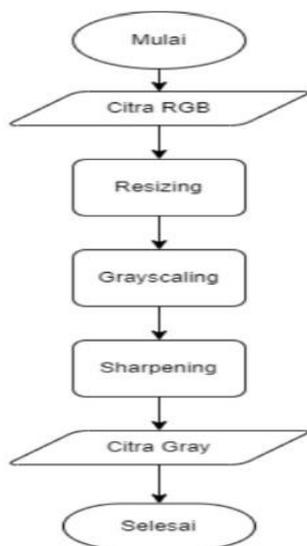
Sistem klasifikasi menggunakan citra batik sebagai data uji untuk menguji kinerja sistem. Citra Batik diperoleh dari <https://batik-tulis.com/blog/batik-tasikmalaya/> dari menjelajah secara acak di internet.



Gambar 1. Data Batik

B. Pemrosesan Data Awal (Pre-Processing)

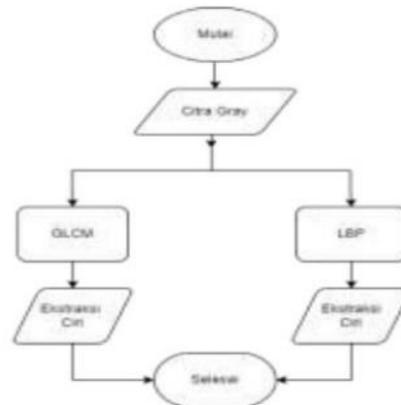
Proses awal Pengolahan data dimulai dengan citra yang berada dalam format RGB, yang kemudian secara manual disesuaikan atau diatur. diubah ukurannya agar memiliki dimensi 320 x 240 piksel, lalu diubah menjadi citra skala abu-abu (grayscale).



Gambar 2. Pre-Processing

Dalam proses pengambilan nilai tekstur, digunakan metode GLCM dan LBP. Selanjutnya, dilakukan ekstraksi ciri

tekstur untuk mendapatkan nilai yang menjadi acuan dalam analisis atau klasifikasi selanjutnya.

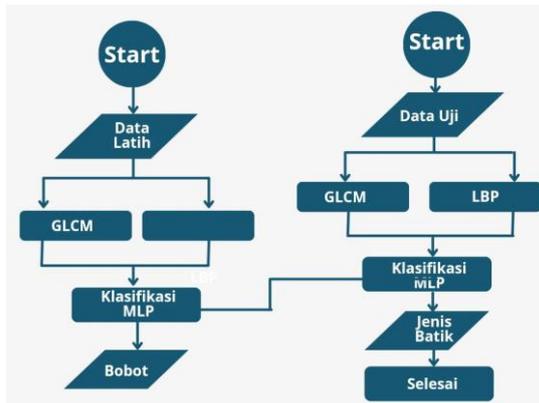


Gambar 3. Pengambilan Nilai Tekstur

Dalam proses klasifikasi untuk mengidentifikasi jenis citra batik Sukapura, Merak Ngibing, Sidomukti Payung, dan Lancah Tasik, digunakan metode MLP. Proses klasifikasi ini melibatkan pengambilan atau penentuan ciri-ciri yang relevan menggunakan metode GLCM dan LBP, dan menghasilkan fitur-fitur seperti korelasi, kontras, energi, dan homogenitas dari citra tersebut. Hasil dari fitur-fitur ini kemudian dijadikan masukan untuk MLP guna melakukan klasifikasi jenis batik.

C. Klasifikasi Menggunakan Multilayer Perceptron

Proses klasifikasi untuk mengidentifikasi jenis citra batik, terjadi tahap ekstraksi ciri menggunakan GLCM dan LBP. Ekstraksi ini menghasilkan fitur-fitur seperti korelasi, kontras, energi, dan homogenitas dari citra batik. Selanjutnya, dilakukan tahap klasifikasi menggunakan metode MLP. Hasil dari fitur-fitur ekstraksi ciri GLCM dan LBP digunakan untuk masukan ke dalam MLP dan melakukan klasifikasi serta membedakan jenis batik yang diinginkan.



Gambar 4. Proses Klasifikasi MPL

D. Representasi Data

Data yang digunakan terpisah menjadi dua bagian, yakni data latih dan data uji. Data latih terdiri dari 40 citra batik yang digunakan untuk proses pelatihan model atau sistem digunakan untuk proses pembelajaran dalam sistem klasifikasi yang dibuat. Di sisi lain, terdapat data uji yang terdiri dari total 20 citra, yang digunakan untuk tujuan pengujian sistem yang telah dikembangkan, khususnya dalam mengukur tingkat akurasi hasil klasifikasi.

E. Konversi Citra RB Ke *Grayscale*

Pada tahap ini, citra batik khas Tasikmalaya, diakuisisi sebagai citra RGB. Citra dalam ruang warna RGB menggunakan tiga komponen warna: merah, hijau, dan biru. Pixel direpresentasikan dengan penggabungan intensitas dari ketiga komponen warna tersebut untuk menentukan warna pada pixel tersebut.

$$Grayscale = 0.299 \times r + 0.587 \times g + 0.114 \times b$$

Dalam representasi citra dalam ruang warna RGB, variabel r menunjukkan tingkat kecerahan warna merah, g menunjukkan tingkat kecerahan warna hijau, dan b menunjukkan tingkat kecerahan warna biru. Kombinasi nilai-nilai ini menggambarkan warna pada setiap pixel citra.

