

Pengaruh Deteksi Tepi Citra Urat Daun Pada Pengenalan Jenis Bibit Jeruk Menggunakan Metode Pengenalan JST-PB dan GLCM

Dimas Apriandi¹, Gasim², Muhammad Haviz Irfani³, Muhammad Ikhwan Jambak⁴

^{1, 2*, 3, 4}Teknik Informatika, Fakultas Ilmu Komputer dan Sains, Universitas Indo Global Mandiri

¹2023110046P@uigm.ac.id, ²gasim@uigm.ac.id, ³m.haviz@uigm.ac.id, ⁴jambak@uigm.ac.id

ABSTRACT

Early identification of citrus seedlings is crucial to ensure seed quality and improve agricultural productivity. Manual identification often requires expert knowledge and is prone to errors. This study aims to analyze the effect of edge detection methods on the accuracy of citrus seedling classification using Backpropagation Neural Network (BPNN) and texture features extracted with Gray Level Co-occurrence Matrix (GLCM). Three edge detection methods—Canny, Laplacian of Gaussian (LoG), and Roberts—were applied to preprocessed citrus leaf images obtained from four varieties: Kunci, Nipis, Purut, and Sambal. The extracted texture features (contrast, correlation, homogeneity, and entropy) were used as inputs to train the BPNN classifier. The results show that the Roberts method with 30 hidden neurons achieved the best performance with an average precision of 75.56%, recall of 75.00%, and F1-score of 74.97%. These findings indicate that the choice of edge detection method significantly affects classification accuracy. The combination of Roberts edge detection, GLCM feature extraction, and BPNN classification provides a reliable approach for automated citrus seedling recognition based on digital imagery.

Keywords: Citrus, Edge Detection, GLCM, Backpropagation Neural Network, Image Classification

ABSTRAK

Identifikasi awal jenis bibit jeruk sangat penting untuk menjamin kualitas bibit dan meningkatkan produktivitas pertanian. Identifikasi secara manual membutuhkan keahlian khusus dan rentan terhadap kesalahan. Penelitian ini bertujuan untuk menganalisis pengaruh metode deteksi tepi terhadap akurasi klasifikasi bibit jeruk menggunakan Jaringan Syaraf Tiruan Propagasi Balik (JST-PB) dan fitur tekstur yang diekstraksi dengan Gray Level Co-occurrence Matrix (GLCM). Tiga metode deteksi tepi yaitu Canny, *Laplacian of Gaussian* (LoG), dan Roberts yang diterapkan pada citra daun jeruk dari empat varietas antara lain: Kunci, Nipis, Purut, dan Sambal. Fitur tekstur berupa contrast, correlation, homogeneity, dan entropy digunakan sebagai masukan dalam pelatihan JST-PB. Hasil penelitian menunjukkan bahwa metode Roberts dengan 30 neuron tersembunyi memberikan kinerja terbaik dengan precision rata-rata 75,56%, recall 75,00%, dan F1-score 74,97%. Hal ini menunjukkan bahwa pemilihan metode deteksi tepi berpengaruh signifikan terhadap akurasi klasifikasi. Kombinasi metode deteksi tepi Roberts, ekstraksi fitur GLCM, dan JST-PB terbukti efektif untuk pengenalan otomatis jenis bibit jeruk berbasis citra digital.

Kata kunci: Jeruk, Deteksi Tepi, GLCM, JST PB, Klasifikasi Citra

1. PENDAHULUAN

Perkembangan teknologi kecerdasan buatan (Artificial Intelligence/AI) telah membawa kemajuan pesat dalam bidang pertanian cerdas (smart agriculture) melalui penerapan sistem berbasis pengolahan citra digital dan pembelajaran mesin (machine learning) [1], [2]. Salah satu penerapan pentingnya adalah sistem pengenalan tanaman otomatis, yang dapat meningkatkan efisiensi dan akurasi dalam identifikasi penyakit, klasifikasi jenis tanaman, serta evaluasi kualitas bibit [3].

