

Klasifikasi Daun Herbal Berbasis Integrasi Fitur LBP dan Bentuk Menggunakan Random Forest

AMALIA PUTRI UTAMI¹, DOLLY INDRA^{2*}, FITRIYANI UMAR³

^{1,3} Program Studi Teknik Informatika, Universitas Muslim Indonesia, Indonesia

² Program Studi Sistem Informasi, Universitas Muslim Indonesia, Indonesia
Email: dolly.indra@umi.ac.id

Received 24 Desember 2025 | Revised 16 Maret 2026 | Accepted 14 April 2026

ABSTRAK

Identifikasi daun herbal secara manual sering mengalami kendala akibat kemiripan visual antarspesies yang berpotensi menimbulkan kesalahan pemanfaatan. Penelitian ini bertujuan mengklasifikasikan sepuluh jenis daun herbal menggunakan kombinasi fitur tekstur Local Binary Pattern (LBP) dan fitur bentuk, yaitu aspect ratio, eccentricity, circularity, dan convexity. Dataset terdiri dari 500 citra yang dibagi menjadi 400 data latih dan 100 data uji dengan rasio 80:20. Tahap pre-processing meliputi resize, konversi ke grayscale, dan Gaussian Blur untuk mengurangi noise. Segmentasi dilakukan menggunakan Otsu thresholding untuk memperoleh objek daun dan Canny Edge Detection untuk menonjolkan struktur tekstur. Proses klasifikasi menerapkan algoritma Random Forest dengan pengujian beberapa kombinasi parameter guna memperoleh model optimal. Hasil terbaik diperoleh pada model dengan $n_estimators=200$, $max_features=2$, $max_depth=none$, dan $min_samples_leaf=2$, yang menghasilkan akurasi 92%, precision 92%, recall 92%, dan F1-score 92%.

Kata kunci: Daun Tanaman Herbal; Fitur Bentuk; Fitur Tekstur; Klasifikasi Citra; Local Binary Pattern; Random Forest

ABSTRACT

Manual identification of herbal leaves often encounters challenges due to visual similarities among species, which can potentially lead to errors in their utilization. This study aims to classify ten types of herbal leaves using a combination of Local Binary Pattern (LBP) texture features and shape features, namely aspect ratio, eccentricity, circularity, and convexity. The dataset consists of 500 images divided into 400 training data and 100 testing data with an 80:20 ratio. The preprocessing stage includes resizing, grayscale conversion, and Gaussian Blur to reduce noise. Segmentation was performed using Otsu thresholding to extract the leaf object and Canny Edge Detection to enhance texture structures. The classification process applies the Random Forest algorithm with testing of several parameter combinations to obtain the optimal model. The best results were achieved with a model using $n_estimators=200$, $max_features=2$, $max_depth=none$, and $min_samples_leaf=2$, yielding an accuracy of 92%, precision of 92%, recall of 92%, and F1-score of 92%.

Keywords: Herbal Plant Leaves, Texture Features, Shape Features, Image Classification, Local Binary Pattern; Random Forest

1. PENDAHULUAN

Tanaman herbal merupakan jenis tumbuhan yang mengandung satu atau lebih senyawa aktif yang bermanfaat untuk perawatan kesehatan dan pengobatan (**Rahmawati et al., 2021**). Di Indonesia, terdapat sekitar 30.000 jenis tanaman herbal, namun hanya 1.200 di antaranya yang dimanfaatkan secara luas oleh masyarakat sebagai bahan pengobatan (**Basri et al., 2023**). Setiap jenis tanaman herbal memiliki karakteristik yang unik, termasuk pada bagian daunnya, yang sering kali digunakan dalam berbagai ramuan obat tradisional. Daun tanaman herbal dapat dibedakan berdasarkan tekstur dan bentuknya. Namun, banyak masyarakat yang kesulitan dalam mengidentifikasi dan mengklasifikasikan jenis daun tanaman tersebut (**Kasim et al., 2024**), terutama bagi mereka yang tidak memiliki pengetahuan khusus dalam bidang botani. Hal ini tentu dapat mempengaruhi pemanfaatan tanaman herbal yang optimal, karena kesalahan dalam identifikasi daun dapat berisiko pada efektivitas pengobatan yang diberikan.

Seiring dengan pesatnya perkembangan teknologi, khususnya dalam bidang pengolahan citra digital, kini telah memungkinkan untuk menciptakan sistem yang dapat mengklasifikasikan jenis daun tanaman herbal secara otomatis. Teknologi ini menggunakan metode pengenalan pola yang dapat mengidentifikasi ciri-ciri daun tanaman herbal berdasarkan tekstur dan bentuknya (**Melani Winandari et al., 2023**), (**Herdiansah et al., 2022**). Pengenalan pola ini menjadi penting karena persepsi manusia dalam mengidentifikasi jenis daun sering kali dipengaruhi oleh faktor subjektif dan pengalaman visual yang berbeda-beda, yang dapat menyebabkan kesalahan dalam klasifikasi.

Beberapa penelitian telah mengeksplorasi klasifikasi daun tanaman menggunakan pendekatan ekstraksi fitur tunggal dengan hasil yang bervariasi. Penelitian yang mengimplementasikan fitur *invariant moment* dan fitur geometri menggunakan metode *Naive Bayes Classifier* dan *K-Nearest Neighbor* (KNN) untuk klasifikasi daun herbal memperoleh akurasi masing-masing sebesar 75% dan 70,83% (**Lamasigi et al., 2020**). Di sisi lain, penelitian yang menerapkan ekstraksi fitur tekstur *Gray Level Co-Occurrence Matrix* (GLCM) dengan metode *Convolutional Neural Network* (CNN) dan *Naive Bayes* untuk klasifikasi daun katuk dan kelor pada 480 citra menunjukkan bahwa metode CNN mencapai akurasi, *precision*, *recall*, dan *f1-score* sebesar 98% (**Azzahra et al., 2023**). Penelitian-penelitian tersebut telah memberikan kontribusi penting dalam mengembangkan berbagai pendekatan klasifikasi daun tanaman. Namun, eksplorasi kombinasi fitur tekstur dan bentuk secara simultan masih terbatas dan memberikan peluang untuk penelitian lebih lanjut. Integrasi kedua jenis fitur ini berpotensi meningkatkan akurasi klasifikasi, terutama pada spesies dengan kemiripan visual tinggi yang memerlukan representasi fitur yang lebih komprehensif untuk membedakan karakteristik unik setiap jenis daun.

