

Identifikasi Penyakit pada Daun Tanaman Apel Menggunakan *Local Binary Pattern* (LBP) dan *Color Histogram*

Firlia Duanita Putri¹, Kurniawan Nur Ramadhani², Prasti Eko Yunanto³

^{1,2,3}Fakultas Informatika, Universitas Telkom, Bandung

¹firiaduanitaputri@student.telkomuniversity.ac.id, ²kurniawanr@telkomuniversity.ac.id,

³gppras@telkomuniversity.ac.id

Abstrak

Penyakit pada daun tanaman apel dapat menyebabkan potensi gagal panen dan mempengaruhi kuantitas serta kualitas produksi pada pertanian. Sebagian besar penyakit pada tanaman dapat didiagnosa dari penyakit daun. Oleh karena itu, untuk mengurangi potensi gagal panen tersebut, perlu dilakukan identifikasi penyakit pada daun tanaman apel. Penelitian ini mengidentifikasi 5 jenis penyakit pada daun tanaman apel, yaitu kelas penyakit *Glomerella*, *Herbicida*, *Magnesium Deficiency*, *Potassium Deficiency*, dan *Scab*. Metode yang digunakan adalah *Local Binary Pattern* (LBP) dan *Color Histogram*. *Random forest* digunakan sebagai klasifikasi. Berdasarkan dari hasil pengujian pada tanaman apel yang menggunakan dataset sejumlah 2.154 citra daun diperoleh rata-rata akurasi sebesar 91,41%.

Kata kunci : Penyakit Daun, Tanaman Apel, *Local Binary Pattern* (LBP), *Color Histogram*, *Random Forest*

Abstract

Apple leaf disease could cause a failure of potential crop and affected the quantity and quality of production in agriculture. Most of plants disease could diagnosed from leaf disease. Therefore, to reduce the failure of potential crop, it is needed to identification the disease of apple leaves. This research identifications 5 type of diseases in apple tree, there are *Glomerella*, *Herbicida*, *Magnesium Deficiency*, *Potassium Deficiency* and *Scab*. The method was used were *Local Binary Pattern* (LBP) and *Color Histogram*. *Random forest* was used as a classification. Based on the test result of apple tree that used 2.154 datasets of leaf image obtained an accuracy of 91,41%.

Keywords: Leaf Diseases, Apple Leaves, *Local Binary Pattern* (LBP), *Color Histogram*, *Random Forest*

1. Pendahuluan

Bagian pendahuluan berisikan tentang bahasan lebih detail dari abstrak mengenai latar belakang, topik dan batasan, tujuan, dan organisasi tulisan tentang penelitian.

Latar Belakang

Penyakit tanaman merupakan ketidaknormalan pada tanaman yang dapat mengganggu pertumbuhan tanaman[1]. Penyakit pada tanaman dapat mempengaruhi perekonomian dan mengurangi kuantitas serta kualitas produksi pada pertanian[2]. Oleh karena itu, identifikasi penyakit pada daun tanaman sejak dini dapat membantu untuk mencegah kerugian[1]. Pada penelitian yang dilakukan oleh Harshal dan Radha (2016) menunjukkan bahwa sebagian besar penyakit pada tanaman dapat didiagnosa melalui daun[2]. Terdapat banyak jenis penyakit yang dapat diidentifikasi melalui daun, diantaranya adalah *rust*, *scab*, *yellow leaf disease*, *leaf rot*, *leaf curl*, *magnesium deficiency*, *potassium deficiency*, *herbicide*, *glomerella*, dan *late blight*[3][4]. Penyakit tersebut dapat disebabkan oleh jamur, mikroba, ataupun virus[4], yang mengakibatkan sulit bagi manusia untuk mendeteksi jenis penyakit yang terdapat pada daun dengan mata telanjang[3][4][5]. Pada tahun 2019 dilakukan penelitian klasifikasi penyakit pada *Flavia Leaf* dan *Swedish Leaf* menggunakan *Local Binary Pattern* (LBP) dan berhasil mencapai akurasi sebesar 75,49% dan 85,56%[6]. Pada tahun yang sama dilakukan identifikasi daun bunga matahari menggunakan model warna HSV dan *Random Forest* yang menghasilkan akurasi sebesar 95%[7]. Pada penelitian ini, penulis mengusulkan sistem identifikasi penyakit pada daun tanaman apel agar dapat mempermudah dalam mengidentifikasi penyakit pada daun tanaman apel. Metode yang digunakan adalah penggabungan fitur dari metode *Local Binary Pattern* (LBP) untuk tekstur dan *Color Histogram* untuk warna, serta menggunakan *Random Forest* sebagai klasifikasi.

Topik dan Batasannya

Berdasarkan latar belakang yang telah dijabarkan, rumusan masalah yang diangkat adalah bagaimana cara membangun suatu sistem identifikasi penyakit pada daun tanaman apel menggunakan metode *Local Binary Pattern* (LBP) dan *Color Histogram*. Selain itu, terdapat beberapa batasan masalah yang digunakan dalam penelitian ini: (a) Dataset yang digunakan terdiri dari daun sehat dan 5 jenis penyakit, yaitu *Glomerella*, *Herbicida*, *Magnesium Deficiency*, *Potassium Deficiency*, dan *Scab*; (b) Input dari sistem yang dibangun adalah

citra daun dengan *background* berwarna putih, dengan resolusi citra 256 x 256 piksel; (c) Dataset diperoleh dari beberapa sumber[8][9] yang berjumlah 2.154 citra.