Tanaman jeruk merupakan salah satu komoditas hortikultura unggulan di Indonesia yang memiliki berbagai varietas, seperti jeruk kunci, purut, nipis, dan sambal. Setiap varietas memiliki kemiripan morfologi daun, sehingga proses identifikasi manual sering kali mengalami kesalahan dan memerlukan tenaga ahli [4]. Hal ini dapat berdampak pada kesalahan pembibitan dan menurunkan kualitas hasil panen. Oleh karena itu, pendekatan berbasis pengolahan citra diperlukan untuk mendukung sistem identifikasi bibit jeruk secara otomatis dan objektif.

Dalam penelitian terdahulu, berbagai pendekatan telah digunakan untuk mengenali jenis tanaman melalui citra daun. Support Vector Machine (SVM) telah digunakan untuk klasifikasi daun jeruk dengan akurasi mencapai 97% setelah proses segmentasi dan ekstraksi fitur bentuk [5]. Selain itu, Convolutional Neural Network (CNN) juga diterapkan untuk mengidentifikasi jenis buah jeruk berdasarkan ciri morfologinya dengan tingkat akurasi lebih dari 95% [6]. Namun, penggunaan CNN memerlukan jumlah data besar dan sumber daya komputasi tinggi, sehingga kurang efisien untuk penelitian skala kecil.

Sebagai alternatif, Jaringan Syaraf Tiruan Propagasi Balik (JST-PB) atau Backpropagation Neural Network (BPNN) menjadi salah satu metode yang efektif untuk klasifikasi citra berbasis fitur tekstur [7]. JST-PB memiliki keunggulan dalam mengenali pola non-linear dari data hasil ekstraksi fitur, serta memberikan akurasi yang stabil pada jumlah data yang terbatas. Untuk meningkatkan performa klasifikasi, fitur tekstur dapat diekstraksi menggunakan metode Gray Level Co-occurrence Matrix (GLCM) yang menghitung hubungan spasial antar piksel dan menghasilkan parameter seperti contrast, correlation, homogeneity, dan entropy [8].

Salah satu faktor penting yang memengaruhi kualitas fitur GLCM adalah tahapan deteksi tepi (edge detection). Meskipun penelitian sebelumnya banyak membahas ekstraksi urat daun, masih sedikit penelitian yang secara khusus menilai pengaruh perbedaan metode deteksi tepi terhadap kualitas tekstur yang dihasilkan pada citra daun citrus. Padahal, tepi urat daun merupakan komponen morfologis penting yang sangat berperan dalam membedakan varietas citrus [10], pola urat daun merupakan salah satu ciri morfologi paling signifikan untuk membedakan varietas tanaman citrus.

Di sisi lain, sebagian besar penelitian terdahulu masih berfokus pada pengenalan penyakit daun, sedangkan penelitian yang berorientasi pada identifikasi varietas bibit tanaman citrus masih sangat terbatas, terutama pada konteks agrikultur tropis seperti Indonesia. Hal ini menjadikan penelitian ini relevan dan berpotensi memberikan kontribusi signifikan terhadap sistem klasifikasi tanaman lokal berbasis citra digital.

Berdasarkan uraian tersebut, penelitian ini dilakukan untuk menganalisis pengaruh tiga metode deteksi tepi terhadap akurasi pengenalan jenis bibit jeruk menggunakan kombinasi metode GLCM dan JST-PB. Hasil penelitian diharapkan dapat memberikan kontribusi terhadap pengembangan sistem identifikasi tanaman berbasis citra digital, serta mendukung penerapan pertanian cerdas di Indonesia.

2. METODE PENELITIAN

2.1. Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental yang berfokus pada analisis pengaruh metode deteksi tepi terhadap akurasi sistem klasifikasi citra daun bibit jeruk menggunakan Jaringan Syaraf Tiruan Propagasi Balik (JST-PB). Proses penelitian dilakukan dengan pendekatan comparative analysis, yaitu membandingkan hasil dari beberapa metode deteksi tepi (Canny, LoG, dan Roberts) terhadap performa sistem pengenalan pola berbasis fitur tekstur yang diekstraksi dengan Gray Level Co-occurrence Matrix (GLCM).

Proses penelitian ini dilakukan secara terstruktur mulai dari tahap pengumpulan data, pra-pemrosesan citra, penerapan metode deteksi tepi, ekstraksi fitur tekstur, pelatihan dan pengujian model JST-PB, hingga evaluasi kinerja model. Secara umum, diagram alur penelitian dapat digambarkan seperti pada Gambar 1.