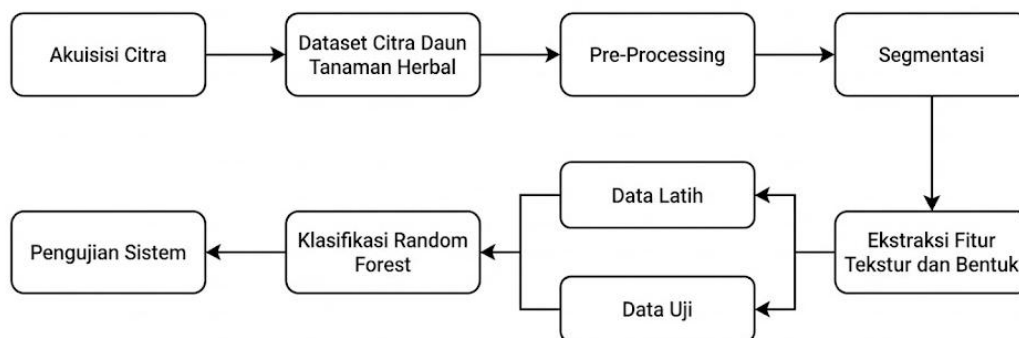
Untuk meningkatkan performa klasifikasi, diperlukan algoritma yang mampu menangani kompleksitas data dengan baik. Salah satu algoritma yang efektif untuk klasifikasi daun tanaman herbal adalah *Random Forest* (RF). Algoritma ini merupakan metode pembelajaran mesin yang mengklasifikasikan data menggunakan teknik *ensemble learning*, yang menggabungkan banyak pohon keputusan untuk menghasilkan hasil yang lebih akurat (**Mahmuda, 2024**). Keunggulan dari RF adalah kemampuannya dalam menghindari masalah *overfitting*, toleransinya terhadap data yang mengandung *noise*, serta kemampuannya dalam menangani klasifikasi dengan lebih dari dua kategori (*multi-class classification*) (**Ainun et al., 2023**). Keefektifan algoritma RF telah terbukti dalam berbagai aplikasi klasifikasi citra. Penelitian yang menggunakan algoritma RF untuk mendeteksi penderita COVID-19 berbasis citra CT-Scan dengan menggabungkan fitur Haralick dan *Color Histogram* menunjukkan akurasi terbaik sebesar 96,9% (**Wuryani & Sarifah, 2022**). Selanjutnya, penelitian yang

menerapkan metode RF dan ekstraksi fitur *Color Histogram* untuk mengklasifikasikan penyakit daun padi menghasilkan tingkat akurasi sebesar 99,65% (**Agustiani et al., 2022**). Hasil-hasil ini menunjukkan potensi RF dalam menangani klasifikasi berbasis citra dengan akurasi tinggi.

Oleh karena itu, penelitian ini bertujuan untuk mengklasifikasikan 10 jenis daun tanaman herbal menggunakan algoritma RF dengan mengombinasikan ekstraksi fitur tekstur dan fitur bentuk untuk meningkatkan akurasi identifikasi. Ekstraksi tekstur dilakukan menggunakan *LBP Binary Pattern* (LBP), yang mampu menggambarkan pola lokal pada permukaan daun melalui perubahan intensitas piksel secara akurat. Selain itu, fitur geometri seperti *aspect ratio*, *eccentricity*, *circularity*, dan *convexity* digunakan untuk merepresentasikan karakteristik bentuk daun yang bersifat unik pada setiap spesies. Integrasi kedua jenis fitur ini memberikan representasi citra yang lebih komprehensif sehingga mendukung proses klasifikasi secara lebih optimal. Berbeda dengan penelitian terdahulu yang umumnya mengandalkan fitur tunggal, kebaruan penelitian ini terletak pada integrasi simultan LBP dan fitur bentuk geometris dalam satu kerangka RF untuk 10 kelas daun herbal menggunakan dataset primer yang dikumpulkan secara langsung, sehingga lebih merepresentasikan kondisi nyata di lapangan. Diharapkan penelitian ini dapat berkontribusi dalam pengembangan sistem identifikasi otomatis daun tanaman herbal yang akurat dan efisien, serta membantu masyarakat dalam memanfaatkan tanaman herbal secara tepat untuk keperluan pengobatan tradisional.

2. METODE PENELITIAN

Penelitian ini menerapkan serangkaian tahapan yang meliputi akuisisi citra, *pre-processing*, segmentasi, ekstraksi fitur tekstur dan bentuk, klasifikasi menggunakan algoritma RF, serta pengujian sistem. Seluruh tahapan tersebut dilaksanakan secara sistematis dan berurutan. Bagan sistem klasifikasi yang diusulkan dapat dilihat pada Gambar 1.



Gambar 1. Bagan Sistem Klasifikasi yang Diusulkan

2.1. Akuisisi Citra

Langkah pertama dalam penelitian ini adalah melakukan akuisisi dataset citra daun tanaman herbal. Dataset terdiri dari 500 citra yang mencakup sepuluh jenis daun herbal, yaitu daun sirih, jambu biji, belimbing wuluh, katuk, sirsak, kemangi, bidara, salam, kumis kucing, dan binahong, dengan masing-masing jenis berjumlah 50 citra. Dataset dibagi menggunakan rasio 80:20, yaitu 400 citra sebagai data latih dan 100 citra sebagai data uji.

2.2. Pre-Processing

Pre-processing adalah suatu proses untuk menghilangkan *noise* pada citra, meningkatkan informasi, dan menyederhanakan data (**Zhou et al., 2020**). Dalam penelitian ini, *pre-processing* dilakukan melalui tiga tahapan utama, yaitu *resize*, konversi ke *grayscale*, dan

Gaussian Blur. Tahap pertama adalah melakukan *resize* dengan mengubah ukuran setiap citra menjadi 256×256 piksel. Ukuran ini dipilih untuk mengurangi beban komputasi sistem tanpa menghilangkan informasi penting dari citra dan memastikan bahwa seluruh citra memiliki dimensi yang konsisten, sehingga memudahkan model dalam mempelajari pola bentuk dan struktur daun secara optimal. Tahap kedua adalah konversi citra dari format RGB ke *grayscale*. Pada tahap ini, setiap piksel diubah menjadi satu nilai intensitas dalam rentang 0 hingga 255 dengan menghitung rata-rata dari tiga komponen warna dasar, yaitu merah (*red*), hijau (*green*), dan biru (*blue*). Proses ini menghasilkan citra *grayscale* yang lebih sederhana dan sesuai untuk ekstraksi fitur (**Thohari & Ramadhani, 2019**). Konversi citra RGB ke *grayscale* dapat dilakukan menggunakan Persamaan (1).

$$g = (0.21 R) + (0.71 G) + (0.07 B) \quad (1)$$

dengan g merupakan nilai *grayscale*, R merupakan komponen *red*, G merupakan komponen *green*, dan B merupakan komponen *blue*.