Tujuan

Tujuan yang ingin dicapai pada tugas akhir ini adalah membangun suatu sistem yang dapat mengidentifikasi penyakit pada daun tanaman apel dengan menggunakan metode *Local Binary Pattern* (LBP) dan *Color Histogram*.

Organisasi Tulisan

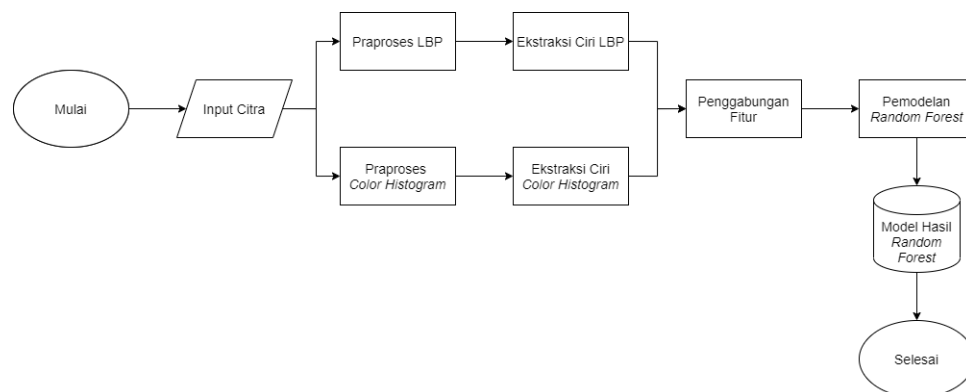
Laporan penelitian ini terdiri dari 5 bagian. Bagian pertama menjelaskan tentang pendahuluan. Bagian kedua menjelaskan tentang studi yang berkaitan dengan penelitian. Bagian ketiga menjelaskan tentang sistem yang dibangun. Bagian keempat menjelaskan tentang evaluasi sistem yang dibangun. Bagian kelima menjelaskan tentang kesimpulan mengenai penelitian yang dilakukan.

2. Studi Terkait

Penelitian penyakit pada tanaman dengan bantuan citra daun tanaman merupakan penelitian yang banyak diminati oleh peneliti karena daun merupakan bagian tumbuhan yang mengandung informasi dan sifat terkaya dari suatu tumbuhan[6]. Pada tahun 2016 dilakukan penelitian klasifikasi penyakit pada daun tanaman anggur menggunakan *Local Binary Pattern* (LBP) dan menghasilkan akurasi sebesar 96,6%[10]. Pada tahun 2019 dilakukan penelitian klasifikasi menggunakan LBP dengan 2 jenis dataset yang berbeda, yaitu *Flavia Leaf* dan *Swedish Leaf* dan didapatkan akurasi dari masing-masing dataset sebesar 75,49% dan 85,56%[6]. Pada tahun yang sama, dilakukan penelitian identifikasi daun bunga matahari menggunakan model warna HSV dan *Random Forest* yang menghasilkan akurasi sebesar 95%[7].

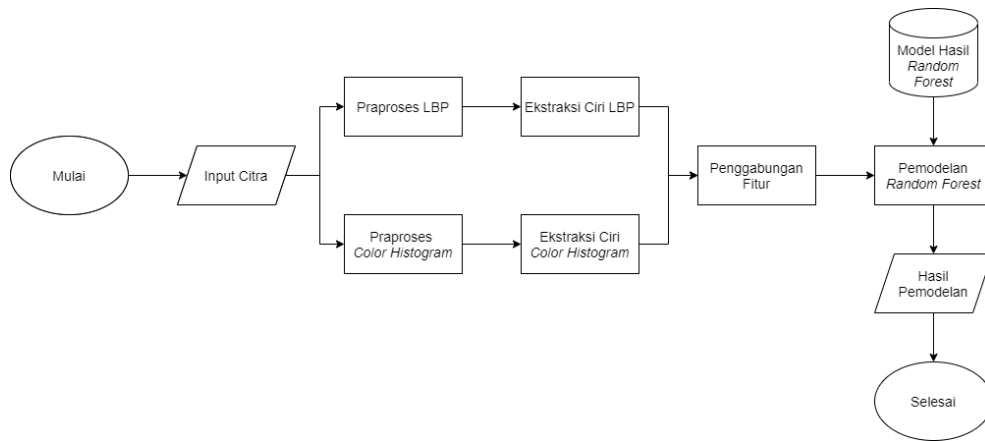
3. Sistem yang Dibangun

Sistem yang diimplementasikan pada penelitian terbagi menjadi dua tahap, yaitu tahap pelatihan dan tahap pengujian. Data yang digunakan dibagi menjadi 80% untuk tahap pelatihan dan 20% untuk tahap pengujian. Tahap pertama yaitu tahap pelatihan dengan input berupa citra ke dalam sistem dan dilakukan praproses. Hasil praproses kemudian digunakan untuk ekstraksi ciri menggunakan LBP dan *Color Histogram*. Hasil dari ekstraksi ciri tersebut akan dilakukan pemodelan menggunakan *Random Forest* dan hasilnya akan disimpan untuk digunakan pada tahap pengujian. Gambar 1 merupakan alur tahap pelatihan yang diimplementasikan.