F. Ekstraksi Fitur GLCM (Gray-Level Co-occurrence Matrix)

GLCM merupakan sebuah metode ekstraksi fitur yang melibatkan beberapa

parameter, yaitu kontras, Inverse Difference Moment (IDM), korelasi, varians, sum varians, sum rata-rata, difference varians, Angular Second Moment (ASM), entropi, sum entropi, dan difference entropi. Parameter-parameter ini digunakan untuk menggambarkan pola tekstur pada citra (Efendi, et al., 2019).

G. Angular Second Moment (ASM)

Untuk menghitung ASM sebagai skala homogenitas dari suatu citra, rumus yang digunakan adalah:

$$ASM = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P(i, j)^2$$

Dimana P(i, j) adalah probabilitas kemunculan pasangan intensitas pixel pada GLCM pada posisi (i, j) dan (N) adalah jumlah tingkat keabuan pada citra.

H. Kontras

Kontras dalam citra berskala keabuan dapat diukur dengan menggunakan perbandingan antara perbedaan nilai intensitas maksimum dan minimum dalam citra terhadap jumlah nilai intensitas keduanya. Rumus umum untuk menghitung kontras adalah:

$$Kontras = \sum_{n=1}^L n^2 \left\{ \sum_{|i-j|=n} GLCM(i, j) \right\}$$

I. Korelasi

Korelasi dalam konteks citra menunjukkan sejauh mana nilai-nilai keabuan di antara pixel-pixel yang berdekatan menunjukkan hubungan linier. Ini membantu dalam mengidentifikasi pola atau struktur linier dalam citra. Semakin tinggi korelasi antar pixel, semakin besar kecenderungan bahwa nilai keabuan mereka memiliki hubungan linier atau pola struktural yang terlihat dalam gambar. Untuk mencari nilai korelasi dapat digunakan rumus :

$$Korelasi = \frac{\sum_{i=1}^L \sum_{j=1}^L (i,j)(GLCM(i,j) - \mu_i' \mu_j')}{\sigma_i' \sigma_j'}$$

$$\mu_i' = \sum_{i=1}^L \sum_{j=1}^L i \times GLCM(i,j)$$

$$\mu_j' = \sum_{i=1}^L \sum_{j=1}^L j \times GLCM(i,j)$$

$$\sigma_j^2 = \sum_{i=1}^L \sum_{j=1}^L GLCM(i,j) (i - \mu_j')^2$$

$$\sigma_i^2 = \sum_{i=1}^L \sum_{j=1}^L GLCM(i,j) (i - \mu_i')^2$$

J. Homogeneity

Inverse Different Moment (IDM) yang juga sering disebut sebagai homogenitas lokal, adalah kebalikan dari bobot kontras, yang menghasilkan nilai yang tinggi jika ada keseragaman piksel yang sama pada saat ASM memiliki nilai yang konsisten. Persamaan 10 digunakan untuk menghitung nilai IDM dalam proses ekstraksi fitur.

Dalam konteks penelitian ini, parameter yang diukur termasuk vektor kontras, korelasi, energi, dan homogenitas digunakan untuk menganalisis dan menafsirkan tekstur citra. Masing-masing fitur memiliki peran yang berbeda bergantung pada penggunaannya. Fitur kontras mengukur perbedaan intensitas piksel, korelasi menggambarkan hubungan antara piksel, energi mengukur kekuatan pola dalam citra, dan homogenitas menunjukkan tingkat keseragaman piksel. Keseluruhan, penggunaan fitur-fitur ini membantu dalam pemahaman yang lebih baik tentang sifat tekstur dalam citra.

K. Local Binary Pattern (LBP)

LBP telah diperkenalkan pada tahun 1994 oleh Timo Ojala, Matti Pietikäinen, dan David Harwood di Universitas Oulu di Finlandia. Teknik ini telah menjadi populer dalam pengolahan citra karena kemampuannya untuk mengekstrak fitur-fitur tekstur yang kuat dan berguna untuk berbagai aplikasi pengolahan citra sebagai deskriptor untuk membedakan tekstur dalam gambar.

Metode LBP membandingkan nilai piksel di pusat gambar memiliki 8 nilai piksel yang berbeda. di sekelilingnya dalam citra berukuran 3x3. Proses ini melibatkan perbandingan intensitas piksel pusat dengan intensitas piksel di titik pusat lebih tinggi daripada intensitas piksel di sekitarnya., nilai yang dihasilkan adalah 1; sebaliknya, jika intensitas pusat lebih kecil atau sama dengan piksel sekelilingnya, nilai yang dihasilkan adalah 0. Dengan 8 piksel di sekelilingnya, terdapat 256 kemungkinan kombinasi kode Local Binary Pattern yang berbeda untuk memetakan pola tekstur dalam citra. Teknik ini memungkinkan ekstraksi fitur tekstur yang kuat dan berguna dalam berbagai aplikasi pengolahan citra.

$$LBP_{R,P} = \sum_{p=0}^{P-1} s(g_p - g_c) \cdot 2^p$$

Binary threshold function $s(x)$,

$$s(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$$

Keterangan :

R	: radius
P	: sampling poin
g_p	: piksel ketetanggan
g_c	: piksel pusat
s	: fungsi s

L. Jaringan Syaraf Tiruan (JST)

Cara kerja dari pendekatan ini yaitu dengan melakukan latihan pada sebuah JST menggunakan nilai-nilai fitur dari data latih yang telah diberikan. Dengan melakukan ini, Sistem yang dibuat dengan menggunakan JST dapat mengategorikan data sesuai dengan informasi yang diperoleh dari proses pelatihan yang diberikan ke dalam kategori-kategori yang telah ditentukan sebelumnya.