Tahap terakhir adalah penerapan *Gaussian Blur* untuk mengurangi *noise* dan detail yang tidak diperlukan sebelum proses segmentasi. *Gaussian Blur* bekerja dengan memberikan efek pengaburan pada citra melalui konvolusi dengan kernel Gaussian, sehingga membantu meningkatkan akurasi deteksi objek (**Abuya et al., 2023**). Teknik ini efektif dalam menghilangkan derau seperti titik-titik acak, sehingga hasil segmentasi menjadi lebih stabil dan konsisten. Persamaan *Gaussian Blur* ditunjukkan pada Persamaan (2).

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2)$$

dengan x dan y merupakan koordinat piksel pada citra, sedangkan σ merupakan standar deviasi yang mengontrol tingkat pengaburan.


2.3. Segmentasi

Pada tahap segmentasi, citra diproses untuk memisahkan objek daun dari latar belakang sekaligus mengekstraksi kontur batasnya. Segmentasi dalam penelitian ini dilakukan melalui dua metode, yaitu *Otsu Thresholding* dan *Canny Edge Detection*, yang masing-masing memiliki fungsi spesifik dalam proses ekstraksi fitur. Metode *Otsu Thresholding* digunakan untuk memisahkan objek daun dan latar belakang pada citra *grayscale* dengan menentukan nilai ambang optimal berdasarkan distribusi intensitas piksel. Metode ini bekerja dengan memaksimalkan varians antar kelas sehingga objek dan latar belakang dapat terpisah secara optimal (**Indra et al., 2018**). Hasil dari *Otsu Thresholding* berupa citra biner yang digunakan sebagai dasar untuk ekstraksi fitur bentuk. Selanjutnya, *Canny Edge Detection* diterapkan untuk mendeteksi tepi daun secara lebih presisi. Metode ini dipilih karena kemampuannya dalam menghasilkan deteksi tepi yang akurat, lokalisasi yang tepat, serta respon tepi tunggal yang minimal terhadap *noise* (**Nugroho et al., 2025**). Hasil deteksi tepi ini digunakan sebagai dasar untuk ekstraksi fitur tekstur, karena dapat menonjolkan struktur dan pola permukaan daun dengan lebih jelas.

2.4. Ekstraksi Fitur Tekstur dan Bentuk

Pada penelitian ini, fitur citra diekstraksi menggunakan dua jenis karakteristik, yaitu fitur tekstur dan fitur bentuk. Kombinasi kedua jenis fitur ini bertujuan untuk menghasilkan representasi citra yang lebih komprehensif dalam proses klasifikasi. Ekstraksi fitur tekstur dilakukan menggunakan metode LBP, sedangkan fitur bentuk diekstraksi melalui empat parameter geometris, yaitu *aspect ratio*, *eccentricity*, *circularity*, dan *convexity*.

LBP merupakan metode ekstraksi fitur tekstur yang bekerja dengan membandingkan intensitas piksel pusat dengan piksel-piksel tetangganya dalam matriks 3×3. Setiap piksel tetangga yang memiliki nilai intensitas lebih besar atau sama dengan piksel pusat diberi kode biner 1, sedangkan piksel dengan nilai lebih kecil diberi kode biner 0. Delapan nilai biner tersebut kemudian disusun searah jarum jam dan dikonversi menjadi nilai desimal sebagai representasi tekstur dari piksel pusat (Lamasigi et al., 2020). Operator dasar ekstraksi fitur LBP ditunjukkan pada Gambar 2.



Gambar 2. Contoh Operator Dasar Ekstraksi Fitur LBP (Kumar et al., 2023)

Ekstraksi fitur bentuk dilakukan untuk merepresentasikan karakteristik geometris daun yang bersifat unik pada setiap spesies. Empat fitur bentuk yang digunakan dalam penelitian ini adalah sebagai berikut:

1) *Aspect Ratio*

Aspect ratio menggambarkan proporsi dimensi daun dengan membandingkan lebar terhadap panjangnya. Nilai ini mengindikasikan apakah bentuk daun cenderung memanjang, melebar, atau mendekati bentuk persegi. Perhitungan *aspect ratio* dapat dilihat pada Persamaan (3).

$$Aspect\ Ratio = \frac{width}{height} \tag{3}$$

dengan *Width* merupakan lebar objek daun dan *Height* merupakan tinggi objek daun.

2) *Eccentricity*

Eccentricity menunjukkan tingkat kelonjongan suatu objek berbasis elips yang paling sesuai dengan bentuk objek tersebut. Nilai *eccentricity* mendekati 0 menunjukkan bentuk yang hampir bulat, sedangkan nilai mendekati 1 menunjukkan bentuk yang semakin lonjong atau memanjang. Perhitungan *eccentricity* dapat dilihat pada Persamaan (4).

$$Eccentricity = \sqrt{1 - \left(\frac{b}{a}\right)^2} \tag{4}$$

dengan *a* merupakan sumbu semi-mayor (panjang) dan *b* merupakan sumbu semi-minor (lebar) dari elips yang melingkupi objek.

3) *Circularity*

Circularity digunakan untuk mengukur seberapa dekat bentuk suatu objek terhadap lingkaran sempurna. Nilai 1 menunjukkan bentuk lingkaran sempurna, sedangkan nilai yang semakin kecil mengindikasikan bentuk yang lebih tidak beraturan atau kompleks. Perhitungan *circularity* dapat dilihat pada Persamaan (5).

$$Circularity = \frac{4\pi A}{P^2} \tag{5}$$

dengan *Area* merupakan luas area objek daun dan *Perimeter* merupakan keliling objek daun.

4) *Convexity*

Convexity menggambarkan tingkat kelengkungan atau kecembungan dari suatu bentuk daun dengan membandingkan area aktual terhadap area *convex hull*-nya. Nilai *convexity* mendekati 1 menunjukkan daun memiliki bentuk yang cembung dan halus tanpa lekukan signifikan, sedangkan nilai yang lebih kecil menunjukkan adanya lekukan, gerigi, atau ketidakteraturan pada tepi daun. Perhitungan *convexity* dapat dilihat pada Persamaan (6).

$$\text{Convexity} = \frac{\text{Area}}{\text{ConvexArea}} \quad (6)$$

dengan *Area* merupakan luas area aktual objek daun dan *Convex Area* merupakan luas area dari *convex hull* (selubung cembung) yang melingkupi objek.

