



Investigasi Forensik Citra Penyakit Daun Bonsai dengan Fitur GLCM dan Bentuk Berbasis Deep Learning

Jesica Mayanda^{1*}, Amrullah²

^{1*,2}Program Studi Sistem Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara, Medan, Indonesia
Email: ^{1*}jessicamayanda@gmail.com, ²amrullah@umsu.ac.id

Abstrak

Identifikasi penyakit daun bonsai secara visual bersifat subjektif dan bergantung pada pengalaman pengamat. Penelitian ini bertujuan mengembangkan dan mengevaluasi sistem klasifikasi kondisi daun bonsai beringin dan serut ke dalam empat kelas, yaitu sehat, bercak, klorosis, dan nekrosis, dengan menggabungkan fitur tekstur Gray Level Co-occurrence Matrix (GLCM) dan fitur bentuk kontur pada jaringan saraf tiruan berlapis. Alur pemrosesan mengacu pada kerangka forensik digital NIST SP 800-86 dan mencakup penyeragaman citra 224×224 piksel, konversi keabuan, segmentasi Otsu, ekstraksi empat fitur GLCM (contrast, correlation, energy, homogeneity) serta empat fitur bentuk (area, perimeter, metric, eccentricity), standarisasi, dan klasifikasi dengan tiga lapisan tersembunyi (128, 64, dan 32 neuron) yang dilatih menggunakan optimizer Adam. Evaluasi pada 113 citra uji menghasilkan akurasi 93,81% (selang kepercayaan 95%: 87,8–97,0%), macro-precision 95,12%, macro-recall 93,08%, dan macro-F1 94,00%. Seluruh citra sehat terklasifikasi benar, sedangkan recall terendah terdapat pada kelas nekrosis (85,00%) karena nilai contrast dan metric kelas ini tumpang tindih dengan kelas bercak. Ketujuh kesalahan terjadi antarkelas sakit. Nilai metric yang konstan pada citra sehat mengindikasikan segmentasi global yang masih sensitif terhadap latar, sehingga diperlukan segmentasi yang lebih kuat, data yang lebih beragam, dan uji ablasi fitur. Sistem diimplementasikan sebagai aplikasi web Streamlit untuk skrining awal.

Kata Kunci: bonsai, GLCM, fitur bentuk, deep learning, klasifikasi penyakit daun.

PENDAHULUAN

Bonsai adalah seni budidaya tanaman dalam wadah dangkal yang menuntut perawatan intensif. Beringin dan serut termasuk jenis yang umum dijadikan bonsai sehingga memiliki nilai ekonomi bagi pembudidaya (Oryza Sativa dan Serdani, 2022). Keterbatasan ruang akar dan pemangkasan berulang membuat tanaman ini rentan terhadap gangguan yang tampak pada daun, seperti bercak, klorosis, dan nekrosis. Kondisi daun umumnya masih ditentukan melalui pengamatan visual, yang bergantung pada pengalaman pengamat dan dapat menghasilkan penilaian yang berbeda antarpengamat. Pendekatan komputasional untuk bonsai yang ditemukan dalam penelusuran literatur penulis berupa sistem pakar yang bernalar dari gejala yang dimasukkan pengguna, misalnya dengan forward chaining dan certainty factor (Anita dkk., 2019), sehingga hasil diagnosis tetap bergantung pada penilaian manusia terhadap gejala.

Pada tanaman pangan dan hortikultura, klasifikasi penyakit dari citra daun telah berkembang pesat. Tinjauan Shoaib dkk. (2023) merangkum perkembangan terbaru deep learning untuk deteksi penyakit tanaman, termasuk jaringan konvolusi (CNN), transfer learning, dan metode ensambel. Contoh penerapannya meliputi pengenalan penyakit daun padi dengan transfer learning (Simhadri dan Kondaveeti, 2023), identifikasi penyakit tanaman dengan CNN (Hassan dan Maji, 2022; Sun dkk., 2022), serta deteksi penyakit jeruk pada perangkat tepi (Dhiman dkk., 2023). Orchi dkk. (2023) membandingkan machine learning konvensional dengan deep transfer learning untuk deteksi penyakit tanaman. Di Indonesia, Anggiratih dkk. (2021) menerapkan EfficientNet B3 pada penyakit padi dan Burhanuddin (2024) memakai Naive Bayes untuk klasifikasi penyakit padi dari citra daun.