Fitur-fitur yang dijadikan sebagai input dalam pelatihan JST adalah ASM, kontras, IDM, entropi, dan korelasi. Setiap fitur dihitung berdasarkan arah 0° , 45° , 90° , dan 135° , menggambarkan sifat tekstur dalam berbagai arah. Algoritma yang digunakan dalam JST ini adalah Levenberg-Marquardt, yang merupakan metode optimasi yang sering digunakan dalam melatih JST untuk mengoptimalkan prediksi dan klasifikasi data. Algoritma pelatihan JST Levenberg-Marquardt meliputi :

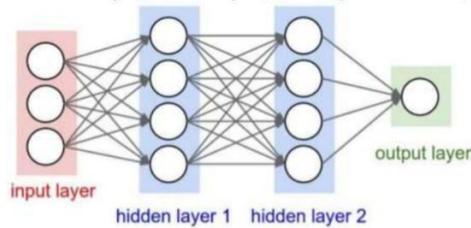
Inisialisasi jaringan random bobot v, w .
 Hitung maju pada *hidden layer* dan *output*.
 $z_j = f(v \cdot in)$
 $y_k = f(w \cdot z_j)$
 Hitung sse
 $sse = \sum_{k=1}^p \frac{1}{2} (t_k - y_k)^2$
 Hitung Matrik Jacobin $J(x)$.
 $x \Rightarrow$ bobot dan bias
 Hitung selisih bobot.
 $\Delta x = [J^T J + \mu I]^{-1} J^T e$
 Koreksi pembobot
 $x = x + \Delta x$
 $E_{new} < E_{step 3}$
 Jika ya, ulangi langkah 3.
 Jika tidak,
 ~ *increase*: $(\mu \times \beta)$
 ~ *reduce*: (μ / β)
 Sampai $e = error\ limit$. Selesai.

M. Multilayer Perceptron (MLP)

MLP (Multilayer Perceptron) adalah sebuah jenis arsitektur dari jaringan saraf tiruan terdiri dari beberapa lapisan neuron atau node yang saling terhubung secara penuh (fully connected). Arsitektur MLP terdiri dari tiga lapisan utama:

1. Lapisan input: Menerima data masukan yang akan diproses oleh jaringan.
2. Satu atau lebih lapisan tersembunyi: Melakukan pemrosesan data dengan melakukan komputasi di antara lapisan-lapisan ini untuk mengekstrak pola dan fitur dari data yang diberikan.
3. Lapisan output: Menghasilkan prediksi atau output berdasarkan proses yang dilakukan oleh lapisan tersembunyi, yang dapat berupa klasifikasi, regresi, atau tugas lainnya tergantung pada jenis masalah yang diselesaikan.

Setiap neuron pada satu lapisan memiliki koneksi ke setiap neuron di lapisan berikutnya dengan nilai bobot yang mengatur kekuatan koneksi antar neuron. Proses ini memungkinkan MLP untuk belajar dari data, menyesuaikan bobot koneksi antar neuron, dan membuat prediksi yang akurat untuk berbagai jenis masalah seperti klasifikasi dan prediksi. MLP menggunakan teknik pembelajaran dengan propagasi mundur (backpropagation) untuk memperbarui bobot-bobot ini berdasarkan kesalahan prediksi yang dihasilkan, sehingga memungkinkan jaringan untuk belajar



Gambar 5. Arsitektur MLP

Sebuah MLP memiliki lapisan (kotak merah dan biru) yang masing-masing. Setiap lapisan dalam MLP terdiri dari sejumlah neuron (lingkaran putih). Jaringan ini menerima data input satu dimensi dan mengirimkannya melalui koneksi antar neuron untuk menghasilkan output. Tiap koneksi antar neuron pada lapisan yang berdekatan, mempunyai bobot satu ukuran yang menetapkan seberapa baiknya model bekerja. Pada setiap lapisan, operasi linier dilakukan dengan bobot yang relevan pada data input, kemudian hasilnya melewati transformasi non-linear melalui fungsi aktivasi. Itulah bagaimana perhitungan di dalam MLP berlangsung secara manual.

HASIL DAN PEMBAHASAN

Aplikasi klasifikasi batik yang memanfaatkan metode GLCM dan LBP dikembangkan menggunakan platform pemrograman MATLAB. Aplikasi ini menyajikan antarmuka pengguna berupa GUI yang user-friendly. Terbagi MLP melibatkan serangkaian langkah yang mencakup proses citra RGB, konversi citra ke grayscale, ekstraksi ciri, dan presentasi hasil prediksi. Hal ini memudahkan pengguna untuk melakukan proses pengolahan gambar, ekstraksi ciri, dan melihat hasil prediksi terkait jenis batik dari citra yang diinputkan.

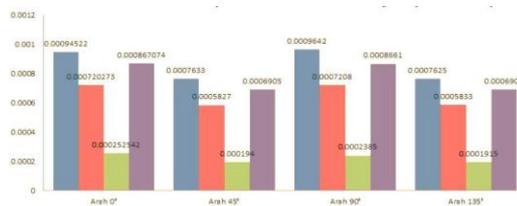
A. Angular Second Moment (ASM)

Dalam tabel 1, terdapat hasil ekstraksi fitur ASM dari lima sampel untuk setiap motif batik pada empat arah yang berbeda: 0°, 45°, 90°, dan 135°.