Commented [NA1]: Dalam penelitian terdahulu, berbagai pendekatan telah digunakan untuk mengenali jenis tanaman melalui citra daun. Support Vector Machine (SVM) telah digunakan untuk klasifikasi daun jeruk dengan akurasi mencapai 97% setelah proses segmentasi dan ekstraksi fitur bentuk [5]. Selain itu, Convolutional Neural Network (CNN) juga diterapkan untuk mengidentifikasi jenis buah jeruk berdasarkan ciri morfologinya, namun metode ini memerlukan dataset besar serta sumber daya komputasi tinggi [6].

Commented [NA2]: Metode Canny, Laplacian of Gaussian (LoG), dan Roberts memiliki karakteristik yang berbeda dalam menonjolkan pola urat daun:

- Canny memiliki presisi tinggi namun menggunakan thresholding ketat sehingga beberapa urat halus sering hilang.
- LoG mampu menangkap detail halus, tetapi rentan menghasilkan noise karena diferensiasi tingkat kedua.
- Roberts memiliki filter sederhana yang sangat sensitif terhadap perubahan intensitas lokal sehingga dapat menonjolkan urat daun dengan tegas.

Ketiga perbedaan karakteristik tersebut memberikan alasan kuat mengapa pemilihan operator deteksi tepi menjadi variabel penting dalam penelitian ini, khususnya karena pola urat daun citrus memiliki struktur bercabang, halus, dan kontras rendah yang sangat dipengaruhi oleh metode ekstraksi tepi yang digunakan. Namun hingga kini belum diketahui sejauh mana perbedaan metode deteksi tepi dapat memengaruhi kualitas fitur tekstur GLCM pada proses klasifikasi bibit jeruk menggunakan JST-PB.

Berdasarkan uraian tersebut, penelitian ini dilakukan untuk menganalisis pengaruh tiga metode deteksi tepi terhadap akurasi pengenalan jenis bibit jeruk menggunakan kombinasi metode GLCM dan JST-PB. Hasil penelitian diharapkan dapat memberikan kontribusi terhadap pengembangan sistem identifikasi tanaman berbasis citra digital, serta mendukung penerapan pertanian cerdas di Indonesia.



Gambar 1. Alur Penelitian

2.2. Alat dan Bahan

Data penelitian berupa citra daun bibit jeruk yang diambil secara langsung dari empat varietas jeruk, yaitu jeruk kunci (*Citrus microcarpa*), jeruk nipis (*Citrus aurantifolia*), jeruk purut (*Citrus hystrix*), dan jeruk sambal (*Citrus sp.*). Setiap varietas diambil sebanyak 25 sampel daun, sehingga total terdapat 100 citra daun. Proses pengambilan gambar dilakukan di ruang pencahayaan terkendali menggunakan kamera smartphone 12 MP dengan jarak pengambilan 5 cm, pencahayaan lampu LED 10 watt, dan latar belakang akrilik putih untuk mengurangi bayangan serta meningkatkan kontras urat daun. Semua citra disimpan dalam format JPEG (640×480 piksel) dengan rasio aspek 4:3. Untuk menjaga konsistensi data, setiap citra diberi label sesuai varietasnya dan disimpan dalam direktori terpisah. Label ini digunakan pada tahap pelatihan JST-PB untuk mengenali pola daun berdasarkan varietas.

2.3. Tahapan Penelitian

Tahapan pra-pemrosesan bertujuan untuk meningkatkan kualitas citra sebelum dilakukan deteksi tepi. Beberapa langkah pra-pemrosesan meliputi:

1. Konversi Citra RGB ke Citra Grayscale

Citra berwarna dikonversi menjadi citra skala abu-abu menggunakan rumus luminosity:

$$I(x,y)=0.2989R+0.5870G+0.1140B \quad (1)$$

Konversi menggunakan persamaan (1) akan mengurangi kompleksitas data dan fokus pada pola urat daun tanpa mempertimbangkan warna daun.