Selain fitur yang dipelajari otomatis oleh CNN, fitur rekayasa (*handcrafted*) tetap relevan ketika data terbatas dan interpretabilitas dibutuhkan. Gray Level Co-occurrence Matrix (GLCM) (Haralick dkk., 1973) adalah deskriptor tekstur orde kedua yang banyak dipakai. Kabir dkk. (2024) menunjukkan bahwa metrik GLCM bervariasi antardataset penyakit tanaman dan berkaitan dengan kinerja model, sehingga pemilihan dan evaluasi dataset perlu dilakukan dengan cermat. Singh dkk. (2022) menggabungkan fitur warna, tekstur, dan fitur dalam (*deep features*) untuk deteksi penyakit daun, sedangkan Fi'Nawu dkk. (2026) memakai GLCM dan K-Nearest Neighbor untuk empat kelas penyakit cabai dengan akurasi tertinggi

88,19% pada 736 citra daun. Fitur morfologi juga bermanfaat: ScabyNet memadukan sifat morfologi dan deep learning untuk menilai keparahan kudis pada umbi kentang (Leiva dkk., 2024), dan Harakannanavar dkk. (2022) melaporkan penggunaan visi komputer dan machine learning untuk deteksi penyakit daun.

Perspektif forensik citra memberi kerangka kerja yang terstruktur dan dapat diaudit. Panduan NIST SP 800-86 (Kent dkk., 2006) membagi investigasi menjadi pengumpulan, pemeriksaan, analisis, dan pelaporan. Pada penelitian ini, keempat fase tersebut dipetakan ke akuisisi citra daun, prapemrosesan dan segmentasi, ekstraksi fitur dan klasifikasi, serta pelaporan hasil. Pendekatan fitur rekayasa dengan klasifikator pada domain forensik citra juga telah dilaporkan dalam artikel IJOMSS. Amrullah (2026) menggabungkan Histogram of Oriented Gradients (HOG) dan Support Vector Machine untuk verifikasi tanda tangan dengan akurasi 75,00% pada dataset CEDAR, Kuncoro dan Syahra (2026) memakai deteksi tepi Canny untuk analisis bentuk dan tekstur citra pupuk dalam aplikasi web, dan Ahmed dkk. (2021) memanfaatkan fitur tekstur untuk mendeteksi pemalsuan citra. Studi-studi tersebut menunjukkan bahwa bentuk dan tekstur merupakan petunjuk terukur untuk analisis citra, tetapi belum diterapkan pada penyakit daun bonsai.

Berdasarkan kajian tersebut, terdapat tiga kesenjangan. Pertama, penelitian bonsai yang ditemukan berbasis sistem pakar dan belum memakai citra daun. Kedua, penelitian GLCM pada penyakit tanaman umumnya memakai klasifikator dangkal dan jarang menyertakan fitur bentuk kontur secara eksplisit. Ketiga, laporan kinerja sering tidak menyertakan matriks konfusi dan analisis kesalahan secara lengkap (Luque dkk., 2019). Kebaruan artikel ini adalah (1) klasifikator hibrida berbasis delapan fitur (empat GLCM dan empat bentuk) pada jaringan saraf berlapis untuk empat kondisi daun bonsai beringin dan serut, (2) pemetaan alur ke fase NIST SP 800-86 yang menghasilkan laporan CSV untuk audit, dan (3) pelaporan terbuka matriks konfusi, metrik per kelas, analisis kesalahan, serta keterbatasan segmentasi.

Masalah yang dikaji adalah seberapa baik kombinasi fitur tekstur GLCM dan fitur bentuk yang diproses jaringan saraf berlapis dapat mengklasifikasikan kondisi daun bonsai. Tujuan artikel ini adalah (1) membangun alur klasifikasi dari citra daun hingga aplikasi web, (2) mengevaluasi kinerjanya menggunakan akurasi, presisi, recall, dan F1-score, serta (3) menganalisis pola kesalahan dan keterbatasan sistem.

METODE

Desain Penelitian dan Kerangka Forensik

Penelitian ini bersifat eksperimental kuantitatif disertai pengembangan sistem. Alur penelitian terdiri atas lima tahap, yaitu pengumpulan data, prapemrosesan citra, ekstraksi fitur GLCM dan bentuk, pelatihan dan klasifikasi deep learning, serta evaluasi model (Gambar 1). Tahap-tahap ini mengikuti fase NIST SP 800-86 (Kent dkk., 2006): *collection* (akuisisi citra daun pada pencahayaan terkontrol), *examination* (penyeragaman ukuran, konversi keabuan, dan thresholding Otsu), *analysis* (ekstraksi fitur dan klasifikasi), serta *reporting* (penampilan hasil, rekomendasi, dan laporan CSV).



Gambar 1. Alur penelitian


Dataset

Objek penelitian adalah daun bonsai beringin (*Ficus* sp.) dan serut (*Streblus asper*). Bonsai bukan nama spesies melainkan teknik budidaya, sehingga sistem mengklasifikasikan kondisi daun dan tidak mengidentifikasi spesies. Terdapat empat kelas: sehat, bercak, klorosis, dan nekrosis (Gambar 2). Citra

berupa potret daun individual pada pencahayaan terkontrol dengan latar yang kontras, dikompilasi dari citra primer dan arsip citra daun, serta dibersihkan dari citra yang sangat buram. Label ditetapkan oleh pakar patologi botani. Data dibagi dengan skema *hold-out* 80% untuk pelatihan dan 20% untuk pengujian. Data uji terdiri atas 113 citra, yaitu 50 bercak, 23 klorosis, 20 nekrosis, dan 20 sehat (Gambar 3).