Tabel 1. Hasil Ekstraksi Fitur ASM

Arah 0°	Arah 45°	Arah 90°	Arah 135°
16.198938	30.438890	20.782856	29.470019
17.010143	31.332863	21.204135	30.240714
24.906312	37.158447	20.439770	37.690183
30.547530	50.261362	29.176047	51.510190
25.686195	43.745497	23.934362	38.638914
28.775954	47.746033	33.014238	50.181006
33.448831	62.242303	43.737555	63.377652
45.311910	93.496728	67.061028	92.735329
51.187699	125.723161	95.032329	122.665092
56.286669	81.370067	64.384169	114.821021
66.938851	159.301845	89.996071	108.089614
55.478832	99.020091	76.716097	124.931800
53.045903	134.402578	98.737989	127.723817
62.957285	127.181164	73.966927	102.399501
80.860087	121.276801	82.837827	145.098113
28.366987	41.550267	24.230051	39.504565
29.778100	44.006624	30.444895	49.865516
23.359968	38.318721	26.418949	37.539350
25.675387	40.605483	28.261260	42.864109
38.335594	61.076136	36.593912	58.841337

Dari hasil ekstraksi ASM, nilai rata-rata dari fitur ASM pada motif Sukapura menunjukkan nilai yang lebih tinggi dibandingkan dengan motif Lancar Tasik. Nilai-nilai tersebut adalah 0.00094522 untuk arah 0°, 0.0007633 untuk arah 45°, 0.0009642 untuk arah 90°, dan 0.0007625 untuk arah 135°. Ini menandakan bahwa citra batik motif Sukapura memiliki tingkat homogenitas yang lebih besar dibandingkan dengan motif Lancar Tasik. Hal ini mengindikasikan variasi yang lebih rendah antara piksel-pikselya dalam motif Sukapura. Grafik yang menunjukkan rata-rata fitur ASM untuk tiap motif batik dari dataset pengujian dapat ditemukan pada Gambar 6.



Gambar 6. Grafik Nilai Rata Rata ASM

B. Menghitung Kontras

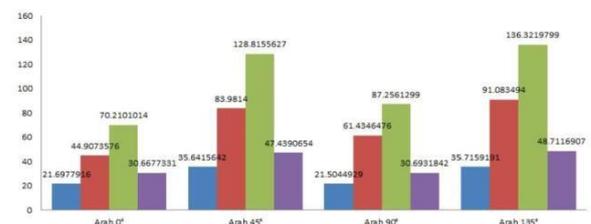
Fitur kontras diekstraksi dari setiap citra batik untuk kemudian digunakan sebagai input dalam model JST yang sudah dirancang. Tabel 2 menampilkan output ekstraksi fitur kontras dari 5 sampel pada setiap motif batik. pada

empat arah yang berbeda (0°, 45°, 90°, dan 135°).

Tabel 2. Kontras

Arah 0°	Arah 45°	Arah 90°	Arah 135°
0.000992153	0.000785	0.000970	0.000787
0.000934747	0.000742	0.000920	0.000748
0.000843516	0.000693	0.000894	0.000692
0.000801265	0.000648	0.000832	0.000643
0.000858279	0.000690	0.000888	0.000704
0.001071838	0.000865	0.001077	0.000865
0.001083942	0.000874	0.001087	0.000876
0.000618167	0.000497	0.000615	0.000500
0.000631339	0.000509	0.000628	0.000512
0.000642452	0.000524	0.000645	0.000521
0.000270687	0.000201	0.000254	0.000212
0.000278319	0.000214	0.000258	0.000206
0.000279427	0.000203	0.000247	0.000204
0.000265191	0.000203	0.000256	0.000208
0.000850731	0.000689	0.000887	0.000697
0.00081763	0.000654	0.000812	0.000642
0.000898185	0.000706	0.000866	0.000707
0.000849849	0.000670	0.000830	0.000668
0.000786475	0.000617	0.000791	0.000627
0.000992153	0.000785	0.000970	0.000787

Dari data ekstraksi kontras, nilai rata-rata fitur kontras pada motif Sukapura menunjukkan nilai yang lebih tinggi, yaitu sebesar 70.2101014 untuk arah 0°, 128.8155627 untuk arah 45°, 87.2561299 untuk arah 90°, dan 136.3219799 untuk arah 135°. Ini menunjukkan bahwa citra batik motif Sukapura memiliki variasi intensitas yang lebih besar antar pikselnya dibandingkan dengan motif Lancar Tasik yang menunjukkan kontras yang relatif lebih rendah. Grafik yang menunjukkan rata-rata fitur kontras untuk tiap motif batik dari dataset pengujian dapat ditemukan pada Gambar 7.



Gambar 7. Kontras

C. Menghitung Korelasi

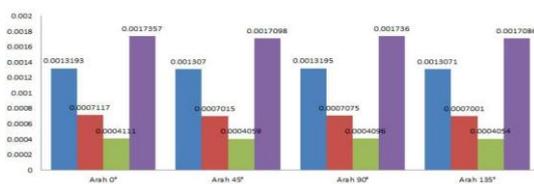
Fitur korelasi diekstraksi dari tiap citra batik digunakan sebagai input dalam model JST yang telah dibuat. Tabel 3 menampilkan ekstraksi fitur korelasi dari lima contoh untuk setiap motif batik dengan empat arah yang berbeda (0°, 45°, 90°, dan 135°).

90°, dan 135°).