Gambar 1 Alur Pelatihan Sistem Identifikasi Penyakit Tanaman Apel

Tahap kedua yaitu tahap pengujian yang bertujuan untuk menguji data baru menggunakan pengetahuan yang diperoleh dari tahap pelatihan. Alur pada tahap pengujian sama seperti tahap pelatihan, hanya saja hasil pada tahap pengujian adalah label kelas hasil klasifikasi data uji dengan menggunakan model yang diperoleh dari tahap pelatihan. Gambar 2 merupakan alur tahap pengujian yang diimplementasikan.



Gambar 2 Alur Pengujian Sistem Identifikasi Penyakit Tanaman Apel


3.1. Dataset

Dataset yang digunakan terdiri dari 6 kelas (5 kelas penyakit dan satu kelas sehat), yaitu *Glomerella*, *Healthy*, *Herbicida*, *Magnesium Deficiency*, *Potassium Deficiency*, dan *Scab*. Citra yang digunakan berjumlah 2.154 citra dengan ukuran 256 x 256 piksel. Adapun citra yang digunakan sudah mengalami segmentasi *background*. Rincian dari dataset yang digunakan pada setiap kelas terdapat pada Tabel 1.

Tabel 1 Rincian Dataset

Kelas	Jumlah Citra
<i>Glomerella</i>	581
<i>Healthy</i>	159
<i>Herbicida</i>	325
<i>Magnesium Deficiency</i>	355
<i>Potassium Deficiency</i>	341
<i>Scab</i>	393
Total	2.154


Selanjutnya, untuk sampel dataset daun tanaman apel dengan penyakit *Glomerella*, *Healthy*, *Herbicida*, *Magnesium Deficiency*, *Potassium Deficiency*, dan *Scab* dapat dilihat pada Gambar 3.



Gambar 3 Sampel Citra Daun Tanaman Apel (a) *Glomerella* (b) *Healthy* (c) *Herbicida* (d) *Magnesium Deficiency* (e) *Potassium Deficiency* (f) *Scab*[8][9]

3.2. Praproses

Tahap praproses dilakukan setelah melakukan input citra. Pada tahap ini terdapat 2 proses yang dilakukan, yaitu merubah ruang warna RGB menjadi *grayscale* yang akan digunakan untuk pada proses ekstraksi *Local Binary Pattern* (LBP) dan merubah ruang warna RGB menjadi ruang warna HSV yang akan digunakan untuk proses ekstraksi *Color Histogram*. Ruang warna HSV dipilih karena ruang warna HSV memiliki kinerja yang baik dalam mendeskripsikan karakteristik warna jika dibandingkan dengan ruang warna RGB[7]. Gambar 4 merupakan alur praproses yang digunakan.



Gambar 4 Alur Praproses Sistem Identifikasi Penyakit Tanaman Apel


3.3. Ekstraksi Ciri

3.3.1. Local Binary Pattern (LBP)

Ekstraksi ciri yang dilakukan pada sistem ini menggunakan *Local Binary Pattern* (LBP) yang ditemukan oleh Ojala dan Pietkain untuk mendeskripsikan karakteristik dari tekstur[11]. Operator LBP yang digunakan adalah sebagai berikut[12]:

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

Dimana P adalah jumlah ketetanggaan, R adalah jarak piksel, adalah derajat keabuan pada piksel tetangga ke-p, dan adalah nilai derajat keabuan pada piksel di titik tengah. Pada dasarnya, LBP melakukan ekstraksi fitur dengan cara menghitung perbandingan lebih besar atau lebih kecil pada suatu piksel dengan piksel ketetanggaan[13]. Pada setiap piksel citra didapatkan nilai biner berdasarkan perbandingan dari nilai tengah dan ketetanggaan. Nilai biner akan bernilai 1 jika nilai tengah lebih kecil atau sama dengan tetangganya, sedangkan akan bernilai 0 jika nilai tengah lebih besar dari tetangganya. Setelah melakukan perbandingan pada semua piksel tetangga, didapatkan hasil set biner yang dikonversi ke bentuk desimal sebagai nilai baru pada nilai tengah matriks tersebut[14]. Gambar 5 merupakan proses ekstraksi pada LBP yang digunakan.



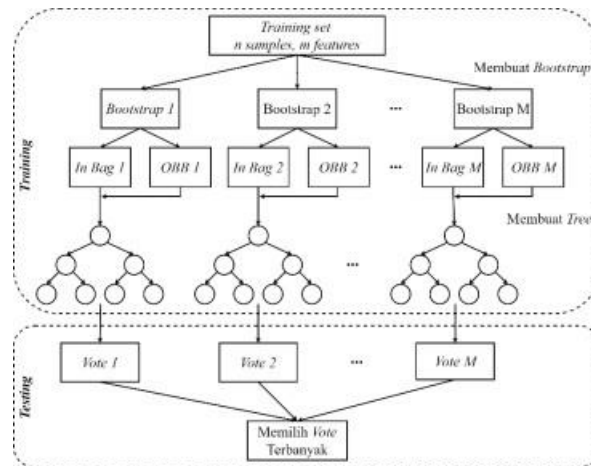
Gambar 5 Proses Ekstraksi LBP Sistem Identifikasi Penyakit Tanaman Apel