Tabel 1. Contoh Sampel Citra Dataset Himpunan Uji

Kelas Anotasi (Ground-truth)	Karakteristik Visual	Sampel Citra Digital
Sehat	Distribusi klorofil merata, warna hijau pekat, dan tepi daun utuh tanpa deformasi.	
Klorosis	Pigmen memudar secara asimetris, daun menguning dengan struktur urat yang masih terlihat.	
Bercak Daun	Terdapat lesi atau bercak coklat kehitaman akibat infeksi jamur pada jaringan epidermis.	
Nekrosis	Jaringan daun mati, mengering, berwarna coklat gelap hingga abu-abu, area fisik menyusut.	



Gambar 3. Parameter himpunan data

Prapemrosesan dan Segmentasi

Setiap citra diubah ukurannya menjadi 224×224 piksel, dikonversi ke skala keabuan, lalu dibinarisasi dengan metode Otsu (Otsu, 1979). Metode ini memilih satu ambang T dari histogram keabuan yang memaksimalkan varians antarkelas $\sigma_B^2(T)$:

$$\sigma_B^2(T) = \omega_0(T) \omega_1(T) [\mu_0(T) - \mu_1(T)]^2 \quad (1)$$

dengan ω_0, ω_1 adalah proporsi piksel pada dua kelas dan μ_0, μ_1 adalah rerata intensitas kelas tersebut. Piksel di atas T menjadi putih (255) dan sisanya hitam (0). Pada citra biner, kontur terluar dicari dengan *findContours* (mode *RETR_EXTERNAL*) dan kontur dengan luas terbesar dipilih sebagai objek daun. Kontur ini hanya dipakai untuk fitur bentuk. Fitur tekstur GLCM dihitung dari seluruh citra keabuan 224×224, bukan hanya dari area hasil segmentasi.

Ekstraksi Fitur

Fitur bentuk dihitung dari kontur terbesar. Area (A) adalah luas kontur dalam piksel dan Perimeter (P) adalah panjang kontur (*contourArea* dan *arcLength* pada OpenCV). Metric menyatakan kebulatan, bernilai 1 untuk lingkaran sempurna:

$$\text{Metric} = 4\pi A / P^2 \quad (2)$$

Eccentricity diperoleh dari elips yang dicocokkan pada kontur, dengan a dan b masing-masing sumbu mayor dan minor:

$$e = \sqrt{1 - b^2 / a^2} \quad (3)$$

Fitur tekstur dihitung dari matriks ko-okurensi ternormalisasi $p(i,j)$ pada jarak $d = 1$ dan sudut $0^\circ, 45^\circ, 90^\circ$, dan 135° menggunakan *scikit-image*, kemudian diintegrasikan menjadi satu nilai untuk setiap fitur. Keempat fitur GLCM mengikuti definisi Haralick dkk. (1973) sebagaimana diimplementasikan pada *scikit-image*:

$$\text{Contrast} = \sum_{i,j} (i - j)^2 p(i,j) \quad (4)$$

$$\text{Correlation} = \sum_{i,j} (i - \mu_i)(j - \mu_j) p(i,j) / (\sigma_i \sigma_j) \quad (5)$$

$$\text{Energy} = \sqrt{\sum_{i,j} p(i,j)^2} \quad (6)$$

$$\text{Homogeneity} = \sum_{i,j} p(i,j) / (1 + (i - j)^2) \quad (7)$$

Keempat fitur GLCM dan keempat fitur bentuk digabung menjadi vektor delapan elemen (Tabel 1), lalu distandardisasi dengan skor-z menggunakan *scaler* yang disimpan dari proses pelatihan:

$$z = (x - \mu) / \sigma \quad (8)$$

Tabel 2. Fitur masukan klasifikator

No.	Fitur (kelompok)	Keterangan
1–4	Contrast, Correlation, Energy, Homogeneity (tekstur GLCM)	Dihitung dari seluruh citra keabuan 224×224; $d = 1$; sudut $0^\circ, 45^\circ, 90^\circ, 135^\circ$
5	Area (bentuk)	Luas kontur terbesar (piksel)
6	Perimeter (bentuk)	Panjang kontur terbesar (piksel)
7	Metric (bentuk)	Kebulatan kontur, $4\pi A/P^2$
8	Eccentricity (bentuk)	Kelonjongan elips yang dicocokkan pada kontur

Arsitektur dan Pelatihan Model

Klasifikator adalah jaringan saraf tiruan berlapis terhubung penuh (*multilayer perceptron*) berurutan dengan tiga lapisan tersembunyi, yaitu 128, 64, dan 32 neuron berfungsi aktivasi ReLU. Setiap lapisan tersembunyi dilengkapi *Batch Normalization* dan *Dropout* 0,3, dan lapisan keluaran empat neuron memakai softmax. Model dilatih dengan optimizer Adam (Kingma dan Ba, 2015) dan fungsi kerugian *categorical cross-entropy*. Konfigurasi lengkap disajikan pada Tabel 2.

