

Identifikasi Penyakit Pada Daun Kopi Menggunakan Metode *Local Binary Pattern* Dan *Random Forest*

(*Identification Of Disease In Coffee Leaves Using Local Binary Pattern And Random Forest Methods*)

1st Begita Wahyuningtyas
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

begitatyas@student.telkomunivers
ity.ac.id

2nd Iwan Iwut Tritoasmoro
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

iwaniwut@telkomuniversity.ac.id

3rd Nur Ibrahim
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

nuribrahim@telkomuniveristy.ac.i
d

Abstrak—Kopi adalah hasil perkebunan yang sangat penting dan merupakan salah satu penghasil devisa terbesar dalam perekonomian Indonesia. Namun, tingkat kualitas dan kuantitas produksi kopi di Indonesia masih rendah. Salah satu faktor yang mempengaruhi adalah kematian tanaman kopi akibat terinfeksi penyakit, sehingga perlu dilakukan pencegahan awal dengan mengidentifikasi penyakit. Identifikasi dapat dilakukan dengan melihat perubahan warna dan bentuk fisik dari daun. Namun, karena lahan perkebunan kopi yang luas dengan jumlah tanaman yang banyak membuat petani kesulitan dalam mengidentifikasi penyakit dengan tepat. Pada tugas akhir ini telah dirancang sistem pengolahan citra digital yang dapat mengidentifikasi penyakit pada daun kopi. Penyakit daun kopi diidentifikasi kedalam 3 jenis penyakit, yaitu *Leaf Blight*, *Leaf Miner*, dan *Leaf Rust*. Proses pengolahan citra digital menggunakan metode ekstraksi ciri *Local Binary Pattern* dan metode klasifikasi *Random Forest*. Dataset yang digunakan sebanyak 240 citra, terbagi menjadi 192 citra data latih dan 48 citra data uji. Dari hasil pengujian diperoleh akurasi terbaik sebesar 95,83% dengan menggunakan parameter ukuran citra 128x128 piksel, radius LBP = 1, dan *n-estimators Random Forest* = 100. Sehingga dapat disimpulkan bahwa sistem yang dibangun dapat berjalan dengan baik dalam mengidentifikasi penyakit pada daun kopi.

Kata Kunci: kopi, penyakit daun, *local binary pattern*, *random forest*.

Abstract—Coffee is a very important plantation product and is one of the largest foreign exchange earners in the Indonesian economy. However, the level of quality and quantity of coffee production in Indonesia is still low. One of the influencing factors is the death of coffee plants due to infected diseases, so prevention needs to be done by identifying the disease. Identification can be done by

looking at changes in color and physical shape of the leaves. However, because the coffee plantation area is large with a large number of plants, it is difficult for farmers to identify the disease correctly. In this final project, a digital image processing system has been designed that can identify diseases in coffee leaves. Coffee leaf disease was identified into 3 types of disease, namely leaf blight, leaf miner, and leaf rust. The digital image processing uses the *Local Binary Pattern* feature extraction method and the *Random Forest* classification method. The dataset used is 240 images, divided into 192 training data images and 48 test data images. From the test results obtained the best accuracy of 95.83% using the parameter image size 128x128 pixels, LBP radius = 1, and *n-estimator Random Forest* = 100. So it can be said that the system built can run well in identifying diseases in coffee leaves.

Keywords: coffee, leaf disease, local binary pattern, random forest.

I. PENDAHULUAN

Kopi adalah hasil perkebunan yang sangat penting dan merupakan salah satu penghasil devisa terbesar dalam perekonomian Indonesia. Saat ini Indonesia merupakan negara penghasil kopi terbesar keempat di dunia, dengan total lahan perkebunan kopi sebesar 1,24 juta hektar[1]. Namun, tingkat kualitas dan kuantitas produksi kopi di Indonesia masih rendah jika dibandingkan dengan negara lain. Menurut penelitian pangan dari *Center for Indonesia Policy Studies* (CIPS), terdapat dua faktor utama penyebab kurangnya produktifitas kopi di Indonesia. Pertama, pohon pada usia yang sudah tua akan sangat rentan terhadap serangan penyakit. Kedua, peremajaan tanaman yang belum dilakukan dengan baik[2]. Hal tersebut dapat menunjang tingkat kematian pada

tanaman kopi akibat terinfeksi penyakit tertentu. Solusi dari permasalahan tersebut, perlu dilakukan pencegahan awal dengan mengidentifikasi penyakit pada tanaman kopi sehingga dapat dilakukan penanganan yang tepat.

Penyakit pada tanaman kopi dapat dilihat dari perubahan warna dan bentuk fisik dari daun tanaman kopi. Beberapa penyakit yang dapat diidentifikasi dari daun pada tanaman kopi diantaranya adalah *leaf rust* (*Hemilia Vastatrix*), *leaf miner* (*Leucoptera Coffella*), dan *leaf blight* (*Phoma Costaricensis*). Penyakit tersebut dapat disebabkan oleh jamur, mikroba, maupun virus, sehingga akan sulit untuk mengidentifikasi jenis penyakit hanya dengan mata telanjang[3]. Lahan perkebunan kopi yang luas dengan jumlah tanaman yang banyak juga membuat petani kesulitan dalam mengidentifikasi penyakit dengan tepat. Oleh karena itu, diperlukan metode khusus dalam mengidentifikasi penyakit pada daun kopi sehingga dapat membantu petani dalam meningkatkan kualitas dan kuantitas produksi kopi di Indonesia.