3.3.2. Color Histogram

Ekstraksi ciri yang dilakukan menggunakan *Color Histogram* dengan ruang warna HSV. Ruang warna HSV memiliki kinerja yang baik dalam mendeskripsikan karakteristik warna jika dibandingkan dengan ruang warna RGB[7]. Tahap yang dilakukan adalah kuantisasi warna, normalisasi, dan perhitungan histogram. Kuantisasi warna bertujuan untuk mengurangi kemungkinan jumlah warna pada citra, sehingga dapat mengurangi proses komputasi dan akan mempermudah proses yang diperlukan. Hasil dari kuantisasi adalah jumlah piksel yang akan dimasukkan ke n bin. Setiap bin akan berisi nilai statistik berupa persentase dari banyaknya jumlah piksel. Penelitian ini melakukan pengelompokkan piksel warna ke dalam 16 *bin*. Setiap kelompok dilakukan normalisasi untuk menyederhanakan nilai distribusi warna pada histogram dan membuat nilai histogram tetap sama pada citra dengan ukuran citra yang berbeda yang memiliki kesamaan pada distribusi warna.

3.4. Pemodelan

Tahap ini dilakukan klasifikasi menggunakan *Random Forest* yang bertujuan untuk menentukan kelas *Glomerella*, *Healthy*, *Herbicida*, *Magnesium Deficiency*, *Potassium Deficiency*, dan *Scab* pada citra yang digunakan. Skema klasifikasi *Random Forest* terdapat pada Gambar 6.

Gambar 6 Skema Klasifikasi *Random Forest*[15]

Pada proses ini dilakukan pelatihan model dan melihat hasil pemodelan dengan menggunakan validasi. Vektor ciri hasil dari ekstraksi ciri dibagi menjadi menjadi data latih dan data uji menggunakan *cross validation* dan diklasifikasi menggunakan *Random Forest*. Pada proses pembentukan pohon, *Random Forest* melakukan proses latih terhadap sampel data. Sepertiga sampel data pelatihan digunakan sebagai data *Out of Bag* (OBB) untuk menghitung *error* dan menentukan *variable importance*, serta sisanya digunakan sebagai data *In Bag* untuk membentuk pohon. Setiap pohon yang dihasilkan dapat memberikan suatu prediksi yang sama atau berbeda. Prediksi akhir didapatkan dari kelas yang memiliki jumlah prediksi terbanyak.

4. Evaluasi

Tahap evaluasi menggunakan *stratified k-fold validation*, yaitu variasi *k-fold* yang membagi data dalam *k* partisi dengan memastikan di setiap partisi mempunyai proporsi kelas yang sama rata[16]. Tahap ini akan melakukan proses perulangan sebanyak *k* dan data yang digunakan akan dibagi menjadi *k* partisi dengan menjadikan salah satu bagian menjadi data latih dan sisanya menjadi data uji. Hasil yang didapatkan merupakan kinerja model yang diperoleh dari rata-rata setiap perulangan dalam bentuk akurasi.

4.1. Skenario Pengujian

Pada penelitian ini terdapat 4 (empat) skenario pengujian dengan melakukan parameter *tuning*, yaitu:

1. Parameter *Tuning Local Binary Pattern* (LBP).
2. Parameter *Tuning Color Histogram*.
3. Penggabungan metode LBP dan *Color Histogram*.
4. *Tuning hyperparameter* untuk *Random Forest*.

Pada skenario pengujian menggunakan klasifikasi *Random Forest* dengan *bootstap* bernilai *True*, *max_depth* bernilai *None*, *min_samples_leaf* bernilai 1, *min_samples_split* bernilai 2, *n_estimators* bernilai 100, dan *cross validation* dengan nilai *k* sebesar 10. Nilai *k* sebesar 10 adalah nilai yang umum digunakan pada *machine learning* yang dapat bekerja dengan baik[17].

4.2. Hasil Pengujian

4.2.1. Parameter *Tuning Local Binary Pattern* (LBP)

Pada skenario parameter *tuning* ini dilakukan suatu proses dengan mencoba berbagai parameter ketetangaan (P) dan radius (R) pada metode LBP untuk mendapatkan parameter yang optimal. Hasil dari parameter yang mempunya akurasi terbesar akan digunakan untuk pengujian skenario. Nilai parameter yang digunakan adalah $P \in \{4 \ 8 \ 16\}$ dan $R \in \{1 \ 3 \ 4\}$. Tabel 2 merupakan hasil percobaan dari beberapa parameter P dan R pada proses LBP.

Tabel 2 Hasil Parameter *Tuning* LBP

P	R	Akurasi (%)
4	1	62,64
8	1	71,46
4	2	65,19
8	2	72,62
16	2	62,41
4	3	65,19
8	3	74,24
16	3	63,34
4	4	65,66
8	4	70,99
16	4	66,58

Pada Tabel 2 dapat dianalisis parameter LBP yang dapat menghasilkan performansi optimal. Hasil akurasi yang optimal menggunakan nilai parameter (P=8 dan R=3) pada LBP. Nilai dari parameter ini akan digunakan untuk proses selanjutnya.