Tabel 3. Konfigurasi model dan pelatihan

Komponen	Pengaturan
Masukan	Vektor 8 fitur terstandardisasi
Lapisan tersembunyi	Dense 128 → 64 → 32, aktivasi ReLU
Regularisasi	Batch Normalization pada tiap lapisan; Dropout 0,3
Keluaran	Dense 4 neuron, softmax (sehat, bercak, klorosis, nekrosis)
Optimizer dan laju belajar	Adam; laju belajar awal 0,001
Fungsi kerugian	Categorical cross-entropy

Komponen	Pengaturan
Epoch maksimum	150
Callback	EarlyStopping (patience 25, memantau validation loss); ReduceLROnPlateau (faktor 0,5); ModelCheckpoint (menyimpan bobot terbaik)
Perangkat lunak	Python 3.10, OpenCV, scikit-image, scikit-learn, TensorFlow/Keras, Streamlit

Evaluasi Kinerja

Kinerja dievaluasi pada data uji menggunakan matriks konfusi. Karena jumlah sampel antarkelas tidak seimbang (20 hingga 50 citra), metrik dilaporkan per kelas selain akurasi total (Luque dkk., 2019). Untuk kelas ke- k dengan TP_k , FP_k , dan FN_k :

$$\text{Accuracy} = \sum_k TP_k / N \quad (9)$$


$$\text{Precision}_k = TP_k / (TP_k + FP_k), \quad \text{Recall}_k = TP_k / (TP_k + FN_k) \quad (10)$$

$$F1_k = 2 \cdot \text{Precision}_k \cdot \text{Recall}_k / (\text{Precision}_k + \text{Recall}_k) \quad (11)$$


Nilai macro diperoleh dari rerata tidak berbobot keempat kelas. Ketidakpastian akurasi dinyatakan dengan selang kepercayaan Wilson 95%, dan kesesuaian prediksi dengan label dinyatakan dengan koefisien Cohen's kappa.

Implementasi Aplikasi Web


Model diimplementasikan dalam aplikasi web Streamlit bernama *Bonsai Forensics*. Pengguna dapat mengunggah citra atau memilih citra dari folder uji, menjalankan diagnosis, melihat hasil beserta rekomendasi penanganan, menjalankan pengujian massal, dan mengunduh laporan CSV. Perancangan sistem dimodelkan dengan *flowchart* dan UML, yaitu *use case diagram*, *activity diagram*, dan *class diagram* (Gambar 4–8), sedangkan rancangan antarmuka ditunjukkan pada Gambar 9. Apabila model gagal dimuat, aplikasi memakai mesin cadangan berbasis aturan: kelas klorosis ditetapkan jika proporsi warna kuning pada ruang warna HSV melebihi 20%, dan kelas nekrosis ditetapkan jika Contrast lebih dari 180 dengan Metric kurang dari 0,45. Mesin cadangan ini tidak dievaluasi dan tidak digunakan dalam hasil artikel ini.




Gambar 4. Flowchart dan algoritma program




Gambar 5. Perancangan UML




Gambar 6. Use case diagram



Gambar 7. Activity diagram



Gambar 8. Class diagram



Gambar 9. Rancangan antarmuka aplikasi web

HASIL DAN PEMBAHASAN

Kinerja Klasifikasi

Dari 113 citra uji, 106 citra terklasifikasi benar sehingga akurasi mencapai 93,81% (selang kepercayaan Wilson 95%: 87,8–97,0%) dengan Cohen's kappa 0,91. Tabel 3 dan Gambar 10 menunjukkan matriks konfusi. Kelas sehat terklasifikasi sempurna (20 dari 20), diikuti bercak (48 dari 50; 96,00%), klorosis (21 dari 23; 91,30%), dan nekrosis (17 dari 20; 85,00%). Seluruh tujuh kesalahan terjadi antarkelas sakit: tidak ada daun sakit yang diprediksi sehat dan tidak ada daun sehat yang diprediksi sakit.