Terdapat beberapa penelitian yang telah dilakukan terkait identifikasi penyakit daun pada tanaman. Pada tahun 2020 telah dilakukan penelitian mengenai klasifikasi penyakit pada daun tomat menggunakan metode *Local Binary Pattern* (LBP) dan *Random Forest* dengan hasil akurasi terbaik sebesar 94%[4]. Pada tahun 2021 telah dilakukan penelitian mengenai deteksi penyakit pada tanaman jagung menggunakan beberapa algoritma, diantaranya *Naive Bayes* (NB), *Decision Tree* (DT), *K-Nearest Neighbor* (KNN), *Support Vektor Machine* (SVM) dan *Random Forest* (RF). Hasil dari penelitian tersebut menunjukkan bahwa metode *Random Forest* memiliki tingkat akurasi terbesar yaitu 80,68% jika dibandingkan dengan algoritma lainnya[5]. Selanjutnya pada tahun 2021 dilakukan identifikasi penyakit pada daun tanaman apel menggunakan *Local Binary Pattern* (LBP) dan *Color Histogram*. Penelitian tersebut mengidentifikasi 5 jenis penyakit pada daun apel yaitu penyakit *Glomerella*, *Herbicida*, *Magnesium Deficiency*, *Potassium Deficiency*, dan *Scab*. Akurasi yang dihasilkan dalam penelitian tersebut sebesar 91,41% dengan menggunakan dataset sejumlah 2.154 citra daun dalam mengidentifikasi penyakit pada daun tanaman apel[3].

Berdasarkan pada penelitian sebelumnya, metode *Local Binary Patter* dan *Random Forest* memiliki hasil akurasi yang baik. Oleh karena itu, pada Tugas Akhir ini dirancang sistem pengolahan citra digital yang dapat mengidentifikasi penyakit pada daun kopi menggunakan metode ekstraksi ciri *Local Binary Patter* dan metode klasifikasi *Random Forest*. Penyakit daun kopi diidentifikasi kedalam 3 jenis penyakit, yaitu *leaf rust*, *leaf miner*, dan *leaf blight*. Dataset yang digunakan sebanyak 240 citra, terbagi menjadi 192 citra data latih dan 48 citra data uji. Dengan menggunakan metode tersebut diharapkan sistem menghasilkan nilai akurasi yang tinggi dalam mengidentifikasi penyakit pada daun kopi.

II. KAJIAN TEORI

A. Kopi

Kopi (*Coffea sp*) merupakan spesies tanaman berbentuk pohon yang termasuk dalam famili *Rubiaceae* dan genus *Coffea*. Struktur tanaman kopi terdiri dari akar, batang, daun, bunga dan buah. Pertumbuhan tanaman kopi tegak, bercabang, dan tingginya dapat mencapai 12 meter. Daun kopi berbentuk bulat telur dengan ujung agak meruncing dan tumbuh pada batang, cabang, serta ranting pada tanaman kopi[6]. Terdapat sekitar 70 spesies tanaman kopi, namun hanya ada dua spesies yang ditanam dalam skala besar di seluruh dunia, yaitu kopi arabika (*Coffea Arabica*) dan kopi Robusta (*Coffea canephora var robusta*)[7]. Dari kedua spesies kopi tersebut, tanaman kopi arabika lebih rentan terkena penyakit dibandingkan tanaman kopi Robusta.

B. Penyakit Daun Kopi yang Dideteksi

1. Leaf Rust

Leaf Rust atau karat daun merupakan penyakit daun pada tumbuhan yang disebabkan oleh golongan jamur yang termasuk dalam ordo *Pucciniales*. Karat daun yang terjadi pada tanaman kopi disebabkan oleh jamur *Hemilia Vastatrix*. Jamur tersebut menginfeksi daun melalui stomata pada permukaan daun kopi. Gejala serangan akibat penyakit karat daun diawali dengan timbulnya bercak kuning pada permukaan atas daun, kemudian berubah warna menjadi coklat. Sedangkan pada permukaan bawah daun banyak terdapat spora berwarna orange atau jingga[8].

Berkembangnya penyakit karat daun ditandai dengan meluasnya bercak pada permukaan daun. Akibatnya, bagian permukaan daun yang digunakan tanaman untuk melakukan fotosintesis akan berkurang dan berdampak pada pertumbuhan tanaman. Hal ini dapat menyebabkan banyaknya daun yang gugur dan mati sehingga kuantitas dan kualitas kopi akan menurun[9]. Pada Gambar 1 merupakan salah satu contoh penyakit *leaf rust* yang terjadi pada daun kopi.