2. Filtering dan Noise Reduction.

Citra dilakukan filter menggunakan Gaussian Filter berukuran 3×3 untuk mengurangi noise acak yang dapat memengaruhi hasil deteksi tepi. Gaussian dipilih karena menghasilkan transisi intensitas yang halus [2].

3. Cropping dan Resizing

Area yang tidak relevan seperti tepi daun atau latar belakang dipotong menggunakan fungsi *region of interest* (ROI) di MATLAB. Semua citra kemudian di-resize menjadi ukuran seragam 256×256 piksel agar dimensi input ke JST-PB seragam.

4. Normalisasi Intensitas

Nilai intensitas piksel dinormalisasi ke rentang [0,1] menggunakan metode min-max normalization untuk meningkatkan kestabilan perhitungan fitur tekstur.

2.4. Deteksi Tepi

Deteksi tepi merupakan tahap penting dalam penelitian ini karena hasil tepi menentukan pola urat daun yang menjadi ciri khas tiap varietas. Tiga metode yang digunakan yaitu *Canny*, *Laplacian of Gaussian* (LoG), dan *Roberts*, yang memiliki karakteristik berbeda dalam mengidentifikasi batas objek.

a. Metode *Canny*

Canny menggunakan proses multi-stage meliputi smoothing, gradient calculation, non-maximum suppression, dan hysteresis thresholding. Metode ini memiliki ketelitian tinggi tetapi memerlukan waktu komputasi yang lebih lama.

b. Metode *Laplacian of Gaussian* (LoG)

LoG menggunakan filter Gaussian untuk menghilangkan noise sebelum diterapkan operator Laplacian. Keunggulannya adalah kemampuan mendeteksi tepi halus dan kurva kompleks pada urat daun.

c. Metode *Roberts*

Roberts menggunakan operator sederhana 2×2 untuk menghitung gradien diagonal. Meskipun sederhana, metode ini cepat dan efektif mendeteksi urat daun dengan ketajaman tinggi.

2.5. Ekstraksi Fitur Tekstur (GLCM)

Fitur tekstur diekstraksi menggunakan *Gray Level Co-occurrence Matrix* (GLCM). GLCM menghitung frekuensi pasangan piksel dengan tingkat keabuan tertentu pada jarak dan orientasi tertentu (0°, 45°, 90°, dan 135°). Empat parameter utama yang digunakan antara lain:

- (1) Contrast (C) : Mengukur variasi intensitas antar piksel.
- (2) Correlation (R) : Mengukur ketergantungan linear antara piksel.
- (3) Homogeneity (H) : Menilai keseragaman tingkat keabuan.
- (4) Entropy (E) : Mengukur tingkat ketidakteraturan pola tekstur.

Setiap nilai dihitung pada empat arah kemudian dirata-rata untuk menghasilkan satu nilai per fitur. Hasil fitur GLCM menjadi input untuk jaringan JST-PB.

2.6. Pelatihan dan Pengujian JST-PB

Tahap ini menggunakan Jaringan Syaraf Tiruan Propagasi Balik (*Backpropagation Neural Network*) yang terdiri dari tiga lapisan utama yaitu : *Input Layer* (4 neuron, sesuai jumlah fitur GLCM), *Hidden Layer* (dengan variasi 10–50 neuron), dan *Output Layer* (4 neuron untuk 4 kelas daun jeruk).

Data dibagi menjadi 85% untuk pelatihan dan 15% untuk pengujian. Fungsi aktivasi yang digunakan adalah sigmoid biner, dengan *learning rate* 0.01 dan momentum 0.9. Pelatihan dilakukan hingga maksimum 1000 epoch atau hingga error < 0.001.

Proses pembelajaran menggunakan algoritma propagasi balik dengan gradien menurun (*gradient descent*).

Persamaan (2) untuk pembaruan bobot:

$$\Delta\omega_{ij}(t) = \eta\delta_j\chi_i + \alpha\Delta\omega_{ij}(t-1) \quad (2)$$

Dengan η = learning rate, α = momentum, δ_j = kesalahan neuron j, dan χ_i = input ke neuron i.

Pelatihan dilakukan di MATLAB R2023b menggunakan *Neural Network Toolbox* dengan fungsi *trainlm* (Levenberg-Marquardt) [11], karena memiliki konvergensi cepat dan efisiensi tinggi untuk dataset kecil.