2.5. Klasifikasi RF

RF adalah metode pembelajaran *ensemble* yang menggunakan kumpulan pohon keputusan untuk melakukan klasifikasi dan regresi. Metode ini bekerja dengan melatih sejumlah besar pohon keputusan secara independen, kemudian menggabungkan hasil prediksi melalui mekanisme *voting* untuk menghasilkan keputusan akhir yang lebih akurat dan robust (**Mekha & Teeyasuksaet, 2021**). Algoritma RF dalam penelitian ini dapat dijelaskan melalui tahapan berikut:

- 1) Mengambil sejumlah sampel dari dataset asli menggunakan metode bootstrap resampling, yaitu pengambilan data secara acak dengan pengembalian.
- 2) Untuk setiap sampel bootstrap, dibangun sebuah pohon keputusan, dengan memilih atribut secara acak dari seluruh fitur yang tersedia. Jumlah fitur yang dipilih bisa ditentukan menggunakan rumus seperti $\frac{1}{2}m$, \sqrt{m} , $2\sqrt{m}$, dengan m adalah total jumlah fitur.
- 3) Setiap pohon yang terbentuk kemudian digunakan untuk melakukan prediksi terhadap data.
- 4) Proses ini diulang hingga sejumlah pohon yang diinginkan terbentuk. Proses pengulangan bisa dilakukan hingga k kali.
- 5) Hasil akhir klasifikasi ditentukan berdasarkan mayoritas hasil prediksi dari seluruh pohon yang telah dibentuk (*voting*).

2.6. Pengujian Sistem

Pengujian sistem dilakukan untuk mengevaluasi kinerja model dalam melakukan klasifikasi citra daun herbal menggunakan pendekatan *hold-out validation* dengan rasio pembagian data 80:20. Pendekatan ini dipilih karena ukuran dataset yang digunakan relatif terbatas (500 citra), sehingga pemisahan langsung menjadi data latih dan data uji dinilai cukup representatif untuk mengevaluasi performa model. Pada tahap ini, performa model dianalisis menggunakan beberapa metrik evaluasi, yaitu akurasi, presisi, *recall*, dan *F1-Score*. Metrik-metrik ini berfungsi untuk mengukur tingkat keberhasilan model dalam mengklasifikasikan data secara tepat (**Florentina Tatrini Kurniati & Dian Pramana, 2023**). Setiap metrik dihitung berdasarkan *confusion matrix* yang terdiri dari empat komponen: *True Positive* (TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN). Penjelasan masing-masing metrik evaluasi adalah sebagai berikut:

1) Akurasi

Akurasi mengukur sejauh mana model berhasil memprediksi kelas yang benar dari keseluruhan dataset. Perhitungan nilai akurasi dapat dilihat pada Persamaan (7).

$$\text{Akurasi} = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (7)$$

2) Presisi

Presisi mengukur ketepatan model dalam memprediksi kelas positif, yaitu perbandingan antara prediksi positif yang benar dengan seluruh prediksi positif. Perhitungan nilai presisi dapat dilihat pada Persamaan (8).

$$Presisi = \frac{TP}{(TP+FP)} \quad (8)$$

3) Recall

Recall mengukur sejauh mana model berhasil mendeteksi positif yang sebenarnya. Perhitungan nilai recall dapat dilihat pada Persamaan (9).

$$Recall = \frac{TP}{(TP + FN)} \quad (9)$$

4) F1 – Score


F1 – Score adalah rata-rata harmonik dari presisi dan recall. Hal ini berguna ketika ingin mencari keseimbangan antara presisi dan recall. Perhitungan nilai F1-Score dapat dilihat pada Persamaan (10).

$$F1 - score = 2 \times \frac{(Presisi \times Recall)}{(Presisi + Recall)} \quad (10)$$

3. HASIL DAN PEMBAHASAN

3.1. Akuisisi Citra

Dataset pada penelitian ini merupakan data primer yang diperoleh secara langsung melalui proses akuisisi citra daun tanaman herbal menggunakan kamera *smartphone* beresolusi 12 MP. Pengambilan gambar dilakukan di luar ruangan pada pukul 09.00–12.00 untuk memanfaatkan pencahayaan alami yang stabil, dengan jarak pemotretan sekitar 20 cm dan menggunakan latar belakang berwarna kuning guna meningkatkan kontras antara objek dan *background*. Total dataset terdiri dari 500 citra daun herbal dalam format JPG, di mana setiap jenis tanaman memiliki 50 citra. Dataset tersebut kemudian dibagi menggunakan rasio 80:20, sehingga 400 citra digunakan sebagai data latih dan 100 citra sebagai data uji. Beberapa contoh citra yang dikumpulkan melalui proses akuisisi ditampilkan pada Gambar 3.




Gambar 3. Citra Daun (a) Sirih, (b) Jambu Biji, (c) Belimbing Wuluh, (d) Katuk, (e) Sirsak, (f) Kemangi, (g) Bidara, (h) Salam, (i) Kumis Kucing, (j) Binahong

3.2. Pre-Processing


Pada tahap *pre-processing*, terdapat tiga tahapan yang dilakukan. Tahap pertama yaitu melakukan proses *resize* dengan mengubah ukuran setiap citra dari ukuran awal 3024 × 3024

piksel menjadi 256×256 piksel agar seluruh citra memiliki ukuran yang seragam dan sesuai untuk proses ekstraksi fitur pada tahap berikutnya. Perbandingan antara citra asli dan citra hasil *resize* ditampilkan pada Gambar 4.



Gambar 4. (a) Citra Asli (3024x3024), (b) Setelah *Resize* (256 x 256)


Selanjutnya, citra yang telah diubah ukurannya dikonversi dari format RGB ke *Grayscale* untuk menyederhanakan informasi warna menjadi intensitas abu-abu. Tahap berikutnya adalah melakukan pemfilteran menggunakan *Gaussian Blur* dengan nilai sigma sebesar 1 untuk mengurangi *noise* dan menghasilkan citra yang lebih halus, sehingga dapat mempermudah proses segmentasi pada tahap selanjutnya. Hasil konversi ke *Grayscale* dan penerapan *Gaussian Blur* ditampilkan pada Gambar 5.



Gambar 5. (a) Grayscale, (b) Gaussian Blur

3.3. Segmentasi

Proses segmentasi bertujuan untuk memisahkan objek daun dari latar belakang sehingga mempermudah tahapan ekstraksi fitur. Segmentasi pada penelitian ini dilakukan dengan menerapkan *Otsu Thresholding* pada citra hasil *Gaussian Blur* untuk mengubah citra menjadi biner, sehingga objek daun tampil sebagai area putih dan latar belakang sebagai area hitam. Nilai ambang *Otsu* diperoleh secara otomatis menggunakan metode *Otsu* melalui fungsi *graythresh*, yang menentukan ambang optimal berdasarkan distribusi histogram intensitas citra *grayscale*. Citra biner tersebut kemudian digunakan sebagai masker pada citra *grayscale* agar hanya bagian daun yang dipertahankan. Tahap akhir segmentasi dilakukan menggunakan *Canny Edge Detection* untuk menampilkan garis tepi daun secara lebih jelas. Hasil segmentasi ditampilkan pada Gambar 6.