4.2.2. Parameter *Tuning* Color Histogram

Pada skenario parameter *tuning* ini dilakukan suatu proses untuk mendapatkan parameter yang optimal pada *Color Histogram*. Parameter yang digunakan adalah *channel* warna dan jumlah bin. Ruang warna yang digunakan pada skenario ini berupa HSV dengan jumlah bin yang digunakan adalah 4 bin, 8 bin, dan 16 bin. Tabel 3 merupakan hasil pengujian parameter *tuning* *Color Histogram*.

Tabel 3 Hasil Parameter *Tuning* Color Histogram

Channel	Bin	Akurasi (%)
H	4	55,91
	8	70,06
	16	80,27
S	4	48,25
	8	64,26
	16	64,03
V	4	40,6
	8	55,68
	16	57,3
H,S	16,16	85,61
H,V	16,16	83,29
S,V	16,16	73,54
H,S,V	4,4,4	74,94
	8,8,8	80,97
	16,16,16	86,77

Pada skenario ini dilakukan uji coba menggunakan semua *channel* HSV dengan nilai bin 4,8, dan 16 pada setiap *channel*. Tabel 3 menunjukkan bahwa kinerja terbaik terdapat pada *channel* H, S, dan V dengan jumlah bin sebesar 16. Oleh Karena itu, *channel* H, S, dan V serta nilai bin 16 akan digunakan untuk digabungkan dengan fitur LBP.

4.2.3. Penggabungan Metode LBP dan *Color Histogram*

Pada skenario parameter *tuning* ini dilakukan suatu proses penggabungan metode LBP dan *Color Histogram*. Penggabungan metode ini dilakukan untuk mengetahui seberapa besar peningkatan kinerja yang dihasilkan. Parameter yang digunakan pada penggabungan ini adalah parameter terbaik dari LBP dan *Color Histogram*. Tabel 4 merupakan hasil pengujian dari penggabungan kedua metode.

Tabel 4 Hasil Penggabungan Metode LBP dan *Color Histogram*

	Metode		
	LBP	Color Histogram	Gabungan
Akurasi	74,24%	86,77%	90,48%

Hasil penggabungan dari metode LBP dan *Color Histogram* mendapatkan hasil akurasi sebesar 90.48%. Tabel 4 menunjukkan bahwa penggabungan fitur tekstur dan warna dapat meningkatkan kinerja sistem.

4.2.4. Tuning Hyperparameter untuk Random Forest


Pada skenario *tuning hyperparameter* untuk *random forest* dilakukan untuk mendapatkan parameter terbaik untuk menghasilkan suatu akurasi. Proses ini dilakukan menggunakan *Exhaustive Grid Search*. Hasil parameter yang didapatkan pada proses ini adalah *bootstap* bernilai *True*, *n_estimators* bernilai 1200, *max_depth* bernilai 15, *min_samples_split* bernilai 5, dan *min_samples_leaf* bernilai 1. Tabel 5 merupakan hasil dari klasifikasi menggunakan *random forest*.

Tabel 5 Hasil Pemilihan Hyperparameter untuk Random Forest

Metode	Stratified K-Fold			
	Akurasi	Precision	Recall	F1 Score
LBP dan <i>Color Histogram</i>	91,41%	91,55%	91,41%	91,42%

4.3. Analisis Hasil Pengujian

Hasil pengujian pada 2.154 citra daun tanaman apel dilakukan dengan menggunakan parameter ($P=8$ dan $R=3$) pada konfigurasi LBP dan ruang warna H, S, dan V dengan jumlah bin sebanyak 16 bin, parameter *Random Forest* dengan *bootstap* bernilai *True*, *max_depth* bernilai 25, *min_samples_leaf* bernilai 1, *min_samples_split* bernilai 5, *n_estimators* bernilai 1200, dan parameter *k* pada *cross validation* sebesar 10. Akurasi yang didapatkan sebesar 91,41%. Gambar 7 merupakan *confussion matrix* dari hasil proses pengujian yang dilakukan.




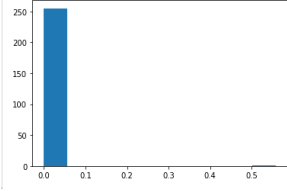
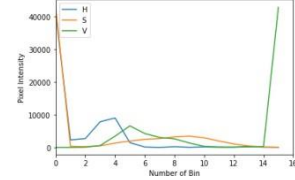
Gambar 7 Confussion Matrix

Berdasarkan dari hasil *confussion matrix* pada Gambar 6, memiliki jumlah data uji sebanyak 431 citra yang terdiri dari 115 citra *Glomerella*, 29 citra *Healthy*, 70 citra *Herbicida*, 76 citra *Magnesium Deficiency*, 68 citra *Potassium Deficiency*, dan 73 citra *Scab*. Berdasarkan hasil pengujian, 391 citra berhasil diidentifikasi dengan benar. Citra yang berhasil teridentifikasi dengan benar adalah 109 citra *Glomerella*, 29 citra *Healthy*, 63 citra *Herbicida*, 65 citra *Magnesium Deficiency*, 63 citra *Potassium Deficiency*, dan 65 citra *Scab*. Sedangkan citra yang salah teridentifikasi sebanyak 37 citra, dengan rincian 2 citra *Glomerella* teridentifikasi sebagai kelas *Magnesium Deficiency*, 1 citra *Glomerella* teridentifikasi sebagai kelas *Potassium Deficiency*, 3 citra *Glomerella* teridentifikasi sebagai kelas *Scab*, 6 citra *Herbicida* teridentifikasi sebagai kelas *Glomerella*, 1 citra *Herbicida*