GAMBAR 1
LEAF RUST PADA DAUN KOPI [10]

2. Leaf Miner

Leaf Miner merupakan penyakit yang menyerang daun kopi yang disebabkan oleh serangan *Leucoptera Caffeine* atau yang biasa disebut hama penambang daun. Hama ini sering muncul pada area perkebunan yang rimbun dan memakan jaringan parenkim palisade pada daun yang menyebabkan

kematian sel pada jaringan daun. Hal ini dapat mengurangi area daun dalam melakukan fotosintesis sehingga banyak daun yang gugur dan mati. Hama ini pertama kali ditemukan pada lahan perkebunan kopi di Brazil[11]. Salah satu contoh daun kopi yang terserang penyakit *leaf miner* dapat dilihat pada Gambar 2.



GAMBAR 2
LEAF MINER PADA DAUN KOPI [10]

3. Leaf Blight

Leaf Blight atau hawar daun merupakan penyakit pada daun kopi yang disebabkan oleh jamur *Phoma Costaricensis*. Penyakit ini menyebabkan dahan kering, keguguran pada daun, jatuhnya tunas buah dan kelopak bunga yang dapat mempengaruhi tingkat produktivitas pada tanaman kopi. Gejala yang timbul akibat penyakit ini adalah nampaknya noda lingkaran hitam pada permukaan daun kopi seperti tampak pada Gambar 3. Penyakit ini banyak terjadi pada tanaman dengan lingkungan yang memiliki tingkat cuaca angin besar dan dingin[12].



GAMBAR 3
LEAF BLIGHT PADA DAUN KOPI [10]

C. Pengolahan Citra Digital

Pengolahan citra digital adalah teknik yang digunakan untuk mengolah citra digital baik berupa gambar atau video. Sebuah citra digital dapat diwakili oleh sebuah matriks dua dimensi $f(x, y)$ yang terdiri dari M kolom dan N baris, dimana perpotongan antara kolom dan baris disebut piksel (*pixel = picture element*) atau elemen terkecil dari sebuah citra[13]. Secara matematis, citra dapat dinyatakan sebagai fungsi $f(x, y)$. Dimana indeks baris (x) dan indeks kolom (y) adalah koordinat posisi piksel pada citra digital, sedangkan fungsi $f(x, y)$ adalah informasi warna dan intensitas (derajat keabuan) pada titik (x, y) . Penggambaran fungsi $f(x, y)$ pada citra dapat dituliskan kedalam sebuah matriks sebagai berikut:

$$f(x, y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0, M-1) \\ f(1,0) & f(1,1) & \dots & f(1, M-1) \\ \vdots & \vdots & \ddots & \vdots \\ f(N-1,0) & f(N-1,1) & \dots & f(N-1, M-1) \end{bmatrix} \quad (1)$$

1. Citra RGB

Citra RGB adalah salah satu citra digital yang merupakan kombinasi dari 3 warna yaitu merah (*Red*), hijau (*Green*) dan biru (*Blue*). Warna tersebut merupakan warna dasar yang dapat diterima oleh mata manusia. Setiap warna dasar memiliki intensitas tersendiri dengan nilai terkecil adalah nol (0) dan nilai terbesar adalah 255 (8 bit). Citra RGB terdiri dari tiga matriks yang mewakili nilai-nilai merah, hijau, biru untuk setiap pikselnya[13].

2. Citra Grayscale

Citra *Grayscale* adalah salah satu citra digital yang menampilkan tingkatan keabuan dari suatu citra digital dan hanya memiliki satu nilai kanal pada setiap pikselnya. Setiap sampel piksel pada citra *grayscale* disimpan dalam format 8 bit, sehingga terdapat 256 intensitas yang terdiri dari 0 hingga 255. Nilai 0 menyatakan warna hitam, nilai 255 menyatakan warna putih, sedangkan nilai diantara 0-255 menyatakan derajat keabuan citra. Citra *grayscale* berbeda dengan citra “hitam-putih” yang hanya terdiri atas dua warna saja yaitu hitam dan putih[15]. Untuk mengubah citra RGB menjadi *grayscale* dapat menggunakan rumus sebagai berikut:


$$Grayscale = (0.299 \times R) + (0.587 \times G) + (0.144 \times B) \quad (2)$$

dengan R, G, B menyatakan nilai dari masing-masing warna untuk bagian merah, hijau dan biru pada citra.

D. Local Binary Pattern

Local Binary Pattern (LBP) adalah algoritma yang digunakan untuk mendeskripsikan tekstur pada citra *grayscale* dengan memberi label berupa angka desimal pada piksel suatu citra. Pembentukan label diawali dengan melakukan proses *thresholding* yaitu membandingkan setiap piksel pusat dengan kedelapan nilai *neighbors* atau piksel tetangganya pada ukuran 3x3. Perbandingan dilakukan dengan mengurangi nilai piksel *neighbors* dengan nilai piksel pusat. Jika hasilnya lebih atau sama dengan 0 maka akan diberi nilai biner 1 dan jika kurang dari 0 akan diberi nilai biner 0. Setelah melakukan perbandingan pada semua piksel *neighbors*, hasil biner dari nilai *neighbors* dikonversi menjadi nilai desimal sebagai nilai baru untuk piksel pusat.