Tabel 3. Korelasi

Arah 0°	Arah 45°	Arah 90°	Arah 135°
0.001271	0.001259	0.001267	0.001260
0.001276	0.001264	0.001273	0.001266
0.001171	0.001162	0.001174	0.001162
0.001112	0.001099	0.001113	0.001098
0.001279	0.001264	0.001280	0.001268
0.000846	0.000839	0.000845	0.000839
0.000825	0.000815	0.000821	0.000815
0.000686	0.000674	0.000680	0.000674
0.000690	0.000671	0.000679	0.000672
0.000682	0.000676	0.000680	0.000668
0.000413	0.000405	0.000411	0.000410
0.000427	0.000422	0.000425	0.000420
0.000418	0.000410	0.000414	0.000411
0.000423	0.000418	0.000422	0.000420
0.000398	0.000395	0.000398	0.000393
0.001803	0.001781	0.001811	0.001785
0.001643	0.001623	0.001643	0.001615
0.001871	0.001844	0.001866	0.001846
0.001594	0.001574	0.001591	0.001572
0.001429	0.001404	0.001431	0.001407

Dari data ekstraksi korelasi, nilai rata-rata fitur kontras pada motif Sukapura menunjukkan nilai yang lebih tinggi, yaitu 0.0017357 untuk arah 0°, 0.0017098 untuk arah 45°, 0.001736 untuk arah 90°, dan 0.0017086 untuk arah 135°. Ini menunjukkan bahwa motif Sukapura atau Motif Merak Ngibing memiliki tingkat ketergantungan linear antara aras keabuan yang lebih besar dibandingkan dengan motif Sidomuki Payung, yang menunjukkan nilai yang relatif lebih rendah. Grafik yang menampilkan nilai rata-rata dari fitur korelasi untuk tiap motif batik dari dataset pengujian dapat ditemukan pada Gambar 8.



Gambar 8. Korelasi

Setelah tahap ekstraksi fitur, dilakukan klasifikasi menggunakan JST untuk mengategorikan setiap citra batik berdasarkan kelas atau label motifnya. Hasil klasifikasi terhadap 20 citra data uji menunjukkan bahwa seluruhnya berhasil diklasifikasikan dengan tepat. Oleh karena itu, akurasi yang diperoleh adalah 100%, di mana seluruh citra berhasil

diklasifikasikan dengan benar dari total citra uji yang ada.

D. Uji Coba Batik Dengan GLCM

Di bawah ini adalah hasil implementasi klasifikasi jenis batik dengan menggunakan metode GLCM pada 20 data uji.

Tabel 4. Hasil Prediksi GLCM

No	Ekstraksi Ciri				Hasil Prediksi
	Contrast	Correlation	Energy	Homogeneity	
1	15497.2477655756	0.00183281222914176	1.33122415657829e-05	0.0308466189944586	Sukapura
2	15389.8394252594	0.000151398723289688	1.31644545703200e-05	0.0307942530986617	Sukapura
3	15590.0055124623	-0.00160819331143411	1.33335907962211e-05	0.0307613667503102	Sukapura
4	15552.0066774179	-0.00190854104520068	1.33334265765156e-05	0.0308375262073314	Sukapura
5	15576.2610423831	0.000330812408892348	1.33619256360483e-05	0.0307679389654262	Sukapura
6	15472.6519479846	-0.000711816102331167	1.31882357507903e-05	0.0308069815957289	Sukapura
7	15447.3190887948	-0.00213811456789091	1.32028615274810e-05	0.0308022221637997	Sukapura
8	15488.2048456330	-0.000439207541228986	1.32434724014231e-05	0.0307724125547740	Sukapura
9	15551.1775452712	-0.00213746385741600	1.33009048071707e-05	0.0307642349235312	Sukapura
10	15341.1563770530	0.000523875440275615	1.31507819178775e-05	0.0308232563698184	Sukapura
11	15684.6751142363	-0.000691166770122168	1.34820081533834e-05	0.0307101777348601	Merak Ngibing
12	15646.7912373239	0.00286486843604682	1.35525131007999e-05	0.0307900629319592	Merak Ngibing
13	15749.2591197185	-0.000629460108570286	1.34946203052232e-05	0.0306862086595289	Merak Ngibing
14	15535.3687288176	-0.00144333218272458	1.33710634300074e-05	0.0307459241681411	Merak Ngibing
15	15679.4240886090	0.000290946277494644	1.34567619244798e-05	0.0308161048340962	Merak Ngibing
16	15673.9990480210	0.000497167409013400	1.34334003364377e-05	0.0307504225050620	Lancang Tasik
17	15706.1242364631	-0.000281267723821390	1.35400673724676e-05	0.0307004640100461	Merak Ngibing
18	15597.0807544248	0.000919904105392656	1.34577555924673e-05	0.0307647798115378	Merak Ngibing
19	15659.3685677315	0.00118829306692803	1.34765815343420e-05	0.0307618846483481	Merak Ngibing
20	15599.6064760264	0.00186100018536975	1.35344169973312e-05	0.0307362434627812	Sidomuki Payung

Dari hasil prediksi pada Tabel 4 terhadap 20 data uji, 18 data diprediksi secara tepat dan 2 data memiliki prediksi yang salah. Pada Tabel 4, hasil prediksi yang tepat ditunjukkan dengan warna hijau sementara yang salah ditunjukkan dengan warna merah. Kemudian, dilakukan pengujian data uji yang memanfaatkan metode confusion matrix untuk prediksi tiga kelas. Dalam proses ini, akan dihitung nilai presisi, recall, spesifisitas, dan akurasi menggunakan data uji.

Tabel 5. Evaluasi Performa Confusion Matrix Metode GLCM

Three-Class Predicion	Sukapura	Predicted Class			
		Mera k Ngibing	Lan cah Tasi k	Sidom ukti Payun g	
Act ual	Sukapura	10	0	0	0