Gambar 6. (a) *Otsu Thresholding*, (b) *Masker*, (c) *Canny Edge Detection*

3.4. Ekstraksi Fitur Tekstur dan Bentuk

Proses ekstraksi fitur dilakukan untuk memperoleh karakteristik daun yang relevan bagi klasifikasi. Penelitian ini menggunakan kombinasi fitur tekstur dan bentuk, yaitu *mean* LBP, standar deviasi LBP, *aspect ratio*, *eccentricity*, *circularity*, dan *convexity*. Fitur LBP digunakan untuk menangkap pola intensitas lokal, sedangkan fitur bentuk menggambarkan proporsi dan kelengkungan daun. Ekstraksi fitur dilakukan pada data latih dengan pembagian data 80:20. Tabel 1 menyajikan hasil ekstraksi dari 400 citra data latih, berupa nilai *mean* dan standar deviasi fitur tekstur serta fitur bentuk.

Tabel 1. Nilai Ekstraksi Fitur Tekstur dan Bentuk 400 Citra Data Latih dari Split Data 80:20

Citra	Aspect Ratio	Eccentricity	Circularity	Convexity	Mean Lbp	Standar Deviasi Lbp
Belimbing Wuluh 01	0.4455	0.9013	0.7253	0.9554	0.1016	0.2997
Belimbing Wuluh 02	0.3504	0.9385	0.6418	0.9405	0.1015	0.2997
.....
Belimbing Wuluh 39	0.4202	0.9032	0.7191	0.9606	0.1018	0.2996
Belimbing Wuluh 40	0.3858	0.9295	0.6555	0.9408	0.1017	0.2997
Bidara 01	0.8696	0.4915	1.0324	0.9869	0.1007	0.3000
Bidara 02	0.8605	0.5676	1.0159	0.9792	0.1006	0.3000
.....
Bidara 39	0.8780	0.4866	1.0279	0.9821	0.1005	0.3001
Bidara 40	0.7619	0.7285	0.9782	0.9775	0.1004	0.3001
Binahong 01	0.9780	0.3611	0.9253	0.9604	0.1025	0.2994
Binahong 02	0.9000	0.3418	0.8530	0.9510	0.1020	0.2996
.....
Binahong 39	0.8544	0.3848	0.8566	0.9478	0.1025	0.2994
Binahong 40	1.0149	0.4434	0.9234	0.9680	0.1014	0.2998
Jambu Biji 01	0.3716	0.9278	0.7166	0.9841	0.1029	0.2992
Jambu Biji 02	0.3882	0.9210	0.7373	0.9850	0.1032	0.2992
.....
Jambu Biji 39	0.3867	0.9227	0.7273	0.9862	0.1028	0.2993
Jambu Biji 40	0.3896	0.9197	0.7398	0.9840	0.1033	0.2991
Katuk 01	0.3714	0.9276	0.7057	0.9799	0.1011	0.2999
Katuk 02	0.5000	0.8649	0.8419	0.9820	0.1010	0.2999
.....
Katuk 39	0.4554	0.8888	0.7905	0.9803	0.1012	0.2998
Katuk 40	0.5109	0.8660	0.8322	0.9799	0.1011	0.2999
Kemangi 01	0.4483	0.8847	0.7254	0.9675	0.1010	0.2999
Kemangi 02	0.4667	0.8655	0.7747	0.9775	0.1011	0.2999
.....
Kemangi 39	0.4505	0.8745	0.7802	0.9809	0.1011	0.2999
Kemangi 40	0.4787	0.8679	0.7896	0.9749	0.1012	0.2998
Kumis Kucing 01	0.4646	0.8711	0.7003	0.9549	0.1011	0.2999
Kumis Kucing 02	0.4433	0.8811	0.6787	0.9513	0.1012	0.2998
.....
Kumis Kucing 39	0.4167	0.8947	0.6975	0.9620	0.1008	0.3000

Citra	Aspect Ratio	Eccentricity	Circularity	Convexity	Mean Lbp	Standar Deviasi Lbp
Kumis Kucing 40	0.5111	0.8431	0.7199	0.9508	0.1011	0.2999
Salam 01	0.4020	0.9088	0.6880	0.9779	0.1044	0.2987
Salam 02	0.4069	0.9049	0.6947	0.9790	0.1044	0.2987
.....
Salam 39	0.4881	0.8464	0.7900	0.9753	0.1036	0.2990
Salam 40	0.5379	0.8163	0.8230	0.9754	0.1026	0.2994
Sirih 01	0.6242	0.7568	0.8643	0.9794	0.1038	0.2989
Sirih 02	0.8644	0.4397	0.9356	0.9770	0.1034	0.2991
.....
Sirih 39	0.8378	0.5745	0.9558	0.9856	0.1032	0.2992
Sirih 40	0.6713	0.6903	0.8282	0.9728	0.1037	0.2990
Sirsak 01	0.4072	0.9115	0.7464	0.9834	0.1029	0.2992
Sirsak 02	0.3785	0.9296	0.7084	0.9851	0.1032	0.2991
.....
Sirsak 39	0.4162	0.9106	0.7452	0.9853	0.1036	0.2990
Sirsak 40	0.3490	0.9294	0.6577	0.9851	0.1032	0.2991

3.5. Random Forest (RF)

Setelah proses ekstraksi fitur selesai, tahap berikutnya adalah melatih model klasifikasi menggunakan algoritma RF. Pada tahap ini dilakukan pengujian beberapa kombinasi parameter untuk memperoleh konfigurasi yang paling optimal. Parameter yang dievaluasi meliputi jumlah pohon ($n_estimators$), jumlah fitur maksimum pada setiap pemisahan node ($max_features$), kedalaman maksimum pohon (max_depth), dan jumlah minimum sampel pada daun ($min_samples_leaf$). Evaluasi ini penting untuk mencapai keseimbangan antara akurasi dan efisiensi komputasi, serta mencegah terjadinya *overfitting* maupun *underfitting*. Hasil pengujian parameter ditampilkan pada Tabel 2 hingga Tabel 5.

Tabel 2. Hasil Pengujian Berdasarkan Parameter $n_estimators$

$n_estimators$	Akurasi training	Akurasi uji
50	99.25%	90%
100	99.25%	91%
200	99.25%	92%
300	99.50%	92%
400	99.50%	92%
500	99.25%	91%

Berdasarkan hasil pengujian parameter $n_estimators$, seluruh model menunjukkan akurasi *training* yang tinggi, yaitu di atas 99%. Akurasi data uji meningkat seiring dengan penambahan jumlah pohon dan mencapai nilai tertinggi sebesar 92% pada $n_estimators = 200, 300,$ dan 400. Namun, peningkatan jumlah pohon di atas $n_estimators = 200$ tidak memberikan peningkatan akurasi yang berarti. Pada $n_estimators = 200$, model telah mencapai akurasi data uji maksimum dengan keseimbangan yang baik antara akurasi *training* dan data uji, sehingga tidak menunjukkan indikasi *overfitting*. Selain itu, penggunaan jumlah pohon yang lebih sedikit lebih efisien secara komputasi. Oleh karena itu, $n_estimators = 200$ dipilih sebagai konfigurasi terbaik.