teridentifikasi sebagai kelas *Scab*, 3 citra *Magnesium Deficiency* teridentifikasi sebagai kelas *Glomerella*, 1 citra *Magnesium Deficiency* teridentifikasi sebagai kelas *Herbicida*, 3 citra *Magnesium Deficiency* teridentifikasi sebagai kelas *Potassium Deficiency*, 4 citra *Magnesium Deficiency* teridentifikasi sebagai kelas *Scab*, 3 citra *Potassium Deficiency* teridentifikasi sebagai kelas *Glomerella*, 1 citra *Potassium Deficiency* teridentifikasi sebagai kelas *Magnesium Deficiency*, 1 citra *Potassium Deficiency* teridentifikasi sebagai kelas *Scab*, 2 citra *Scab* teridentifikasi sebagai kelas *Glomerella*, 5 citra *Scab* teridentifikasi sebagai kelas *Magnesium Deficiency*, dan 3 citra *Scab* teridentifikasi sebagai kelas *Potassium Deficiency*.

Pada Gambar 6 dapat dilihat bahwa hasil salah terprediksi terbanyak adalah 6 citra daun penyakit *Herbicida* terprediksi penyakit *Glomerella*. Hal ini disebabkan karena terdapat satu kesamaan gejala yang dialami oleh daun dengan penyakit *Herbicida* dan *Glomerella*. Gejala tersebut adalah daun akan berubah warna menjadi kuning jika tidak segera diatasi. Tabel 6 merupakan salah satu citra kelas *Herbicida* yang teridentifikasi menjadi kelas *Glomerella*.

Tabel 6 Sampel Citra Kelas *Herbicida* Teridentifikasi Kelas *Glomerella*

Citra	Kelas		LBP Histogram	Color Histogram
	Asal	Prediksi		
	<i>Herbicida</i>	<i>Glomerella</i>		

Tabel 7 merupakan perbandingan jarak antara fitur kelas asal dengan fitur kelas prediksi menggunakan *Euclidean distance*.

Tabel 7 Perbandingan Jarak *Euclidean Distance* Kelas *Herbicida* Terprediksi *Glomerella*

Rata-rata jarak LBP		Rata-rata jarak <i>Color Histogram</i>	
Asal	Prediksi	Asal	Prediksi
0,1915	0,1855	34.134,14	29.932,64

Tabel 8 merupakan kinerja sistem yang didapat berdasarkan Gambar 6.

Tabel 8 Kinerja Sistem

	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	Jumlah Data
<i>Glomerella</i>	89%	95%	92%	115
<i>Healthy</i>	100%	100%	100%	29
<i>Herbicida</i>	98%	90%	94%	70
<i>Magnesium Deficiency</i>	89%	86%	87%	76
<i>Potassium Deficiency</i>	93%	93%	93%	68
<i>Scab</i>	88%	89%	88%	68
Akurasi			91%	431
Weighted avg	92%	91%	91%	431

Weighted avg adalah nilai rata-rata dari setiap nilai *Precision*, *Recall*, dan *F1 Score*. Berdasarkan dari hasil yang didapatkan pada Tabel 8, sistem yang dibangun memiliki kinerja terbaik dengan akurasi sebesar 91%, *Precision* sebesar 92%, *Recall* sebesar 91%, dan *F1 Score* sebesar 91%.

5. Kesimpulan

Berdasarkan hasil pengujian dan analisis yang dilakukan, dapat disimpulkan bahwa sistem identifikasi penyakit pada daun tanaman apel menggunakan metode *Local Binary Pattern (LBP)*, *Color Histogram*, dan metode klasifikasi *Random Forest* menghasilkan akurasi sebesar 91,41% dengan *precision* sebesar 91,55%, *Recall* sebesar 91,41%, dan *F1 Score* sebesar 91,42%. Parameter terbaik pada LBP dengan jumlah ketetanggaan sebesar 8 dan nilai radius sebesar 3. Parameter terbaik pada *Color Histogram* dengan menggunakan *channel H, S, dan V* dengan jumlah bin 16. Parameter terbaik pada *Random Forest* dengan jumlah pohon sebanyak 1200.

Adapun saran untuk penelitian selanjutnya adalah dengan menambahkan data augmentasi untuk meningkatkan jumlah sampel pada masing-masing kelas.