Nilai desimal yang dihasilkan dari penggabungan konversi angka biner dari semua nilai *neighbors* akan digunakan untuk memberi label pada setiap piksel yang diberikan. Nilai-nilai tersebut akan dipresentasikan melalui histogram. Histogram merupakan grafik yang menggambarkan penyebaran nilai intensitas dari suatu citra. Intensitas tersebut merupakan banyaknya nilai dari setiap piksel pada citra. Pada Gambar 4 menunjukkan proses kerja dari LBP untuk piksel *neighbors* pada ukuran 3x3 untuk mendapatkan nilai desimal.



GAMBAR 4
CONTOH CARA KERJA LBP [15]

Secara matematis persamaan dasar dari LBP dapat dirumuskan sebagai berikut:

$$LBP_{P,R} = \sum_{p=0}^{P-1} S(g_p - g_c)2^p \quad (3)$$

$$S(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (4)$$

- dengan P = Sampling point
- R = Radius
- g_p = Piksel neighbors
- g_c = Piksel pusat
- $S(x)$ = binary threshold function

E. Random Forest

Random Forest merupakan salah satu algoritma yang digunakan untuk melakukan klasifikasi dengan menggunakan Decision Tree dan termasuk kedalam Ensemble Learning. Ensemble Learning merupakan suatu sistem pembelajaran dimana model maupun classifier yang akan digunakan lebih dari satu [17]. Classifier yang digunakan adalah decision tree yang akan dibangun sesuai dengan kebutuhan. Tahap awal yang dilakukan dalam pemodelan Random Forest yaitu menentukan jumlah decision tree yang akan dibentuk dari proses pemilihan data menggunakan teknik bootstrap aggregating (bagging). Teknik ini menerapkan sampling with replacement yaitu memilih sampel dari data latih secara acak dan akan dimasukkan kedalam masing-masing tree dengan jumlah yang sama.

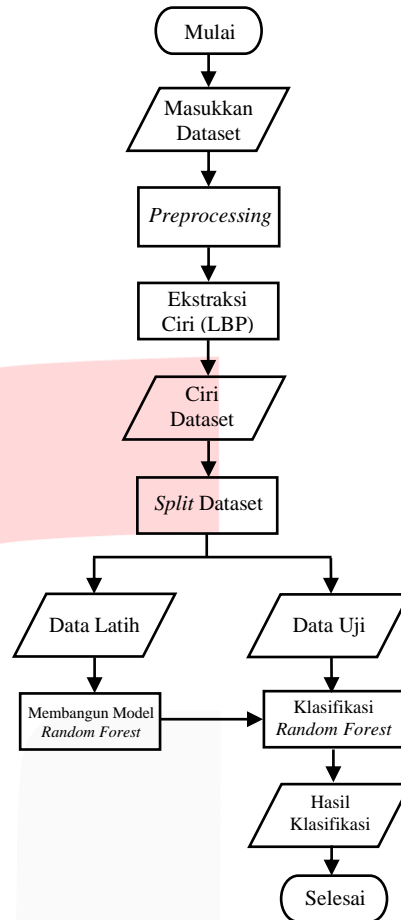
Setelah seluruh tree terbentuk, maka akan dilakukan pengujian model dengan melakukan prediksi terhadap data latih pada setiap model tree. Prediksi yang dihasilkan untuk setiap model tree akan disatukan melalui proses majority voting untuk menghasilkan nilai prediksi final.

III. METODE

A. Desain Sistem

Pada gambar 5 merupakan gambaran diagram alir keseluruhan dari sistem. Sistem akan diawali dengan menginput data berupa citra digital penyakit daun kopi. Data yang telah diinput akan melalui preprocessing untuk mendapatkan kualitas data yang lebih baik. Selanjutnya data yang telah melalui preprocessing akan dilakukan ekstraksi ciri menggunakan metode Local Binary Pattern untuk mendapatkan ciri dari citra penyakit daun kopi. Hasil ekstraksi ciri data akan dibagi menjadi 80% data latih

dan 20% data uji. Selanjutnya kedua data tersebut akan melalui proses klasifikasi dengan menggunakan metode Random Forest.




GAMBAR 5
DIAGRAM ALIR KESELURUHAN SISTEM

B. Citra Daun Penyakit Kopi

Citra daun penyakit kopi yang digunakan sebagai masukan data merupakan citra digital yang terbagi menjadi 3 jenis penyakit daun kopi, yaitu leaf rust, leaf miner, dan leaf blight. Dataset tersebut diperoleh dari open source Kaggle yang berisikan 240 citra dengan masing-masing kelas berisikan 80 citra.

C. Preprocessing

Preprocessing merupakan tahapan yang dilakukan setelah melakukan input citra. Gambar 6. merupakan alur preprocessing yang diawali dengan melakukan resize citra. Resolusi citra akan diperkecil dari ukuran sebenarnya, untuk memudahkan dalam mengolah data. Selanjutnya citra akan dikonversi dari citra RGB menjadi citra grayscale yang akan digunakan untuk ekstraksi ciri pada proses Local Binary Pattern. Proses ini berfungsi mengubah citra tiga dimensi menjadi satu dimensi dengan intensitas yang sama, sehingga akan memudahkan dan mempercepat proses komputasinya.