Tabel 3. Hasil Pengujian Berdasarkan Parameter *max_features*

<i>Max_features</i>	Akurasi <i>training</i>	Akurasi uji
2	99.25%	92%
3	99.50%	92%
6	100%	90%

Berdasarkan hasil pengujian parameter *max_features*, seluruh model menunjukkan akurasi *training* yang tinggi, yaitu di atas 99%. Nilai *max_features* = 2 dan 3 menghasilkan akurasi data uji tertinggi sebesar 92%. Sebaliknya, penggunaan *max_features* = 6 menyebabkan penurunan akurasi data uji menjadi 90%, meskipun akurasi *training* mencapai 100%, yang mengindikasikan terjadinya *overfitting*. Meskipun nilai *max_features* = 2 dan 3 memberikan akurasi yang sama, nilai *max_features* = 2 dipilih sebagai konfigurasi terbaik karena menggunakan jumlah fitur yang lebih sedikit pada setiap pemisahan node, sehingga meningkatkan keragaman antar pohon dalam RF. Selain itu, penggunaan fitur yang lebih sedikit lebih efisien secara komputasi dan berpotensi memberikan kemampuan generalisasi yang lebih baik. Oleh karena itu, *max_features* = 2 dipilih sebagai konfigurasi terbaik.

Tabel 4. Hasil Pengujian Berdasarkan Parameter *max_depth*

<i>Max_depth</i>	Akurasi <i>training</i>	Akurasi uji
none	99.25%	92%
5	86.25%	83%
10	94.50%	90%
15	93.25%	90%
20	95.50%	89%

Berdasarkan hasil pengujian parameter *max_depth*, konfigurasi tanpa pembatasan kedalaman pohon (*max_depth* = none) menghasilkan akurasi *training* tertinggi sebesar 99,25% dan akurasi data uji sebesar 92%. Pemberian batas kedalaman yang terlalu rendah, seperti *max_depth* = 5, menyebabkan penurunan kinerja model dengan akurasi *training* sebesar 86,25% dan akurasi data uji 83%, yang menunjukkan terjadinya *underfitting*. Sementara itu, peningkatan nilai *max_depth* hingga 10 dan 15 mampu meningkatkan akurasi data uji menjadi 90%, namun belum melampaui kinerja model tanpa pembatasan kedalaman. Pada *max_depth* = 20, akurasi *training* meningkat menjadi 95,50%, tetapi akurasi data uji justru menurun menjadi 89%, yang mengindikasikan kecenderungan *overfitting*. Hasil pengujian menunjukkan bahwa penggunaan *max_depth* tanpa batas memberikan keseimbangan terbaik antara akurasi *training* dan data uji. Oleh karena itu, *max_depth* = none dipilih sebagai konfigurasi terbaik.


Tabel 5. Hasil Pengujian Berdasarkan Parameter *min_samples_leaf*

<i>Min_sample_leaf</i>	Akurasi <i>training</i>	Akurasi uji
2	99.25%	92%
4	97.75%	91%
8	95.75%	91%
20	92.75%	91%
40	90.75%	86%

Berdasarkan hasil pengujian parameter *min_samples_leaf*, nilai *min_samples_leaf* = 2 menghasilkan akurasi *training* tertinggi sebesar 99,25% dan akurasi data uji tertinggi sebesar 92%. Peningkatan nilai *min_samples_leaf* menyebabkan penurunan akurasi baik pada data *training* maupun data uji. Pada *min_samples_leaf* = 4, 8, dan 20, akurasi data uji relatif stabil di angka 91%, namun lebih rendah dibandingkan nilai *min_samples_leaf* = 2. Sementara itu,

penggunaan $min_samples_leaf = 40$ menunjukkan penurunan akurasi data uji yang cukup signifikan menjadi 86%, yang mengindikasikan terjadinya *underfitting* akibat pembatasan ukuran daun yang terlalu besar. Hasil pengujian menunjukkan bahwa nilai $min_samples_leaf$ yang kecil memberikan kinerja klasifikasi yang lebih optimal. Oleh karena itu, $min_samples_leaf = 2$ dipilih sebagai konfigurasi terbaik.

Setelah diperoleh konfigurasi parameter terbaik pada algoritma RF, yaitu $n_estimators = 200$, $max_features = 2$, $max_depth = none$, dan $min_samples_leaf = 2$, model diuji menggunakan 100 citra daun pada data uji. Evaluasi performa dilakukan menggunakan *confusion matrix* untuk menganalisis kemampuan model dalam mengklasifikasikan setiap kelas daun secara lebih rinci. *Confusion matrix* menunjukkan distribusi prediksi model terhadap masing-masing kelas daun, di mana nilai pada diagonal utama merepresentasikan jumlah prediksi yang benar, sedangkan nilai di luar diagonal menunjukkan kesalahan klasifikasi akibat kemiripan karakteristik visual antar jenis daun. Warna biru dengan intensitas yang lebih gelap menandakan prediksi yang benar dalam jumlah tinggi, sementara warna oranye atau lebih terang menunjukkan adanya kesalahan prediksi. Hasil *confusion matrix* ditunjukkan pada Gambar 7.



Gambar 7. Hasil Confusion Matrix

Berdasarkan Gambar 7, model RF mampu mengklasifikasikan sebagian besar jenis daun herbal dengan sangat baik, yang ditunjukkan oleh dominasi nilai tinggi pada diagonal utama. Beberapa kelas, seperti Daun Bidara, Daun Binahong, Daun Kumis Kucing, dan Daun Sirih, berhasil diklasifikasikan secara sempurna dengan nilai *recall* sebesar 100%, yang menunjukkan bahwa seluruh sampel pada kelas-kelas tersebut dapat dikenali dengan benar oleh model. Namun demikian, kesalahan klasifikasi paling banyak ditemukan pada kelas Daun Katuk, di mana sebagian sampel masih salah diklasifikasikan sebagai Daun Kemangi dan Daun Salam. Kesalahan ini diduga disebabkan oleh kemiripan karakteristik visual antar beberapa jenis daun, terutama dari aspek bentuk dan tekstur permukaan, sehingga menyulitkan model dalam membedakan kelas-kelas tersebut secara akurat. Secara keseluruhan, hasil ini menunjukkan bahwa model RF dengan kombinasi fitur tekstur dan bentuk telah bekerja secara efektif, meskipun masih terdapat peluang untuk meningkatkan kinerja klasifikasi pada kelas daun yang memiliki karakteristik visual yang serupa.