Reference

- [1] H. Sabrol and K. Satish, "Tomato Plant Disease Classification in Digital Images using Classification Tree," *Int. Conf. Commun. Signal Process. ICCSP 2016*, pp. 1242–1246, 2016, doi: 10.1109/ICCSP.2016.7754351.
- [2] H. Waghmare, R. Kokare, and Y. Dandawate, "Detection and Classification of Diseases of Grape Plant using Opposite Colour Local Binary Pattern Feature and Machine Learning for Automated Decision Support System," *3rd Int. Conf. Signal Process. Integr. Networks, SPIN 2016*, pp. 513–518, 2016, doi: 10.1109/SPIN.2016.7566749.
- [3] L. G. Nachtigall, R. M. Araujo, and G. R. Nachtigall, "Classification of Apple Tree Disorders using Convolutional Neural Networks," *Proc. - 2016 IEEE 28th Int. Conf. Tools with Artif. Intell. ICTAI 2016*, pp. 472–476, 2017, doi: 10.1109/ICTAI.2016.75.
- [4] S. Santhosh Kumar and B. K. Raghavendra, "Diseases Detection of Various Plant Leaf Using Image Processing Techniques: A Review," *2019 5th Int. Conf. Adv. Comput. Commun. Syst. ICACCS 2019*, pp. 313–316, 2019, doi: 10.1109/ICACCS.2019.8728325.
- [5] A. Gargade and S. A. Khandekar, "A Review: Custard Apple Leaf Parameter Analysis and Leaf Disease Detection using Digital Image Processing," *Proc. 3rd Int. Conf. Comput. Methodol. Commun. ICCMC 2019*, no. Iccmc, pp. 267–271, 2019, doi: 10.1109/ICCMC.2019.8819867.
- [6] T. V. Janahiraman, L. K. Yee, C. S. Der, and H. Aris, "Leaf Classification using Local Binary Pattern and Histogram of Oriented Gradients," *2019 7th Int. Conf. Smart Comput. Commun. ICSCC 2019*, pp. 1–5, 2019, doi: 10.1109/ICSCC.2019.8843650.
- [7] J. Liu, F. Lv, and D. Penghui, "Identification of Sunflower Leaf Diseases Based on Random Forest Algorithm," *Proc. - 2019 Int. Conf. Intell. Comput. Autom. Syst. ICICAS 2019*, vol. 11, pp. 459–463, 2019, doi: 10.1109/ICICAS48597.2019.00102.
- [8] L. Toumbourou, "Plant Village Apple." [Online]. Available: [https://www.kaggle.com/lextoumbourou/plantvillageapplecolor?select=Apple healthy](https://www.kaggle.com/lextoumbourou/plantvillageapplecolor?select=Apple+healthy). [Accessed: 24-Nov-2020].
- [9] "DataSet-Apple Leaves." [Online]. Available: <https://www.dropbox.com/s/b81z064ohynhlgN/DataSet-AppleLeaves.zip>. [Accessed: 20-Feb-2020].
- [10] S. R. Dubey and A. S. Jalal, "Detection and Classification of Apple Fruit Diseases using Complete Local Binary Patterns," *Proc. 2012 3rd Int. Conf. Comput. Commun. Technol. ICCCT 2012*, pp. 346–351, 2012, doi: 10.1109/ICCCT.2012.76.
- [11] A. Muthevi and R. B. Uppu, "Leaf Classification using Completed Local Binary Pattern of Textures," *Proc. - 7th IEEE Int. Adv. Comput. Conf. IACC 2017*, pp. 870–874, 2017, doi: 10.1109/IACC.2017.0178.
- [12] P. Hidayatullah, *Pengolahan Citra Digital: Teori dan Aplikasi Nyata*. Informatika Bandung, 2017.
- [13] J. Lu, W. S. Lee, H. Gan, and X. Hu, "Immature Citrus Fruit Detection Based on Local Binary Pattern Feature and Hierarchical Contour Analysis," *Biosyst. Eng.*, vol. 171, pp. 78–90, 2018, doi: 10.1016/j.biosystemseng.2018.04.009.
- [14] E. Prakasa, "Ekstraksi Ciri Tekstur dengan Menggunakan Local Binary Pattern Texture Feature Extraction by Using Local Binary Pattern," vol. 9, no. 2, pp. 45–48, 2016.
- [15] Y. C. See, J. L. Low, and E. Liew, "Investigation of Face Recognition Using Gabor Filter With Random Forest As Learning Framework," pp. 1153–1158, 2017.
- [16] S. Yadav and S. Shukla, "Analysis of K-Fold Cross-Validation over Hold-Out Validation on Colossal Datasets for Quality Classification," *Proc. - 6th Int. Adv. Comput. Conf. IACC 2016*, no. Cv, pp. 78–83, 2016, doi: 10.1109/IACC.2016.25.
- [17] T. Gunasegaran and Y. N. Cheah, "Evolutionary Cross Validation," *ICIT 2017 - 8th Int. Conf. Inf. Technol. Proc.*, pp. 89–95, 2017, doi: 10.1109/ICITECH.2017.8079960.

Lampiran
Hasil Tuning Hyperparameter Random Forest

Tabel 9 merupakan beberapa hasil *tuning hyperparameter random forest* yang dilakukan.


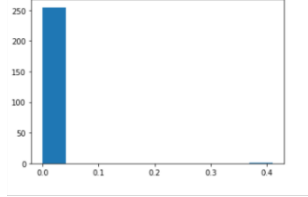
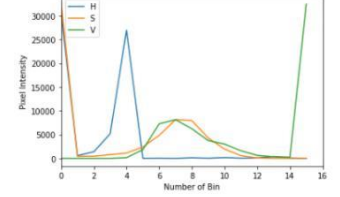
Tabel 9 Hasil Tuning Hyperparameter Random Forest

<i>n_estimators</i>	<i>max_depth</i>	<i>min_samples_split</i>	<i>min_samples_leaf</i>	Akurasi	Precision	Recall	F1 Score
100	8	10	1	89,09%	89,31%	89,09%	89,12%
500	5	5	1	84,68%	85,1%	84,68%	84,74%
1200	10	2	1	90,95%	91,1%	90,95%	90,96%
1200	15	5	1	91,41%	91,55%	91,41%	91,42%
1200	25	5	1	91,18%	91,31%	91,18%	91,19%
1200	30	5	1	91,18%	91,31%	91,18%	91,19%

Data Salah Teridentifikasi

Berikut ini merupakan beberapa sampel lain dari hasil citra yang salah teridentifikasi. Tabel 10 merupakan salah satu citra kelas *Scab* yang teridentifikasi menjadi kelas *Glomerella*.