Tabel 4. Matriks konfusi dan akurasi per kelas pada 113 citra uji

Kelas aktual	Jumlah	Prediksi bercak	Prediksi klorosis	Prediksi nekrosis	Prediksi sehat	Akurasi kelas (%)
Bercak	50	48	1	1	0	96,00
Klorosis	23	2	21	0	0	91,30
Nekrosis	20	3	0	17	0	85,00
Sehat	20	0	0	0	20	100,00
Total	113	53	22	18	20	93,81



Gambar 10. Heatmap confusion matrix klasifikasi penyakit daun bonsai

Metrik per kelas yang dihitung dari Tabel 3 disajikan pada Tabel 4. Macro-precision, macro-recall, dan macro-F1 masing-masing 95,12%, 93,08%, dan 94,00%. Presisi kelas bercak (90,57%) paling rendah karena lima citra dari kelas lain (dua klorosis dan tiga nekrosis) diprediksi sebagai bercak, sedangkan recall kelas nekrosis (85,00%) paling rendah karena seluruh kesalahannya jatuh ke kelas bercak. Dengan hanya 20 citra, selang kepercayaan Wilson 95% untuk recall nekrosis lebar, yaitu 64,0–94,8%.

Tabel 5. Precision, recall, dan F1-score per kelas

Kelas	Jumlah uji	Precision (%)	Recall (%)	F1-score (%)
Bercak	50	90,57	96,00	93,20
Klorosis	23	95,45	91,30	93,33
Nekrosis	20	94,44	85,00	89,47
Sehat	20	100,00	100,00	100,00
Macro-average	113	95,12	93,08	94,00

Dinamika Pelatihan

Kurva pelatihan selama maksimum 150 epoch ditunjukkan pada Gambar 11. Pada sekitar 30 epoch pertama, *loss* pelatihan dan validasi turun tajam dari sekitar 1,5 hingga di bawah 0,3. Akurasi validasi kemudian stabil pada rentang 93–96% hingga sekitar epoch ke-100, dan setelahnya kurva *loss* pelatihan dan validasi tetap berdekatan tanpa kenaikan *loss* validasi yang jelas. Pola ini tidak menunjukkan *overfitting* yang nyata pada data validasi, tetapi tidak menggantikan pengujian pada data independen yang lebih besar.



Gambar 11. Kurva akurasi dan loss pelatihan model

Karakteristik Fitur Teksstur dan Bentuk

Tabel 5 merangkum rentang dan rerata fitur Contrast dan Metric pada data uji. Rentang Contrast kelas sehat (29,49–78,11; rerata 47,82) hampir tidak tumpang tindih dengan kelas sakit, yang nilai minimumnya 78,17 (klorosis), 225,40 (bercak), dan 295,77 (nekrosis). Klorosis memiliki Contrast moderat (rerata 179,53), sedangkan bercak dan nekrosis tinggi dengan rerata yang hampir sama (612,14 dan 614,08). Pada fitur bentuk, Metric bercak (rerata 0,0864) dan nekrosis (0,0512) rendah karena kontur lesi yang tidak teratur memperbesar perimeter tanpa menambah luas secara sebanding.

Tabel 6. Statistik fitur Contrast (GLCM) dan Metric (bentuk) per kelas

Kelas	Rentang Contrast	Rerata Contrast	Rentang Metric	Rerata Metric
Bercak	225,40–1146,55	612,14	0,0230–0,2007	0,0864
Klorosis	78,17–339,45	179,53	0,0243–0,7854	0,1652
Nekrosis	295,77–843,39	614,08	0,0233–0,1944	0,0512
Sehat	29,49–78,11	47,82	0,2100–0,7854	0,7566

Catatan: rerata Metric kelas Sehat 0,7566 merupakan rerata 19 citra bernilai 0,7854 dan satu citra bernilai 0,2100.

Analisis Kesalahan

Tujuh citra salah diklasifikasikan (Tabel 6). Tiga citra nekrosis (infected 1083, 1084, dan 1097) diprediksi bercak dengan Contrast 434,08–679,65 dan Metric 0,0285–0,0494, yaitu berada di dalam rentang kelas bercak pada kedua fitur. Dua citra klorosis diprediksi bercak, dan dua citra bercak masing-masing diprediksi nekrosis dan klorosis. Empat dari tujuh kesalahan memiliki tingkat keyakinan di bawah 70% (44,29–65,61%), tetapi tiga kesalahan lainnya memiliki keyakinan tinggi (77,91–96,80%). Dengan demikian, ambang keyakinan dapat dipakai untuk menandai sebagian kasus agar ditinjau manual, namun tidak cukup untuk menangkap semua kesalahan.