GAMBAR 6
DIAGRAM ALIR PREPROCESSING

D. Ekstraksi Ciri

Pada proses ekstraksi ciri dilakukan untuk mengambil ciri atau pola khusus dari citra hasil *preprocessing*. Hasil ekstraksi ciri akan digunakan sebagai parameter untuk membedakan ciri dari masing-masing citra daun penyakit kopi *leaf rust*, *leaf miner*, dan *leaf blight* sehingga akan memudahkan klasifikasi. Pada proses ini, akan dilakukan ekstraksi ciri menggunakan metode *Local Binary Pattern* (LBP) pada citra hasil *preprocessing*. Berikut diagram alir proses ekstraksi ciri menggunakan metode LBP, yaitu:

1. Menentukan Parameter LBP, Parameter yang digunakan adalah P dan R, dimana P merupakan sampling point atau jumlah tetangga piksel pusat dan R merupakan radius atau jari-jari antara piksel pusat dengan piksel tetangga.
2. *Thresholding*, merupakan tahap mengubah nilai piksel tetangga menjadi angka biner dengan membandingkan setiap piksel pusat dan piksel tetangganya pada ukuran 3x3. Perbandingan dilakukan dengan mengurangi nilai piksel tetangga dengan nilai piksel pusat. Jika hasilnya lebih atau sama dengan 0 maka akan diberi nilai biner 1 dan jika kurang dari 0 akan diberi nilai biner 0.
3. *Binary Pattern*, nilai biner yang telah didapatkan pada proses *thresholding* akan dibentuk pola searah dengan jarum jam (*clockwise*).
4. *Mapping*, menentukan nilai titik pusat dengan mengonversi nilai biner menjadi nilai desimal. Konversi dilakukan dengan mengalikan nilai biner yang telah dibentuk pada *Binary Pattern* dengan bobot untuk menggantikan nilai piksel pusat dengan angka desimal. Nilai tersebut akan dipresentasikan melalui histogram dengan nilai

dari x (piksel) dan sumbu y (intensitas) sebagai ciri yang diperoleh dari proses ekstraksi ciri.

E. Split Data

Setelah diperoleh parameter ciri dari dataset, selanjutnya dilakukan *split* atau membagi dataset menjadi dua bagian yaitu data latih dan uji. Data latih digunakan untuk bahan pembelajaran atau latihan pada model klasifikasi (*Random Forest*) sehingga model dapat bekerja dengan baik ketika melakukan klasifikasi. Data uji digunakan sebagai pengujian terhadap model yang telah dibuat untuk mengetahui kekuatan model tersebut dalam melakukan klasifikasi. Dataset yang berisikan 240 citra akan dibagi menjadi 80% data latih yaitu 192 citra dan 20% data uji yaitu 48 citra.

F. Klasifikasi

Pada tahap ini dilakukan klasifikasi menggunakan metode *Random Forest* (RF). Dalam melakukan pemodelan klasifikasi, terdapat dua proses yang akan dilakukan yaitu tahap latih dan tahap uji. Dengan menggunakan parameter hasil ekstraksi ciri, akan dilakukan model klasifikasi RF terhadap data latih. Proses pemodelan diawali dengan membuat pohon keputusan sesuai dengan jumlah yang ditentukan. Setiap pohon akan mengklasifikasikan data berdasarkan ketentuan yang didapatkan dari proses pelatihan. Hasil dari setiap pohon akan digunakan sebagai satu unit suara untuk melakukan prediksi dan menentukan kelas dari suatu data uji.

G. Performansi Sistem

Setelah melakukan semua proses, selanjutnya dilakukan performansi sistem untuk mengetahui kinerja dari sistem yang telah dibuat dengan menggunakan *confusion matrix*.

TABEL 1.
CONFUSION MATRIX

		Kelas prediksi	
		Positif	Negatif
Kelas aktual	Positif	TP	FN
	Negatif	FP	TN

Berdasarkan table 1 dapat dijelaskan bahwa:

1. Kelas aktual adalah kelas yang diberikan dalam kumpulan data.
2. Kelas prediksi adalah kelas yang diprediksi dengan metode klasifikasi yang telah dilakukan sebelumnya.
3. *True Positive* (TP) adalah jumlah data dengan nilai sebenarnya positif dan hasil prediksi positif.
4. *False Positive* (FP) adalah jumlah data dengan nilai sebenarnya negatif dan hasil prediksi positif.

5. *True Negative* (TN) adalah jumlah data dengan nilai sebenarnya negatif dan hasil prediksi negatif.
6. *False Negative* (FN) adalah jumlah data dengan nilai sebenarnya positif dan hasil prediksi negatif.

Nilai-nilai pada *confusion matrix* akan digunakan untuk menghasilkan performansi sistem yang terdiri dari nilai *accuracy*, *precision*, *recall*, dan *f-1 score*.