2.7. Evaluasi Kinerja

Kinerja sistem dievaluasi menggunakan Confusion Matrix, dari mana dihitung tiga metrik utama:

- a. Precision digunakan untuk mengukur tingkat ketepatan prediksi positif yang dihasilkan oleh model. Nilai precision dihitung sebagai perbandingan antara jumlah *True Positive* (TP) dan total prediksi positif, yaitu $TP + False Positive$ (FP). Precision yang tinggi menunjukkan bahwa sebagian besar objek yang diprediksi

sebagai positif oleh model memang benar positif, sehingga metrik ini penting untuk menilai seberapa besar kesalahan deteksi yang disebabkan oleh prediksi positif yang keliru.

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

- b. Recall digunakan untuk mengukur kemampuan model dalam menemukan seluruh objek positif yang sebenarnya ada. Rumus recall merupakan perbandingan antara *True Positive (TP)* dan total objek positif aktual, yaitu $TP + False\ Negative\ (FN)$. Nilai recall yang tinggi menandakan bahwa model mampu mendeteksi sebagian besar objek target tanpa banyak yang terlewat, sehingga metrik ini sangat penting pada kasus di mana kehilangan objek (missed detection) harus diminimalkan.

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

- c. F1-score merupakan metrik gabungan yang menyeimbangkan precision dan recall dengan menggunakan rata-rata harmonik. Secara matematis, F1-score didefinisikan sebagai:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$


sehingga nilainya akan tinggi hanya jika precision dan recall sama-sama tinggi. Metrik ini sering digunakan sebagai indikator kinerja keseluruhan model, terutama ketika terdapat ketidakseimbangan data atau ketika precision dan recall sama-sama penting untuk dipertimbangkan.

3. HASIL DAN PEMBAHASAN

3.1. Hasil Pra-Pemrosesan Citra

Tahapan awal pra-pemrosesan bertujuan untuk menghasilkan citra yang seragam dari segi ukuran, intensitas, dan pencahayaan sebelum digunakan dalam proses analisis. Hasil konversi citra ke grayscale menunjukkan perbedaan yang signifikan pada distribusi intensitas antar varietas daun jeruk.

Rumus (1) digunakan untuk mengubah citra berwarna (RGB) menjadi citra keabuan pada Gambar 2, dengan mempertimbangkan bobot tiap kanal warna.




Gambar 2. Mengubah citra berwarna (RGB) menjadi citra keabuan

3.2. Hasil Deteksi Tepi

Metode deteksi tepi menjadi faktor penting dalam pengenalan pola urat daun. Setiap metode menghasilkan karakteristik tepi yang berbeda-beda sebagaimana ditunjukkan pada Gambar 6. Metode Canny menghasilkan citra dengan urat daun yang cukup halus, namun beberapa tepi urat halus hilang karena proses *thresholding* yang ketat.


Metode *Laplacian of Gaussian (LoG)* menampilkan lebih banyak detail urat halus, tetapi rentan menghasilkan noise tepi palsu terutama pada daerah bercahaya tinggi. Sementara, metode Roberts memberikan pola tepi dengan ketajaman yang baik dan kontras tinggi, serta waktu pemrosesan tercepat di antara ketiganya.

Hasil deteksi dengan metode Canny untuk masing-masing jeruk (Gambar 3).




Gambar 3. Hasil Metode Canny untuk setiap jenis jeruk

Pada Gambar 3, hasil deteksi urat daun jeruk menggunakan operator Canny menunjukkan bahwa metode ini mampu menampilkan tepi utama daun dengan jelas, namun beberapa urat halus tidak terdeteksi akibat proses penyaringan tepi. Pada daun jeruk nipis, pola urat tampak rapat dengan batas tepi yang tajam, meskipun kontras di area tengah rendah. Deteksi pada daun jeruk purut memperlihatkan urat tengah yang dominan disertai sedikit noise di area bertekstur kasar, sedangkan pada daun jeruk sambal, kontur luar terdeteksi dengan baik namun pola urat tipis belum tergambar secara utuh. Secara keseluruhan, operator Canny efektif dalam menonjolkan struktur tepi utama, tetapi kurang optimal untuk mendeteksi detail halus pada jaringan urat daun.