Tabel 7. Citra uji yang salah diklasifikasikan

No.	Berkas	Aktual	Prediksi	Keyakinan (%)	Contrast	Metric
2	PXL_20240628_210002507	Bercak	Nekrosis	65,61	339,93	0,1134
45	PXL_20240702_183318996	Bercak	Klorosis	44,29	203,03	0,0656
53	thumb (10)	Klorosis	Bercak	87,64	339,45	0,0243
57	thumb (14)	Klorosis	Bercak	45,63	176,01	0,0963
78	infected (1083)	Nekrosis	Bercak	96,80	679,65	0,0494
79	infected (1084)	Nekrosis	Bercak	77,91	434,08	0,0311
92	infected (1097)	Nekrosis	Bercak	56,94	606,70	0,0285

Implementasi dan Contoh Diagnosis

Antarmuka aplikasi web ditunjukkan pada Gambar 14. Sebagai contoh, citra bercak PXL_20240702_181521731 menghasilkan Contrast 1146,55 dan Metric 0,0537, lalu diklasifikasikan sebagai bercak dengan keyakinan 95,15%. Citra sehat thumb (8) menghasilkan Contrast 29,49 dan Metric 0,7854 dan diklasifikasikan benar sebagai sehat. Potongan kode ekstraksi fitur GLCM dan inisialisasi model ditunjukkan pada Gambar 12 dan 13. Setiap tahap (citra asli, mask segmentasi, fitur, vektor, dan probabilitas kelas) ditampilkan pada antarmuka dan dapat diunduh dalam laporan CSV, sehingga hasil dapat ditelusuri ulang sesuai fase *reporting* pada NIST SP 800-86.

```

Python
def extract_glm_features( grayscale_image ):
    glm = graycomatrix(
        grayscale_image,
        distances=[1],
        angles=[0, np.pi/4, np.pi/2, 3*np.pi/4],
        levels=256,
        symmetric=True,
        normed=True
    )

    contrast = graycoprops(glm, 'contrast').mean()
    correlation = graycoprops(glm, 'correlation').mean()
    energy = graycoprops(glm, 'energy').mean()
    homogeneity = graycoprops(glm, 'homogeneity').mean()

    return [contrast, correlation, energy, homogeneity]
    
```

Gambar 12. Kode program fungsi ekstraksi fitur tekstur GLCM


```

def build_deep_learning_model(input_dim, num_classes):
    model = Sequential()

    model.compile(
        optimizer=tf.keras.optimizers.Adam(learning_rate=0.001),
        loss='categorical_crossentropy',
        metrics=['accuracy']
    )

    return model
    
```

Gambar 13. Kode program inisialisasi dan kompilasi model deep learning



Gambar 14. Antarmuka dasbor web Streamlit untuk diagnosis citra daun bonsai

Pembahasan

Hasil menunjukkan bahwa delapan fitur sederhana yang dikombinasikan dengan jaringan saraf kecil sudah cukup untuk memisahkan kondisi daun bonsai pada data uji ini. Pemisahan sehat dan sakit terutama ditopang oleh Contrast: permukaan daun sehat yang halus menghasilkan variasi keabuan lokal yang rendah, sedangkan lesi menambah transisi intensitas yang tajam. Temuan ini sejalan dengan alasan penggunaan GLCM pada penyakit tanaman (Kabir dkk., 2024; Fi'Nawu dkk., 2026).

Kesalahan terkonsentrasi pada pasangan nekrosis dan bercak. Keduanya sama-sama membentuk area gelap dengan tepi tegas sehingga Contrast dan Metric-nya saling tumpang tindih (rerata Contrast 614,08 dan 612,14). Delapan fitur yang dipakai tidak memuat informasi warna, padahal warna merupakan pembeda utama antara jaringan mati yang mengering dan lesi berhalo klorotik. Karena itu, penambahan fitur warna pada ruang HSV atau Lab merupakan perbaikan yang paling mungkin menurunkan kesalahan nekrosis–bercak; hal ini perlu dibuktikan melalui uji ablasi.

Akurasi 93,81% lebih tinggi daripada akurasi tertinggi 88,19% pada klasifikasi empat kelas penyakit cabai dengan GLCM dan K-NN (Fi'Nawu dkk., 2026) dan akurasi 75,00% pada verifikasi tanda tangan dengan HOG dan SVM (Amrullah, 2026). Perbandingan ini hanya indikatif karena objek, data, jumlah kelas, dan protokol pengujiannya berbeda. Kabir dkk. (2024) juga menegaskan bahwa kinerja berbasis GLCM bergantung pada dataset, sehingga angka pada artikel ini berlaku untuk dataset dan kondisi akuisisi yang digunakan.