Sebagai tahap akhir evaluasi, kinerja model diukur menggunakan metrik akurasi, presisi, *recall*, dan *F1-score* untuk memperoleh gambaran menyeluruh mengenai efektivitas model dalam

melakukan klasifikasi. Hasil evaluasi performa model RF pada data pengujian disajikan pada Tabel 6, sehingga dapat menunjukkan tingkat generalisasi model dalam mengenali berbagai jenis daun herbal.

Tabel 6. Hasil Evaluasi Performa Model RF

Kelas	Presisi	Recall	F1-Score	Accuracy
Belimbing Wuluh	100%	90%	95%	92%
Bidara	100%	100%	100%	
Binahong	91%	100%	95%	
Jambu Biji	90%	90%	90%	
Katuk	88%	70%	79%	
Kemangi	82%	90%	86%	
Kumis Kucing	100%	100%	100%	
Salam	82%	90%	86%	
Sirih	100%	100%	100%	
Sirsak	90%	90%	90%	
Hasil	92%	92%	92%	92%

Berdasarkan hasil evaluasi performa model pada tabel di atas, dapat dilihat bahwa model RF menunjukkan kinerja yang baik dalam mengklasifikasikan sebagian besar kelas daun herbal. Beberapa kelas mencapai hasil evaluasi yang sangat tinggi, terutama Daun Bidara, Daun Kumis Kucing, dan Daun Sirih, yang memperoleh nilai presisi, *recall*, dan *F1-score* sebesar 100%. Hal ini menunjukkan bahwa model mampu mengenali jenis daun tersebut dengan sangat akurat tanpa kesalahan klasifikasi, yang kemungkinan disebabkan oleh karakteristik bentuk dan tekstur daun yang lebih khas dibandingkan kelas lainnya. Sebaliknya, kinerja terendah terlihat pada kelas Daun Katuk, di mana Daun Katuk memiliki nilai presisi 88%, *recall* 70%, dan *F1-score* 79%. Hal ini mengindikasikan bahwa model masih mengalami kesulitan dalam membedakan jenis daun tersebut dari kelas lain akibat kemiripan karakteristik visual. Sementara itu, kelas lain seperti Daun Jambu Biji dan Daun Sirsak menunjukkan performa yang cukup baik dengan nilai presisi, *recall*, dan *F1-score* masing-masing sebesar 90%.

Secara keseluruhan, model RF memperoleh rata-rata presisi sebesar 92%, *recall* 92%, *F1-score* 92%, dan akurasi 92%. Hasil ini menunjukkan bahwa model memiliki kemampuan klasifikasi dan generalisasi yang sangat baik dalam mengidentifikasi berbagai jenis daun tanaman herbal, meskipun masih terdapat beberapa kelas yang memerlukan peningkatan performa. Untuk memperkuat kontribusi penelitian, dilakukan perbandingan performa antara algoritma RF dengan dua model *baseline*, yaitu *K-Nearest Neighbor* (KNN) dan *Decision Tree* (DT), menggunakan fitur dan data yang sama. Hasil perbandingan disajikan pada Tabel 7.

Tabel 7. Perbandingan Performa Model Klasifikasi

Model	Akurasi	Presisi	Recall	F1-Score
KNN	90%	91%	90%	90%
<i>Decision Tree</i>	87%	88%	87%	87%
RF	92%	92%	92%	92%

Berdasarkan Tabel 7, algoritma RF mengungguli kedua model *baseline* pada seluruh metrik evaluasi. *Decision Tree* memperoleh akurasi terendah sebesar 87%, yang mengindikasikan keterbatasan model pohon tunggal dalam menangani variasi fitur yang kompleks pada dataset daun herbal. *K-Nearest Neighbor* menunjukkan performa yang lebih baik dengan akurasi 90%, namun masih di bawah RF. RF berhasil mencapai akurasi, presisi, *recall*, dan *F1-score* tertinggi masing-masing sebesar 92%. Keunggulan ini disebabkan oleh mekanisme *ensemble learning*

pada RF yang menggabungkan prediksi dari banyak pohon keputusan, sehingga lebih mampu menangkap variasi fitur yang kompleks dan menghasilkan generalisasi yang lebih baik dibandingkan model tunggal.

Sebagai perbandingan, penelitian (**Purnawansyah et al.,2023**) yang mengklasifikasikan daun katuk dan kelor menggunakan kombinasi GLCM dengan SVM (kernel linear) memperoleh akurasi tertinggi sebesar 96% pada kondisi pencahayaan gelap, sedangkan GLCM dengan CNN mencapai 98% pada kondisi pencahayaan terang. Meskipun kedua pendekatan tersebut menunjukkan performa yang tinggi, cakupan kelasnya hanya 2 jenis daun dengan kondisi pencahayaan terkontrol, sedangkan penelitian ini berhasil mencapai akurasi 92% untuk 10 kelas daun herbal menggunakan dataset primer yang lebih beragam.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi daun tanaman herbal dengan mengintegrasikan fitur tekstur dan bentuk menggunakan algoritma RF. Ekstraksi tekstur melalui LBP dan empat fitur bentuk, yaitu *aspect ratio*, *eccentricity*, *circularity*, dan *convexity*, mampu merepresentasikan karakteristik visual daun secara efektif. Berdasarkan pengujian berbagai konfigurasi parameter, kombinasi terbaik diperoleh pada $n_estimators = 200$, $max_features = 2$, $max_depth = none$, dan $min_samples_leaf = 2$, yang menghasilkan performa sangat baik dengan rata-rata akurasi sebesar 92%, presisi 92%, *recall* 92%, dan *F1-score* 92%. Beberapa kelas seperti Daun Bidara, Daun Kumis Kucing, dan Daun Sirih menunjukkan performa terbaik dengan tingkat pengenalan yang sangat tinggi, sedangkan performa terendah masih terjadi pada kelas Daun Katuk akibat kemiripan bentuk dengan Daun Kemangi dan Daun Salam. Secara keseluruhan, hasil *confusion matrix* dan evaluasi model menunjukkan bahwa model yang dikembangkan memiliki kemampuan generalisasi yang baik dalam mengidentifikasi daun tanaman herbal. Pada penelitian selanjutnya, fokus pengembangan diarahkan pada penambahan variasi dan jumlah data latih, eksplorasi fitur tambahan, serta penerapan pendekatan *deep learning* seperti *Convolutional Neural Network* (CNN) guna meningkatkan kemampuan ekstraksi fitur secara otomatis dan mencapai tingkat akurasi yang lebih tinggi, khususnya pada kelas dengan karakteristik visual yang serupa.