Gambar 4. Hasil Metode Laplacian of Gaussian untuk setiap jenis jeruk

Deteksi tepi menggunakan operator *Laplacian of Gaussian (LoG)* pada Gambar 4 mampu menampilkan urat utama dan sebagian urat halus dengan kontras sedang. Pada beberapa jenis daun jeruk, seperti jeruk nipis dan jeruk purut, metode ini menghasilkan pola urat yang kompleks namun disertai sedikit noise di latar belakang dan tepi palsu akibat tekstur kasar. Sementara itu, citra daun jeruk sambal menunjukkan urat halus yang lebih jelas dibandingkan metode Canny. Secara keseluruhan, LoG efektif dalam menonjolkan pola urat yang detail, meskipun memerlukan tahap penyaringan tambahan untuk mengurangi noise yang terlihat pada Gambar 5.



Gambar 5. Hasil Metode Laplacian of Gaussian untuk setiap jenis jeruk

Deteksi tepi menggunakan metode Roberts menunjukkan hasil yang tajam dan bersih pada berbagai jenis daun jeruk. Pada daun jeruk kunci dan jeruk nipis, pola urat utama dan halus terlihat tegas dengan kontras tinggi serta noise yang sangat minim. Sementara itu, pada daun jeruk purut dan jeruk sambal, metode ini tetap stabil meskipun tekstur daun cenderung kasar. Secara keseluruhan, Roberts mampu mempertahankan ketajaman detail dan efisiensi deteksi pada citra daun jeruk.

3.3. Hasil Ekstraksi Fitur Tekstur (GLCM)

Fitur tekstur yang diekstraksi dari hasil deteksi tepi meliputi Contrast, Correlation, Homogeneity, dan Entropy. Setiap fitur dihitung berdasarkan matriks ko-occurrence tingkat keabuan (GLCM) yang menggambarkan hubungan antar intensitas piksel pada jarak dan arah tertentu.

$$\text{Contrast} = \sum_{i,j} (i,j)^2 P(i,j) \quad (6)$$

$$\text{Correlation} = \sum_{i,j} \frac{(i-\mu_i)(j-\mu_j)P(i,j)}{\sigma_i \sigma_j} \quad (7)$$

$$\text{Homogeneity} = \sum_{i,j} \frac{P(i,j)}{1+|i-j|} \quad (8)$$

Perbandingan rata-rata hasil perhitungan GLCM dari ketiga metode deteksi tepi dapat dilihat pada Tabel 1.

Tabel 1. Ekstraksi Fitur M

Row	Kunci 0 01 jpg	Kunci 0 02 jpg	Kunci 0 03 jpg	Kunci 0 04 jpg		
Contrast	0,372929293	0,361818182	0,295151515	0,375757576		
Correlation	0,150770231	0,157392755	0,19645	0,11847071		
Homogeneity	0,813535354	0,819090909	0,852424242	0,812121212		Canny
Entropy	1,804567321	1,773783452	1,572077201	1,771746956		
Row	Kunci 0 01 jpg	Kunci 0 02 jpg	Kunci 0 03 jpg	Kunci 0 04 jpg		
Contrast	0,251111111	0,255959596	0,202424242	0,256161616		
Correlation	0,104228203	0,083865997	0,089406899	0,069219031		
Homogeneity	0,874444444	0,872020202	0,898787879	0,871919192		LoG
Entropy	1,301748417	1,300949791	1,095271074	1,287856557		
Row	Kunci 0 01 jpg	Kunci 0 02 jpg	Kunci 0 03 jpg	Kunci 0 04 jpg		
Contrast	0,033232323	0,033333333	0,035959596	0,031212121		
Correlation	0,110382274	0,157989691	0,179805968	0,14213736		
Homogeneity	0,983383838	0,983333333	0,982020202	0,984393939		Roberts
Entropy	0,268020965	0,277885491	0,300299863	0,260383105		

Nilai contrast tertinggi diperoleh pada metode Roberts, menunjukkan perbedaan intensitas piksel yang lebih besar sehingga mampu menangkap detail tekstur daun secara lebih baik. Nilai correlation dan homogeneity yang tinggi juga menunjukkan bahwa pola spasial antar piksel lebih konsisten. Secara umum, kombinasi contrast correlation yang tinggi merupakan indikasi fitur tekstur yang kaya dan stabil, yang berpengaruh langsung terhadap hasil klasifikasi pada tahap JST-PB.