Class	Merak Ngibing	0	8	1	0
	Lancah Tasik	0	0	0	0
	Sidomukti Payung	0	0	0	1

True Positive 1 (TP1) = 10
 True Positive 2 (TP2) = 8
 True Positive 3 (TP3) = 0
 True Positive 4 (TP4) = 1
 True Negative 1 (TN1) = 8 + 0 + 0 + 1 = 9
 True Negative 2 (TN2) = 10 + 0 + 0 + 0 = 10
 True Negative 3 (TN3) = 10 + 0 + 0 + 8 = 18
 True Negative 3 (TN3) = 10 + 0 + 0 + 1 = 11
 False Positive 1 (FP1) = 0 + 0 = 0
 False Positive 2 (FP2) = 0 + 0 = 0
 False Negative 3 (FN3) = 0 + 0 = 0
 False Positive 4 (FN4) = 0 + 1 = 1
 Accuracy = $\frac{10+8+0+1}{10+0+0+0+0+0+8+0+0+0+0+1+0+0+0+0+1}$
 = $\frac{19}{20}$
 = 0.95 x 100%
 = 95%

$$\text{Precision 1} = \frac{TP1}{TP1+FP1} = \frac{10}{10+0} = 1$$

$$\text{Precision 2} = \frac{TP2}{TP2+FP2} = \frac{8}{8+0} = 1$$

$$\text{Precision 3} = \frac{TP3}{TP3+FP3} = \frac{0}{0+0} = 0$$

$$\text{Precision 4} = \frac{TP4}{TP4+FP4} = \frac{1}{1+1} = \frac{1}{2}$$

$$\text{Recall 1} = \frac{TP1}{TP1+FN1} = \frac{10}{10+0} = 1$$

$$\text{Recall 2} = \frac{TP2}{TP2+FN2} = \frac{8}{8+0} = 1$$

$$\text{Recall 3} = \frac{TP3}{TP3+FN3} = \frac{0}{0+0} = 0$$

$$\text{Recall 4} = \frac{TP4}{TP3+FN3} = \frac{1}{1+1} = \frac{1}{2}$$

$$\text{Specificity 1} = \frac{TN1}{TN1+FP1} = \frac{9}{9+0} = 1$$

$$\text{Specificity 2} = \frac{TN2}{TN2+FP2} = \frac{10}{10+0} = 1$$

$$\text{Specificity 3} = \frac{TN3}{TN3+FP3} = \frac{18}{18+0} = 1$$

$$\text{Specificity 4} = \frac{TN4}{TN4+FP4} = \frac{11}{11+1} = 0,916$$

Dari data yang ada pada tabel sebelumnya yang diolah menggunakan metode GLCM, hasilnya menunjukkan nilai akurasi sebesar 95%.

E. Uji Coba Menggunakan LBP

Di bawah ini adalah hasil implementasi klasifikasi jenis batik dengan menggunakan metode LBP.

Tabel 6. Hasil Prediksi LBP

No	LBP 1	LBP 2	LBP 3	LBP 4	LBP 5	LBP 6	LBP 7	LBP 8	LBP 9	LBP 10	Hasil Prediksi
1.	9903	9287	4174	3441	2994	3556	4473	9194	10553	18109	Sukapura
2.	6940	9896	4371	5130	5668	5563	5193	9753	8467	14703	Sukapura
3.	8261	9002	4681	4839	4606	5125	5247	8885	9047	15991	Sukapura
4.	8190	9118	4612	4857	4752	5137	5338	8969	8875	15836	Sukapura
5.	8261	9014	4612	4794	4829	5161	5112	9181	8883	15837	Sukapura
6.	7135	9368	4699	5294	5145	5698	5333	9411	8579	15022	Sukapura
7.	7013	9452	4468	5322	5388	5962	5276	9444	8400	14959	Sukapura
8.	6884	9237	4519	5529	5815	6256	5227	9468	8165	14584	Sukapura
9.	8638	9198	4597	4354	4116	4674	5127	9213	9341	16426	Sukapura
10.	6834	10296	4244	5136	5918	5439	5150	10042	8335	14290	Sukapura
11.	9202	9774	3844	3827	4243	4017	4190	9798	9748	17041	Sukapura
12.	9833	9532	3734	3474	3712	3813	4160	9478	10180	17768	Sukapura
13.	9066	9689	3817	3971	4390	4137	4229	9752	9620	17013	Merak Ngibing
14.	6693	11651	3463	4562	6957	4909	4144	11376	8015	13914	Merak Ngibing
15.	8956	10375	3477	3712	4522	4000	4079	10149	9541	16873	Merak Ngibing
16.	8648	10450	3548	3859	4746	4328	3961	10264	9343	16537	Sukapura
17.	9718	9591	3803	3497	3596	3850	4166	9626	10133	17704	Sidomukti Payung
18.	9861	9432	3687	3532	3635	3912	4202	9392	10164	17867	Sukapura
19.	9762	9609	3745	3504	3696	3778	4146	9501	10177	17766	Sukapura
20.	10115	9371	3746	3432	3440	3626	4072	9385	10391	18106	Sukapura

Berdasarkan hasil prediksi dari Tabel 6 terhadap 20 data uji, didapati bahwa 11 data diprediksi dengan benar dan 9 data memiliki hasil prediksi yang salah. Pada Tabel 6, hasil prediksi yang ditunjukkan dengan warna hijau menandakan prediksi yang benar, sementara yang berwarna merah menunjukkan prediksi yang salah. Kemudian, dilakukan pengujian data uji menggunakan metode confusion matrix untuk prediksi tiga kelas. Pengujian ini akan menghitung nilai presisi, recall, spesifisitas, dan akurasi berdasarkan data uji.