1. Accuracy

Accuracy (akurasi) adalah nilai untuk mengetahui tingkat keakuratan sistem dalam mengklasifikasi data dengan benar.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (5)$$

2. Precision

Precision (presisi) adalah perbandingan jumlah data positif yang diklasifikasikan secara benar dengan total data yang diklasifikasikan positif.

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (6)$$

3. Recall

Recall adalah nilai untuk mengetahui berapa persen data kategori positif yang diklasifikasikan dengan benar oleh sistem.

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (7)$$

4. F1-Score

F1-Score adalah nilai *harmonic mean* dari *precision* dan *recall*, dengan nilai terbaik adalah 1.0 dan nilai terburuk adalah 0.

$$F1\ Score = 2 \times \frac{presisi \times recall}{presisi + recall} \times 100\% \quad (8)$$

H. Skenario Pengujian

Metode pengujian dilakukan dengan menggunakan beberapa nilai parameter dari ekstraksi ciri dan klasifikasi untuk mengetahui pengaruh parameter tersebut terhadap hasil yang diperoleh pada sistem. Pada tugas akhir ini dilakukan tiga skenario pengujian sebagai berikut:

1. Skenario pertama, yaitu melakukan pengujian parameter *resize* citra terhadap akurasi. Pengujian dilakukan dengan mencoba berbagai nilai ukuran citra yaitu 512x512 piksel, 256x256 piksel, dan 128x128 piksel. Pengujian ini bertujuan untuk mendapatkan ukuran citra yang paling optimal digunakan berdasarkan hasil nilai akurasi pengujian. Hasil dari nilai ukuran citra terbaik akan digunakan untuk pengujian skenario kedua.
2. Skenario kedua, yaitu melakukan pengujian parameter radius (R) LBP terhadap akurasi. Pengujian ini bertujuan untuk mendapatkan parameter radius LBP yang paling optimal digunakan pada proses ekstraksi ciri berdasarkan hasil nilai akurasi pengujian. Nilai parameter R yang

digunakan pada pengujian ini adalah 1, 2, 3, 4, 5, 6, 7, 8, 9, dan 10. Sedangkan parameter lainnya yaitu nilai *sample point* (P) = 8 dan *n-estimators* = 100. Hasil dari parameter R dengan akurasi terbaik akan digunakan pada pengujian skenario ketiga.

3. Skenario ketiga, yaitu melakukan pengujian parameter jumlah pohon (*n-estimators*) *Random Forest*. Pengujian bertujuan untuk mendapatkan parameter *n-estimators* terbaik dari *Random Forest* berdasarkan hasil nilai akurasi pengujian. Pengujian ini dilakukan dengan mencoba berbagai nilai parameter *n-estimators* yaitu 10, 30, 100, 300, dan 1000.

IV. HASIL DAN ANALISIS

A. Hasil Pengujian


Pada pengujian sistem ini dilakukan dengan menggunakan beberapa nilai parameter dan hasilnya akan dipresentasikan dalam bentuk tabel dan grafik. Pengujian sistem ini bertujuan untuk mendapatkan nilai parameter terbaik yang dapat menghasilkan nilai akurasi yang optimal pada sistem yang dibuat.

1. Skenario Pertama

Berikut merupakan hasil pengujian skenario pertama yang dilakukan untuk melihat pengaruh *resize* citra yaitu 512x512 piksel, 256x256 piksel dan 128x128 piksel terhadap akurasi pada sistem. Pengujian pada tahap ini menggunakan parameter LBP R = {1, 8}, P = 8 dan parameter *Random Forest* yaitu *n-estimators* = 100. Dengan menggunakan parameter tersebut akan membuat perhitungan pada setiap region menjadi lebih tepat[20]. Data hasil pengujian dapat dilihat pada Tabel 4.1.

TABEL 2
HASIL SKENARIO PERTAMA

No.	Radius	Piksel	Akurasi Pelatihan (%)	Akurasi Pengujian (%)
1	1	512x512	100	93,75
2		256x256	100	93,75
3		128x128	100	95,83
4		64x64	100	83,33
5	8	512x512	100	91,67
6		256x256	100	89,58
7		128x 28	100	91,67
8		64 x 64	100	75,00



GAMBAR 7

GRAFIK PENGARUH *RESIZE* CITRA TERHADAP AKURASI SISTEM.


Pada Gambar 7 menunjukkan pengaruh ukuran citra penyakit daun kopi terhadap nilai akurasi pada sistem. Dari hasil pengujian yang telah dilakukan, ukuran citra yang paling tepat digunakan yaitu 128x128 dengan nilai akurasi sebesar 95,83%. Oleh karena itu, untuk skenario kedua akan digunakan *resize* citra sebesar 128x128 piksel.

2. Skenario Kedua

Setelah mendapatkan parameter ukuran citra terbaik, selanjutnya skenario kedua yaitu melakukan pengujian untuk melihat pengaruh radius LBP terhadap akurasi sistem. Parameter yang digunakan pada pengujian ini adalah nilai R = 1, 2, 3, 4, 5, 6, 7, 8, 9, dan 10 dengan P = 8 dan *n-estimators* = 100. *Resize* citra yang digunakan adalah 128x128 piksel. Hasil pengujian dapat dilihat pada Tabel 3.