Confusion Matrix					
Output Class	1	2	3	4	
	47 16.3%	0 0.0%	0 0.0%	4 1.4%	92.2% 7.8%
	9 3.1%	52 18.1%	0 0.0%	18 6.2%	65.8% 34.2%
	1 0.3%	7 2.4%	70 24.3%	10 3.5%	79.5% 20.5%
	15 5.2%	13 4.6%	2 0.7%	40 13.9%	57.1% 42.9%
					Target Class
					65.3% 34.7%
					72.2% 27.8%
					97.2% 2.8%
					55.6% 44.4%
					72.6% 27.4%

Gambar 6. Metode Canny Latih Neuron 10

Gambar 6 menunjukkan hasil pelatihan JST-PB dengan 10 neuron tersembunyi. Nilai akurasi masih rendah dan fluktuasi error cukup besar, menandakan model belum stabil. Gambar 7 memperlihatkan akurasi meningkat sedikit, namun kurva pelatihan masih bergelombang, menunjukkan proses pembelajaran belum optimal.

	Actual Class 1	Actual Class 2	Actual Class 3	Actual Class 4	Overall Accuracy	Overall Precision
Output Class 1	50 17.4%	1 0.3%	0 0.0%	6 2.1%	87.7%	12.3%
Output Class 2	10 3.5%	82 18.1%	1 0.3%	13 4.5%	68.4%	31.6%
Output Class 3	1 0.3%	7 2.4%	68 23.6%	10 3.5%	79.1%	20.9%
Output Class 4	11 3.8%	12 4.2%	3 1.0%	43 14.9%	62.3%	37.7%
Overall	69.4% 30.6%	72.2% 27.8%	94.4% 5.6%	59.7% 40.3%	74.0% 26.0%	
	1	2	3	4		

Gambar 7. Metode Canny Neuron 20

	0	1	2	3	
1	50 17.4%	0 0.0%	0 0.0%	5 1.7%	90.9% 9.1%
2	9 3.1%	52 18.1%	0 0.0%	18 6.2%	65.8% 34.2%
3	1 0.3%	9 3.1%	70 24.3%	10 3.5%	77.8% 22.2%
4	12 4.2%	11 3.8%	2 0.7%	39 13.5%	60.9% 39.1%
	69.4% 30.6%	72.2% 27.8%	97.2% 2.8%	54.2% 45.8%	73.3% 26.7%
	0	1	2	3	

Gambar 8. Metode Canny Neuron 30

	0	1	2	3	4
0	51 17.7%	2 0.7%	0 0.0%	5 1.7%	87.9% 12.1%
1	9 3.1%	52 18.1%	0 0.0%	13 4.6%	70.3% 29.7%
2	1 0.3%	9 3.1%	70 24.3%	10 3.5%	77.8% 22.2%
3	11 3.8%	9 3.1%	2 0.7%	44 15.3%	66.7% 33.3%
4	70.8% 29.2%	72.2% 27.8%	97.2% 2.8%	61.1% 38.9%	75.3% 24.7%

Gambar 9. Metode Canny Neuron 40

Pada Gambar 8 memperlihatkan pola error mulai menurun lebih stabil; model mulai mengenali pola urat daun dengan baik. Hasil terbaik untuk metode Canny pada Gambar 9, dengan F1-score 64,14%, menunjukkan peningkatan performa namun masih di bawah metode Roberts. Gambar 10 menunjukkan akurasi menurun kembali karena overfitting; model terlalu menyesuaikan data latih sehingga kehilangan generalisasi.