Tabel 7. Evaluasi Performa Confusion Matrix Metode LBP

Three-Class Predicion		Predicted Class			
		Sukapura	Merak Ngibing	Lan cah Tasi k	Sido mukti Payu ng
Actual Class	Sukapura	16	0	0	1
	Merak Ngibing	0	2	1	0
	Lan cah Tasik	0	0	0	0
	Sidomu kti	0	0	0	0

Payung				
--------	--	--	--	--

True Positive 1 (TP1) = 16
 True Positive 2 (TP2) = 2
 True Positive 3 (TP3) = 0
 True Positive 4 (TP4) = 0
 True Negative 1 (TN1) = 0 + 0 + 0 + 0 = 0
 True Negative 2 (TN2) = 16 + 0 + 0 + 0 = 16
 True Negative 3 (TN3) = 16 + 0 + 0 + 1 = 17
 True Negative 4 (TN4) = 16 + 0 + 0 + 0 = 16
 False Positive 1 (FP1) = 0 + 0 = 0
 False Positive 2 (FP2) = 0 + 1 = 1
 False Positive 3 (FP3) = 0 + 0 = 0
 False Positive 4 (FP4) = 0 + 0 = 0
 False Negative 1 (FN1) = 0 + 0 = 0
 False Negative 2 (FN2) = 0 + 1 = 1
 False Negative 3 (FN3) = 0 + 0 = 0
 False Positive 4 (FN4) = 0 + 0 = 0

Accuracy = $\frac{16+2+0+0}{16+0+0+1+0+2+1+0+0+0+0+0+0+0+0+0+0+0+0+0+0+0}$
 = $\frac{18}{20}$
 = 0.9 x 100%
 = 90%

Precision 1 = $\frac{TP1}{TP1+FP1} = \frac{16}{16+0} = 1$

Precision 2 = $\frac{TP2}{TP2+FP2} = \frac{2}{2+1} = 0,66$

Precision 3 = $\frac{TP3}{TP3+FP3} = \frac{0}{0+0} = 0$

Precision 4 = $\frac{TP4}{TP4+FP4} = \frac{0}{0+0} = 0$

Recall 1 = $\frac{TP1}{TP1+FN1} = \frac{16}{16+0} = 1$

Recall 2 = $\frac{TP2}{TP2+FN2} = \frac{2}{2+1} =$

$$\begin{aligned}
 & 0,66 \\
 \text{Recall 3} &= \frac{TP3}{TP3+FN3} = \frac{0}{0+0} = 0 \\
 \text{Recall 4} &= \frac{TP4}{TP3+FN3} = \frac{0}{0+0} = 0 \\
 \text{Specificity 1} &= \frac{TN1}{TN1+FP1} = \frac{0}{0+0} = 0 \\
 \text{Specificity 2} &= \frac{TN2}{TN2+FP2} = \frac{16}{16+1} = 0,94 \\
 \text{Specificity 3} &= \frac{TN3}{TN3+FP3} = \frac{17}{17+0} = 1 \\
 \text{Specificity 4} &= \frac{TN4}{TN4+FP4} = \frac{16}{16+0} = 1
 \end{aligned}$$

Berdasarkan informasi yang tertera pada tabel sebelumnya yang diolah dengan metode LBP, diperoleh nilai akurasi sebesar 90%.

SIMPULAN (PENUTUP)

Berdasarkan penelitian yang dilakukan, ditemukan bahwa penerapan metode GLCM dan LBP dalam klasifikasi jenis batik menggunakan 40 data latih menghasilkan akurasi sebesar 100%. Meskipun demikian, pada pengujian dengan 20 data uji, metode GLCM memberikan akurasi sebesar 95%, sedangkan metode LBP menghasilkan akurasi sebesar 90%. Dari hasil pengujian tersebut, dapat disimpulkan bahwa metode GLCM memiliki performa akurasi yang lebih tinggi daripada metode LBP dalam klasifikasi jenis batik menggunakan multilayer perceptron. Hal ini menunjukkan bahwa ekstraksi ciri tekstur batik dengan metode GLCM memberikan hasil yang lebih baik dalam penggunaan multilayer perceptron untuk klasifikasi jenis batik.

UCAPAN TERIMA KASIH

Terima kasih kepada para penulis yang telah menyumbangkan pengetahuan dan riset terbaik mereka, menjadikan jurnal ini sumber informasi yang berharga.

DAFTAR PUSTAKA

- Tripasetyo, A. W., Pamungkas, D. P., & Wulanningrum, R. (2018). Aplikasi Pengenalan Pola Batik Trenggalek Menggunakan Deteksi Tepi Sobel Dan Algoritma KMeanS,” *Generation Journal*, 2(2), 25-32. <https://doi.org/10.29407/gj.v2i2.12247>
- Surya, R. A., Fadlil, A., & Yudhana, A. (2017). Ekstraksi Ciri Metode Gray Level Co-Occurrence Matrix (GLCM) dan Filter Gabor Untuk Klasifikasi Citra Batik Pekalongan. *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 02, no. 02, pp. 23–26, Jul. 2017, doi: <http://dx.doi.org/10.30591/jpit.v2i2.520.g556>.
- Surya, R. A., Fadlil, A., & Yudhana, A. (2016). Ekstraksi Ciri Citra Batik Berdasarkan Tekstur Menggunakan Metode Gray Level Co Occurrence Matrix. *Prosiding Annual Research Seminar*, vol. 2, no. 1, pp. 146–150, Desember 2016.
- Andono, P. N., & Rachmawanto, E. H. (2021). Evaluasi Ekstraksi Fitur GLCM dan LBP Menggunakan Multikernel SVM untuk Klasifikasi Batik. *RESTI*, vol. 5, no. 1, pp. 1–9, Feb. 2021, doi: [10.29207/resti.v5i1.2615](https://doi.org/10.29207/resti.v5i1.2615)
- Kaswar, A. B., et al. (2020). Klasifikasi Tingkat Kematangan buah Markisa Menggunakan Jaringan Syaraf Tiruan Berbasis Pengolahan Citra Digital. *Journal of Embedded System Security and Intelligent System*, vol. 01, no. 1, pp. 1–8, May 2020.
- Efendi, et al.. (2021). Pengelompokan Jenis