Keterbatasan

1. Artefak segmentasi pada fitur Metric
Seluruh citra sehat, kecuali satu, bernilai Metric tepat 0,7854 (Tabel 5). Nilai ini sama dengan $\pi/4$, yaitu kebulatan sebuah bujur sangkar, sehingga mengindikasikan bahwa kontur terbesar pada citra tersebut adalah bingkai citra 224×224 dan bukan bentuk daun. Dengan kata lain, Metric pada kelas sehat lebih mencerminkan perilaku thresholding global terhadap latar daripada geometri daun, dan sebagian akurasi 100% pada kelas sehat mungkin dipengaruhi artefak ini. Klorosis juga mencapai 0,7854 pada nilai maksimumnya. Segmentasi berbasis warna (HSV), GrabCut, atau U-Net perlu diuji.
2. Tekstur dari seluruh citra
GLCM dihitung dari seluruh citra keabuan sehingga latar, bayangan, dan pencahayaan ikut memengaruhi fitur tekstur. Perhitungan GLCM pada area daun hasil segmentasi perlu dibandingkan.
3. Ukuran dan skema pengujian
Evaluasi memakai satu pembagian hold-out dengan 113 citra uji (hanya 20 citra pada kelas nekrosis dan sehat), sehingga selang kepercayaan cukup lebar. Validasi silang atau pengulangan dengan beberapa pembagian acak belum dilakukan.
4. Kemungkinan kebocoran data
Pemeriksaan citra duplikat atau sangat mirip antara data latih dan uji belum didokumentasikan. Praktik seperti hashing MD5 pada Matondang dan Tanjung (2026) perlu diterapkan, dan penelitian tersebut juga mencatat penurunan keyakinan model pada citra di luar dataset akibat pergeseran domain.

5. Tidak ada uji ablasi
Kontribusi fitur tekstur, fitur bentuk, dan jaringan saraf dibandingkan klasifikator klasik belum diuji secara terpisah, sehingga manfaat kombinasi hibrida belum dapat dikuantifikasi.
6. Cakupan
Penelitian terbatas pada beringin dan serut, empat kelas, dan pencahayaan terkontrol. Hasil belum dapat digeneralisasi ke jenis bonsai lain atau citra lapangan.

KESIMPULAN

Penelitian ini membangun alur klasifikasi kondisi daun bonsai beringin dan serut yang menggabungkan empat fitur tekstur GLCM dan empat fitur bentuk kontur pada jaringan saraf berlapis, serta mengimplementasikannya sebagai aplikasi web. Pada 113 citra uji, sistem mencapai akurasi 93,81% dan macro-F1 94,00%. Kelas sehat terklasifikasi sempurna dan seluruh kesalahan terjadi antarkelas sakit, terutama nekrosis yang diprediksi sebagai bercak karena kemiripan nilai Contrast dan Metric.

Hasil ini berlaku pada dataset dan kondisi akuisisi yang digunakan. Penelitian selanjutnya disarankan untuk (1) menambah jumlah dan keragaman citra serta memeriksa duplikasi antardata, (2) memperbaiki segmentasi dan menghitung GLCM pada area daun, (3) menambahkan fitur warna dan melakukan uji ablasi serta validasi silang, dan (4) mengembangkan aplikasi seluler untuk penggunaan lapangan.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Program Studi Sistem Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara, atas dukungan selama penelitian ini.

DAFTAR PUSTAKA

- Ahmed, I. T., Hammad, B. T., & Jamil, N. (2021). Forgery detection algorithm based on texture features. *IEEE Access*, 9, 94549–94567. <https://doi.org/10.1109/ACCESS.2021.3093896>
- Amrullah. (2026). Pendekatan forensik dokumen dalam verifikasi keaslian tanda tangan menggunakan metode Histogram of Oriented Gradients (HOG) dan Support Vector Machine (SVM). *Indonesian Journal of Multidisciplinary Scientific Studies*, 4(6), 440–448. <https://doi.org/10.33151/ijomss.v4i6.1131>
- Anggiratih, E., Siswanti, S., Octaviani, S. K., & Sari, A. (2021). Klasifikasi penyakit tanaman padi menggunakan model deep learning Efficientnet B3 dengan transfer learning. *Jurnal Ilmiah SINUS*, 19(1). <https://doi.org/10.30646/sinus.v19i1.526>
- Anita, A., Rodhy, R., Ningsih, S., & Solin, D. (2019). Penerapan metode forward chaining dan certainty factor untuk diagnosa penyakit pada tanaman bonsai. *JGK (Jurnal Guru Kita)*, 3(2), 187–194. <https://doi.org/10.24114/jgk.v3i2.14587>
- Burhanuddin, R. R. (2024). Klasifikasi penyakit padi melalui citra daun menggunakan metode Naive Bayes. *Jurnal Informatika dan Teknik Elektro Terapan*, 12(2). <https://doi.org/10.23960/jitet.v12i2.4012>
- Dhiman, P., Kaur, A., Hamid, Y., Alabdulkreem, E., Elmannai, H., & Ababneh, N. (2023). Smart disease detection system for citrus fruits using deep learning with edge computing. *Sustainability*, 15(5), 4576. <https://doi.org/10.3390/su15054576>
- Fi'Nawu, R. A., Salihi, I. A., Lamasigi, Z. Y., & Idris, I. S. K. (2026). Klasifikasi penyakit tanaman cabai berdasarkan seleksi fitur GLCM dan algoritma K-Nearest Neighbor. *Jambura Journal of Electrical and Electronics Engineering*, 8(1), 40–45. <https://ejurnal.ung.ac.id/index.php/jjee/article/download/34661/12491>
- Harakannanavar, S. S., Rudagi, J. M., Puranikmath, V. I., Siddiqua, A., & Pramodhini, R. (2022). Plant leaf disease detection using computer vision and machine learning algorithms. *Global Transitions Proceedings*, 3(1), 305–310. <https://doi.org/10.1016/j.gltp.2022.03.016>
- Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6), 610–621. <https://doi.org/10.1109/TSMC.1973.4309314>
- Hassan, S. M., & Maji, A. K. (2022). Plant disease identification using a novel convolutional neural network. *IEEE Access*, 10, 5390–5401. <https://doi.org/10.1109/ACCESS.2022.3141371>
- Kabir, M., Unal, F., Akinci, T. C., Martinez-Morales, A. A., & Ekici, S. (2024). Revealing GLCM metric variations across a plant disease dataset: A comprehensive examination and future prospects for