DAFTAR RUJUKAN

- Abuya, T. K., Rimiru, R. M., & Okeyo, G. O. (2023). *applied sciences An Image Denoising Technique Using Wavelet-Anisotropic Gaussian Filter-Based Denoising Convolutional Neural Network for CT Images*.
- Agustiani, S., Tajul Arifin, Y., Junaidi, A., Khotimatul Wildah, S., & Mustopa, A. (2022). Klasifikasi Penyakit Daun Padi menggunakan Random Forest dan Color Histogram. *Jurnal Komputasi*, 10(1). <https://doi.org/10.23960/komputasi.v10i1.2961>
- Ainun, S., Munsarif, M., & Sam'an, M. (2023). Sistem Klasifikasi Tahu Non-Formalin Menggunakan Metode Random Forest. *Jurnal Komputer Dan Teknologi Informasi*, 1(2), 32–47. <https://doi.org/10.26714/jkti.v1i2.12861>
- Azzahra, A. R., Purnawansyah, Darwis, H., & Widyawati, D. (2023). *Klasifikasi Daun Herbal Menggunakan Metode CNN dan Naïve Bayes dengan Fitur GLCM*. 12(1).

- Basri, H., Purnawansyah, P., Darwis, H., & Umar, F. (2023). Klasifikasi Daun Herbal Menggunakan K-Nearest Neighbor dan Convolutional Neural Network dengan Ekstraksi Fourier Descriptor. *Jurnal Teknologi Dan Manajemen Informatika*, 9(2), 79–90. <https://doi.org/10.26905/jtmi.v9i2.10350>
- Florentina Tatrini Kurniati, & Dian Pramana. (2023). Identifikasi Objek Menggunakan Random Forest dan Multi-Fitur. *Jurnal Sistem Dan Informatika (JSI)*, 17(2), 130–136. <https://doi.org/10.30864/jsi.v17i2.590>
- Herdiansah, A., Borman, R. I., Nurnaningsih, D., Sinlae, A. A. J., & Al Hakim, R. R. (2022). Klasifikasi Citra Daun Herbal Dengan Menggunakan Backpropagation Neural Networks Berdasarkan Ekstraksi Ciri Bentuk. *JURIKOM (Jurnal Riset Komputer)*, 9(2), 388. <https://doi.org/10.30865/jurikom.v9i2.4066>
- Indra, D., Hasanuddin, T., Satra, R., & Wibowo, N. R. (2018). Eggs Detection Using Otsu Thresholding Method. *Proceedings - 2nd East Indonesia Conference on Computer and Information Technology: Internet of Things for Industry, EIconCIT 2018*, 2, 10–13. <https://doi.org/10.1109/EIconCIT.2018.8878517>
- Kasim, N., Fadilah, M. B., Hidayat, W. Al, & Saputra, R. A. (2024). Klasifikasi Jenis Tanaman Herbal Berdasarkan Citra Menggunakan Metode Convolution Neural Network (CNN). *Jurnal TEKNO KOMPAK*, 19(1), 64–78. <https://doi.org/https://doi.org/10.33365/jtk.v19i1>
- Kumar, S., Sagar, V., & Punetha, D. (2023). A comparative study on facial expression recognition using local binary patterns, convolutional neural network and frequency neural network. *Multimedia Tools and Applications*, 82(16), 24369–24385. <https://doi.org/10.1007/s11042-023-14753-y>
- Lamasigi, Z. Y., Hasan, M., & Lasena, Y. (2020). Local Binary Pattern untuk Pengenalan Jenis Daun Tanaman Obat menggunakan K-Nearest Neighbor. *ILKOM Jurnal Ilmiah*, 12(3), 208–218. <https://doi.org/10.33096/ilkom.v12i3.667.208-218>
- Mahmuda, S. (2024). Implementasi Metode Random Forest pada Kategori Konten Kanal Youtube. *Jurnal Jendela Matematika*, 2(01), 21–31. <https://doi.org/10.57008/jjm.v2i01.633>
- Mekha, P., & Teeyasuksaet, N. (2021). Image Classification of Rice Leaf Diseases Using Random Forest Algorithm. *2021 Joint 6th International Conference on Digital Arts, Media and Technology with 4th ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunication Engineering, ECTI DAMT and NCON 2021*, 165–169. <https://doi.org/10.1109/ECTIDAMTNCN51128.2021.9425696>
- Melani Winandari, D., Wulanningrum, R., & Sinta Wahyuniar, L. (2023). Klasifikasi Daun Obat

- Berdasarkan Ekstraksi Tekstur GLCM. *Prosiding SEMNAS INOTEK (Seminar Nasional Inovasi Teknologi)*, 7(2), 742–749.
<https://proceeding.unpkediri.ac.id/index.php/inotek/article/view/3492>
- Nugroho, C. W., Nurtanio, I., & Jalil, A. (2025). Penentuan Kualitas Kopra Berbasis Citra Kontur Menggunakan Metode Canny Edge Detection. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 5(1), 436–450.
<https://doi.org/10.57152/malcom.v5i1.1823>
- Rahmawati, F. N., Harmida, & Aminasih, N. (2021). Pemanfaatan Tumbuhan Obat Zingiberaceae Pada Suku Rawas Di Desa Ja-jaran Baru I Kecamatan Megang Sakti Kabupaten Musi Rawas. *Sriwijaya Bioscientia*, 2(1), 23–28.
<https://doi.org/10.24233/sribios.2.1.2021.212>
- Thohari, A. N. A., & Ramadhani, R. D. (2019). Sistem Pengawasan Berbasis Deteksi Gerak Menggunakan Single Board Computer. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi (JNTETI)*, 8(1), 1. <https://doi.org/10.22146/jnteti.v8i1.483>
- Wuryani, N., & Sarifah, A. (2022). Random Forest Classifier untuk Deteksi Penderita COVID-19 berbasis Citra CT Scan. *Jurnal Teknik Komputer AMIK BSI*, 8(2), 174–180.
<https://doi.org/10.31294/jtk.v4i2>
- Zhou, W., Ma, X., & Zhang, Y. (2020). Research on Image Preprocessing Algorithm and Deep Learning of Iris Recognition. *Journal of Physics: Conference Series*, 1621(1).
<https://doi.org/10.1088/1742-6596/1621/1/012008>
- Purnawansyah, Wibawa, A. P., Widyaningtyas, T., Havaluddin, Hasihi, C. E., Teng, M. F., & Darwis, H. (2023). Comparative Study of Herbal Leaves Classification using Hybrid of GLCM-SVM and GLCM-CNN. *ILKOM Jurnal Ilmiah*, 15(2), 382–389.
<https://doi.org/10.33096/ilkom.v15i2.1759.382-389>