- Tekstur Kayu Menggunakan k-Nearest Neighbor dan Ekstraksi Fitur Histogram. *Jurnal VOI (Voice Of Informatics)*, 2017, 6.2.
- Neneng, et al. (2021). Klasifikasi Jenis Kayu Menggunakan Support Vector Machine Berdasarkan Ciri Tekstur Local Binary Pattern. *CYBERNETICS*, 2021, 4.02: 93-100.
- Putra, I. W. S. E. (2019). Klasifikasi citra menggunakan convolutional neural network (CNN) pada caltech 101. 2016. PhD Thesis. Institut Teknologi Sepuluh Nopember.
- Walisyah, et al. (2019). Perbandingan Akurasi Klasifikasi Citra Kayu Jati Menggunakan Metode Naive Bayes dan k-Nearest Neighbor (k-NN). *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, 2019, 5.2: 157-163.
- Wibowo, et al. (2021). Klasifikasi Jenis Kayu Menggunakan Ekstraksi Fitur GLCM dan Multilayer Perceptron. *Jurnal Nasional Teknik Elektro*, 2021, 10.1: 1–10.
- Wibowo, F & A. Harjoko. (2018). Klasifikasi Mutu Pepaya Berdasarkan Ciri Tekstur GLCM Menggunakan Jaringan Saraf Tiruan. *Khazanah Inform. J. Ilmu Komput. dan Inform.*, Vol. 3, No. 2, Hal. 100, 2018, doi: 10.23917/khif.v3i2.4516.
- Suteja, B. (2007). Penerapan Jaringan Saraf Tiruan Propagasi Balik Studi Kasus Pengenalan Jenis Kopi. *J. Inform.*, Vol. 3, No. 1, Hal. 49–62, 2007.
- Rivan, M. E., & T. Juangkara. (2019). Identifikasi Potensi Glaukoma dan Diabetes Retinopati Melalui Citra Fundus Menggunakan Jaringan Saraf Tiruan. *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, Vol. 6, No. 1, Hal. 43–48, 2019, doi:10.35957/jatisi.v6i1.158.
- LF. S. Ni'mah, T. Sutojo, & D. R. I. M. Setiadi (2018). Identification of Herbal Medicinal Plants Based on Leaf Image Using Gray Level Co-occurrence Matrix and K-Nearest Neighbor Algorithms. *J. Teknol. dan Sist. Komput.*, Vol. 6, No. 2, Hal. 51–56, 2018, doi: 10.14710/jtsiskom.6.2.2018.51-56.
- Suhendri, S., & Rahayu, P. (2019). Metode Grayscale Co-occurrence Matrix (GLCM) Untuk Klasifikasi Jenis Daun Jambu Air Menggunakan Algoritma Neural Network. *J. Inf. Technol.*, Vol. 1, No. 1, Hal. 15–22, 2019, doi: 10.47292/joint.v1i1.4
- Rivan, M. E., Rachmat, N., & Ayustin, M. R. (2020). Klasifikasi Jenis Kacang-kacangan Berdasarkan Tekstur Menggunakan Jaringan Saraf Tiruan. *J. Komput. Terap.*, Vol. 6, No. 1, hal. 89–98, 2020.
- Rahmadewi, R., Purwanti, E., & V. Efelina. (2018). Identifikasi Jenis Tumbuhan Menggunakan Citra Daun Berbasis Jaringan Saraf Tiruan (*Artificial Neural Networks*). *J. Media Elektro*, Vol. VII, No. 2, hal. 38–43, 2018, doi: 10.35508/jme.v0i0.427.
- Agmalaro, M. A., Kustiyo, A., & Akbar, A. R. (2013). Identifikasi Tanaman Buah Tropika Berdasarkan Tekstur Permukaan Daun Menggunakan Jaringan Saraf Tiruan. *J. Ilmu Komput. dan Agri-Informatika*, Vol. 2, No. 2, Hal. 73, 2013, doi: 10.29244/jika.2.2.73-82.
- Kasim, A. A., & Harjoko, A. (2014). Klasifikasi Citra Batik Menggunakan Jaringan Saraf Tiruan Berdasarkan Gray Level Co-Occurrence Matrices (GLCM). *Semin. Nas. Apl. Teknol. Inf. Yogyakarta*, 21 Juni 2014, Hal. 7–13, 2014.
- Rivan, M. E., & Noviardy, M. T. (2020). Klasifikasi American Sign Language Menggunakan Ekstraksi Fitur Histogram of Oriented Gradients dan Jaringan Saraf

- Tiruan. J. Tek. Inform. dan Sist. Inf., Vol. 6, No. 3, Hal. 442–451, 2020, doi: 10.28932/jutisi.v6i3.2844.
- Farhani, H. A. S. (2023). Klasifikasi Batik Motif Malang Berdasarkan Nilai Ekstraksi Fitur Gray Level Co-occurrence Matrix Dengan Algoritma Decision Tree. <http://repository.um.ac.id/id/eprint/291736>
- Fauzy, M. N., Soedijono, B., & Sudarmawan (2019). Ekstraksi Citra Fitur Pada Pengenalan Pola Motif Batik Sleman Menggunakan Metode Gray Level Co-Occurrence Matrix. *J. INFORMA*, Vol. 5, No. 3, Hal. 2442-7942, 2019.
- Cahaya Jatmoko & Daurat Sinaga (2023). Metode K-Nearest Neighbor dan Ekstraksi Fitur GLCM untuk Mengklasifikasikan Biji Kopi Robusta dan Arabika Lokal. *Seminar Nasional Teknologi Dan Multidisiplin Ilmu (SEMNASTEKMU)*, 2(2), 353-366. <https://doi.org/10.51903/semnastekmu.v2i1.189>