- enhanced deep learning applications. *Electronics*, 13(12), 2299. <https://doi.org/10.3390/electronics13122299>
- Kent, K., Chevalier, S., Grance, T., & Dang, H. (2006). *Guide to integrating forensic techniques into incident response* (NIST Special Publication 800-86). National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.SP.800-86>
- Kingma, D. P., & Ba, J. (2015). Adam: A method for stochastic optimization. *Proceedings of the 3rd International Conference on Learning Representations (ICLR 2015)*. <https://doi.org/10.48550/arXiv.1412.6980>
- Kuncoro, S. T., & Syahra, Y. (2026). Deteksi tepi citra pupuk menggunakan algoritma Canny untuk analisis bentuk dan tekstur produk. *Indonesian Journal of Multidisciplinary Scientific Studies*, 4(6), 609–622. <https://doi.org/10.33151/ijomss.v4i6.1155>
- Leiva, F., Abdelghafour, F., Alsheikh, M., Nagy, N. E., Davik, J., & Chawade, A. (2024). ScabyNet, a user-friendly application for detecting common scab in potato tubers using deep learning and morphological traits. *Scientific Reports*, 14, 1277. <https://doi.org/10.1038/s41598-023-51074-4>
- Luque, A., Carrasco, A., Martín, A., & de las Heras, A. (2019). The impact of class imbalance in classification performance metrics based on the binary confusion matrix. *Pattern Recognition*, 91, 216–231. <https://doi.org/10.1016/j.patcog.2019.02.023>
- Matondang, D. F., & Tanjung, M. A. P. (2026). Deteksi dini karies dan karang gigi berbasis Android menggunakan CNN MobileNetV2 dan transfer learning. *Indonesian Journal of Multidisciplinary Scientific Studies*, 4(6), 574–582. <https://doi.org/10.33151/ijomss.v4i6.1149>
- Orchi, H., Sadik, M., Khaldoun, M., & Sabir, E. (2023). Automation of crop disease detection through conventional machine learning and deep transfer learning approaches. *Agriculture*, 13(2), 352. <https://doi.org/10.3390/agriculture13020352>
- Oryza Sativa, R. D., & Serdani, A. D. (2022). Bonsai beringin dan serut sebagai alternatif pendapatan petani milenial di masa pandemi Covid 19. *VIABEL: Jurnal Ilmiah Ilmu-Ilmu Pertanian*, 16(1), 21–28. <https://doi.org/10.35457/viabel.v16i1.1800>
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62–66. <https://doi.org/10.1109/TSMC.1979.4310076>
- Shoaib, M., Shah, B., El-Sappagh, S., Ali, A., Ullah, A., Alenezi, F., Gechev, T., Hussain, T., & Ali, F. (2023). An advanced deep learning models-based plant disease detection: A review of recent research. *Frontiers in Plant Science*, 14, 1158933. <https://doi.org/10.3389/fpls.2023.1158933>
- Simhadri, C. G., & Kondaveeti, H. K. (2023). Automatic recognition of rice leaf diseases using transfer learning. *Agronomy*, 13(4), 961. <https://doi.org/10.3390/agronomy13040961>
- Singh, A. K., Sreenivasu, S. V. N., Mahalaxmi, U. S. B. K., Sharma, H., Patil, D. D., & Asenso, E. (2022). Hybrid feature-based disease detection in plant leaf using convolutional neural network, Bayesian optimized SVM, and random forest classifier. *Journal of Food Quality*, 2022, 2845320. <https://doi.org/10.1155/2022/2845320>
- Sun, X., Li, G., Qu, P., Xie, X., Pan, X., & Zhang, W. (2022). Research on plant disease identification based on CNN. *Cognitive Robotics*, 2, 155–163. <https://doi.org/10.1016/j.cogr.2022.07.001>