TABEL 3
HASIL SKENARIO KEDUA

No.	Radius	Akurasi Pelatihan (%)	Akurasi Pengujian (%)
1	1	100	95,83
2	2	100	87,50
3	3	100	85,42
4	4	100	89,58
5	5	100	81,25
6	6	100	87,50
7	7	100	83,33
8	8	100	91,67
9	9	100	91,67
10	10	100	89,58



GAMBAR 8

GRAFIK PENGARUH RADIUS LBP TERHADAP AKURASI SISTEM


Pada Gambar 8 menunjukkan pengaruh radius LBP terhadap nilai akurasi pada sistem. Dari hasil pengujian didapatkan nilai radius yang paling optimal digunakan yaitu R= 1 dengan nilai akurasi sebesar 95,83%. Oleh karena itu, untuk skenario ketiga akan digunakan radius LBP sebesar 1.

C. Skenario Ketiga

Pengujian ini dilakukan untuk melihat pengaruh parameter jumlah pohon (*n-estimators*) *Random Forest* terhadap nilai akurasi sistem. Parameter *n-estimators* yang digunakan pada pengujian ini adalah 10, 30, 100, 300, dan 1000. Sedangkan parameter lainnya yaitu *resize* citra 128x128 piksel, P = 8, dan R = 1 yang telah didapatkan pada skenario kedua. Data hasil pengujian dapat dilihat pada Tabel 3.

TABEL 4
HASIL SKENARIO 3

No.	n-estimators	Akurasi Pelatihan (%)	Akurasi Pengujian (%)
1	10	100	91,67
2	30	100	89,58
3	100	100	95,83
4	300	100	93,75
5	1000	100	93,75



GAMBAR 9

GRAFIK PENGARUH *N-ESTIMATORS RANDOM FOREST* TERHADAP AKURASI SISTEM

Pada Gambar 9 menunjukkan pengaruh parameter *n-estimators Random Forest* terhadap nilai akurasi pada sistem. Dari hasil pengujian didapatkan *n-estimators* yang paling baik digunakan pada sistem ini adalah 100 dengan nilai akurasi sebesar 95,83%. Hal ini menunjukkan bahwa jumlah pohon yang digunakan pada proses *Random Forest* berpengaruh terhadap hasil kinerja pada sistem.

B. Analisis Performansi Sistem



GAMBAR 10

HASIL *CONFUSION MATRIX* SISTEM

Pada tahap pengujian telah dilakukan beberapa skenario pengujian untuk mendapatkan nilai parameter terbaik. Gambar 10 menunjukkan *Confusion Matrix* dari hasil pengujian menggunakan metode *Local Binary Pattern* dan *Random Forest* yang telah dibuat. Berdasarkan hasil *Confusion Matrix*, secara keseluruhan sistem telah bekerja dengan baik dalam melakukan identifikasi. Hal itu ditandai dengan semakin terang intensitas warna pada *Confusion Matrix* maka semakin tinggi juga jumlah data yang diprediksi dengan benar, meskipun masih terdapat beberapa kesalahan pada sistem dalam memprediksi kelas *leaf miner* dan *leaf rust*. Hasil *Confusion Matrix* akan menentukan hasil parameter performansi kinerja sistem yang dapat dilihat pada Tabel 5.

TABEL 5
KINERJA SISTEM

	Precision (%)	Recall (%)	F1-Score (%)
Blight	100	100	100
Miner	100	89	94
Rust	88	100	94
Weighted avg	96	96	96
Accuracy (%)			95,83

Weighted avg adalah nilai rata-rata dari setiap parameter *Precision*, *Recall*, dan *F1-Score*. Berdasarkan hasil kinerja sistem, dapat disimpulkan bahwa sistem yang dibuat memiliki performansi yang baik dalam mengidentifikasi penyakit pada daun kopi dengan presentasi nilai akurasi keseluruhan sebesar 95,83%.

V. KESIMPULAN

A. Kesimpulan

Dari hasil pengujian dan analisis yang dilakukan pada sistem identifikasi penyakit pada daun kopi menggunakan metode *Local Binary Pattern* dan *Random Forest* dapat ditarik kesimpulan sebagai berikut:

1. Sistem hasil perancangan menggunakan metode ekstraksi ciri *Local Binary Pattern* dan klasifikasi *Random Forest* sudah mampu mengidentifikasi penyakit pada daun kopi dengan nilai akurasi terbaik sebesar 95,83%.
2. Sistem hasil perancangan mendapatkan hasil parameter terbaik yaitu ukuran citra 128x128 piksel, nilai radius pada *Local Binary Pattern* sebesar 1, dan *n-estimators* pada *Random Forest* sebesar 100. Dengan menggunakan nilai pada parameter tersebut, dapat mempengaruhi dan meningkatkan hasil akurasi dari kinerja sistem.
3. Sistem yang dirancang telah memiliki performansi yang baik dalam mengidentifikasi penyakit pada daun kopi berdasarkan presentasi nilai rata-rata dari parameter *Precision*, *Recall*, dan *F1-Score* yang didapatkan yaitu masing-masing sebesar 96%.