Tabel 10 Citra Kelas *Scab* Teridentifikasi Kelas *Glomerella*

Citra	Kelas		LBP Histogram	Color Histogram
	Asal	Prediksi		
	<i>Glomerella</i>	<i>Scab</i>		


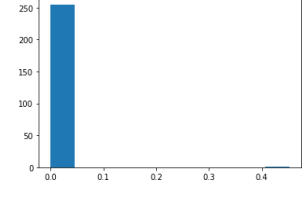
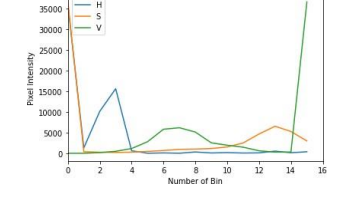
Tabel 11 merupakan perbandingan jarak antara fitur kelas asal dengan fitur kelas prediksi menggunakan *euclidean distance* berdasarkan Tabel 10.

Tabel 11 Perbandingan Jarak *Euclidean Distance* Kelas *Scab* Terprediksi *Glomerella*

Rata-rata jarak LBP		Rata-rata jarak <i>Color Histogram</i>	
Asal	Prediksi	Asal	Prediksi
0,0808	0,0737	33.195,56	26.593,72

Tabel 12 merupakan salah satu citra kelas *Potassium Deficiency* yang teridentifikasi menjadi kelas *Glomerella*.

Tabel 12 Citra Kelas *Potassium Deficiency* Teridentifikasi Kelas *Glomerella*

Citra	Kelas		LBP Histogram	Color Histogram
	Asal	Prediksi		
	<i>Potassium Deficiency</i>	<i>Glomerella</i>		


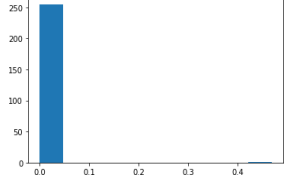
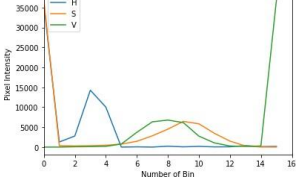
Tabel 13 merupakan perbandingan jarak antara fitur kelas asal dengan fitur kelas prediksi menggunakan *euclidean distance* berdasarkan Tabel 12.

Tabel 13 Perbandingan Jarak *Euclidean Distance* Kelas *Potassium* Terprediksi *Glomerella*

Rata-rata jarak LBP		Rata-rata jarak <i>Color Histogram</i>	
Asal	Prediksi	Asal	Prediksi
0, 1023	0,0709	30.292,37	20.233,71

Tabel 14 merupakan salah satu citra kelas *Magnesium Deficiency* yang teridentifikasi menjadi kelas *Potassium Deficiency*.

Tabel 14 Citra Kelas *Magnesium* Teridentifikasi Kelas *Potassium*

Citra	Kelas		LBP Histogram	<i>Color Histogram</i>
	Asal	Prediksi		
	<i>Magnesium Deficiency</i>	<i>Potassium Deficiency</i>		


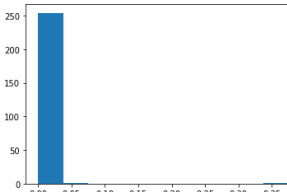
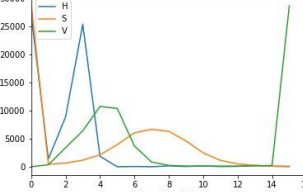
Tabel 15 merupakan perbandingan jarak antara fitur kelas asal dengan fitur kelas prediksi menggunakan *euclidean distance* berdasarkan Tabel 14.

Tabel 15 Perbandingan Jarak *Euclidean Distance* Kelas *Magnesium* Terprediksi *Potassium*

Rata-rata jarak LBP		Rata-rata jarak <i>Color Histogram</i>	
Asal	Prediksi	Asal	Prediksi
0, 0789	0,0677	20.897,83	17.855,16

Tabel 16 merupakan salah satu citra kelas *Herbicida* yang teridentifikasi menjadi kelas *Glomerella*.

Tabel 16 Citra Kelas *Scab* Teridentifikasi Kelas *Potassium*

Citra	Kelas		LBP Histogram	<i>Color Histogram</i>
	Asal	Prediksi		
	<i>Scab</i>	<i>Potassium Deficiency</i>		

Tabel 17 merupakan perbandingan jarak antara fitur kelas asal dengan fitur kelas prediksi menggunakan *euclidean distance* berdasarkan Tabel 16.

Tabel 17 Perbandingan Jarak *Euclidean Distance* Kelas *Scab* Terprediksi *Potassium*

Rata-rata jarak LBP		Rata-rata jarak <i>Color Histogram</i>	
Asal	Prediksi	Asal	Prediksi
0,0763	0,0649	34.230,73	25.097,88