B. Saran

Berdasarkan hasil pengujian dan analisis yang telah dilakukan, maka dapat diambil beberapa saran untuk pengembangan sistem identifikasi penyakit pada daun kopi yaitu:

1. Melakukan pengembangan dengan menggunakan metode ekstraksi ciri dan klasifikasi lain untuk mendapatkan hasil akurasi yang lebih baik.
2. Menggunakan dataset yang lebih banyak dan kelas yang bervariasi agar sistem dapat mengenali data lebih akurat.
3. Melakukan pengujian dengan mengubah beberapa parameter lain untuk mendapatkan nilai akurasi yang lebih optimal.

REFERENSI

- [1] B. B. Nasution, "Specialty Kopi Indonesia," 2018.
- [2] D. Irfansyah, M. Mustikasari, and A. Suroso, "Arsitektur Convolutional Neural Network (CNN) Alexnet untuk Klasifikasi Hama pada Citra Daun Tanaman Kopi," vol. 6, no. 2, pp. 87–92, 2021.
- [3] F. Duanita Putri, K. N. Ramadhani, and P. E. Yunanto, "Identifikasi Penyakit pada Daun Tanaman Apel Menggunakan Local Binary Pattern (LBP) dan Color Histogram," 2021.
- [4] J. Basavaiah and A. Arlene Anthony, "Tomato Leaf Disease Classification using Multiple Feature Extraction Techniques," 2020.
- [5] D. Chauhan, R. Walia, C. Singh, M. Deivakani, and M. Kumbhkar, "Detection of Maize Disease Using Random Forest Classification Algorithm," *Turkish Journal of Computer and Mathematics Education*, vol. 12, no. 9, pp. 715–720, 2021.
- [6] Krisnaindra, "Klasifikasi dan Morfologi Tanaman Kopi dengan Pengertiannya," Oct. 08, 2016. <https://www.teorieno.com/2016/10/klasifikasi-dan-morfologi-tanaman-kopi.html> (accessed Nov. 24, 2021).
- [7] P. Rahardjo, *Berkebun Kopi*. Penebar Swadaya, 2017.
- [8] L. Sugiarti, "Identifikasi Hama dan Penyakit Pada Tanaman Kopi di Kebun Percobaan Fakultas Pertanian Universitas Winaya Mukti," 2019.
- [9] R. K. W. Siska, "Serangan Karat Daun Kopi (*Hemileia vastatrix* Berk&Br) pada Tanaman Kopi Arabika di Perkebunan Rakyat Kabupaten Mandailing Natal Sumatera Utara," 2016.
- [10] M. Odhiambo, "Coffee leaf diseases," 2021. <https://www.kaggle.com/badasstechie/coffee-leaf-diseases> (accessed Nov. 24, 2021).
- [11] O. G. Filho, "Coffee leaf miner resistance," pp. 110–117, 2006.
- [12] Kopi 76, "Hama, Penyakit, dan Nematoda dalam Budidaya Kopi," *Kopi 76*, Jan. 18, 2021. <https://kopi76.com/2021/01/18/hama-penyakit-dan-nematoda-dalam-budidaya-kopi/> (accessed Nov. 24, 2021).
- [13] R. D. Kusumanto and A. N. Tompunu, "Pengolahan Citra Digital untuk Mendeteksi Obyek Menggunakan Pengolahan Warna Model Normalisasi RGB," 2011.
- [14] A. McAndrew, "An Introduction to Digital Image Processing with Matlab Notes for SCM2511 Image Processing 1," 2004.
- [15] A. P. Utami, F. Sthevanie, and K. N. Ramadhani, "Pengenalan Logo Kendaraan Menggunakan Metode Local Binary Pattern dan Random Forest," 2020.
- [16] D. Huang, C. Shan, M. Ardebilian, Y. Wang, and L. Chen, "Local Binary Patterns and Its Application to Facial Image Analysis: A Survey," 2011.
- [17] R. Yudistira, R. Purnamasari, and N. Ibrahim, "Analisis dan Perancangan Sistem untuk Diagnosa Penyakit Parkinson Menggunakan Metode PCA dan Random Forest," 2020.
- [18] JavaTPoint, "Random Forest Algorithm" <https://www.javatpoint.com/machine-learning-random-forest-algorithm> (accessed Des. 1, 2021).
- [19] S. Devella, Yohannes, and F. N. Rahmawati, "Implementasi *Random Forest* untuk Klasifikasi Moftif Songket Palembang Berdasarkan SIFT," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 7, no. 2, pp. 310–320, 2020.
- [20] A. S. Kurnia, I. Safitri, and R. Y. N. Fu'adah, "Deteksi Masker Wajah Pada Pengguna Motor Menggunakan Metode *Local Binary Pattern* (LBP) dan *K-Nearest Neighbor* (K-NN), 2021.