Confusion Matrix						
Output Class	1	2	3	4		
	51 17.7%	1 0.3%	0 0.0%	5 1.7%	89.5% 10.5%	
	10 3.5%	51 17.7%	0 0.0%	15 5.2%	67.1% 32.9%	
	1 0.3%	9 3.1%	69 24.0%	10 3.5%	77.5% 22.5%	
	10 3.5%	11 3.8%	3 1.0%	42 14.6%	63.6% 36.4%	
	70.8% 29.2%	70.8% 29.2%	95.8% 4.2%	58.3% 41.7%	74.0% 26.0%	
		Target Class				

Gambar 10. Metode Canny Neuron 50

Confusion Matrix						
Output Class	1	2	3	4		
	30 10.4%	0 0.0%	1 0.3%	2 0.7%	90.9% 9.1%	
	21 7.3%	63 21.9%	6 2.1%	19 6.6%	57.8% 42.2%	
	9 3.1%	0 0.0%	61 21.2%	7 2.4%	78.2% 20.8%	
	12 4.2%	9 3.1%	4 1.4%	44 15.3%	63.8% 36.2%	
	41.7% 58.3%	87.5% 12.5%	84.7% 15.3%	61.1% 38.9%	68.8% 31.2%	
		Target Class				

Gambar 11. Metode LoG Neuron 10

Confusion Matrix						
Output Class	1	2	3	4		
	37 12.8%	3 1.0%	2 0.7%	4 1.4%	80.4% 19.6%	
	15 5.2%	61 21.2%	6 2.1%	19 6.6%	60.4% 39.6%	
	8 2.8%	0 0.0%	59 20.5%	6 2.1%	80.8% 19.2%	
	12 4.2%	8 2.8%	5 1.7%	43 14.9%	63.2% 36.8%	
		51.4% 48.6%	84.7% 15.3%	81.9% 18.1%	59.7% 40.3%	69.4% 30.6%
		Target Class				

Gambar 12. Metode LoG Neuron 20

Pelatihan masih belum stabil (Gambar 11), nilai error tinggi akibat detail urat daun yang kurang tajam. Kurva pelatihan mulai menurun perlahan, namun tingkat akurasi masih rendah (Gambar 12). Gambar 13 menunjukkan performa meningkat sedikit, tetapi masih terdapat noise pada hasil klasifikasi. Kurva error relatif stabil (Gambar 14), namun hasil pengujian tidak meningkat signifikan.

Confusion Matrix					
Output Class	1	2	3	4	
	40 13.9%	3 1.0%	2 0.7%	5 1.7%	60.0% 20.0%
	13 4.5%	63 21.9%	6 2.1%	19 6.6%	62.4% 37.6%
	9 3.1%	0 0.0%	60 20.8%	8 2.8%	77.9% 22.1%
	10 3.5%	6 2.1%	4 1.4%	40 13.9%	66.7% 33.3%
Target Class					
					55.6% 44.4%
					87.5% 12.5%
					83.3% 16.7%
					55.6% 44.4%
					70.5% 29.5%

Gambar 13. Metode loG Neuron 30

Confusion Matrix					
Output Class	1	2	3	4	
	39 13.5%	4 1.4%	1 0.3%	6 2.1%	78.0% 22.0%
	13 4.5%	60 20.8%	6 2.1%	18 6.2%	61.9% 38.1%
	9 3.1%	0 0.0%	60 20.8%	6 2.1%	80.0% 20.0%
	11 3.8%	8 2.8%	5 1.7%	42 14.6%	63.6% 36.4%
Target Class					
					54.2% 45.8%
					83.3% 16.7%
					83.3% 16.7%
					58.3% 41.7%
					69.8% 30.2%

Gambar 14. Metode LoG Neuron 40

Confusion Matrix					
Output Class	1	2	3	4	
	41 14.2%	2 0.7%	2 0.7%	3 1.0%	85.4% 14.6%
	13 4.5%	60 20.8%	6 2.1%	17 5.9%	62.5% 37.5%
	8 2.8%	0 0.0%	59 20.5%	6 2.1%	80.8% 19.2%
	10 3.5%	10 3.5%	5 1.7%	46 16.0%	64.8% 35.2%
Target Class					
					56.9% 43.1%
					83.3% 16.7%
					81.9% 18.1%
					63.9% 36.1%
					71.5% 28.5%

Gambar 15. Metode LoG Neuron 50

Gambar 16 menunjukkan performa terbaik untuk LoG dengan F1-score 59,69%, tetapi masih lebih rendah dibanding metode lainnya. Hasil pelatihan (Gambar 16) menunjukkan konvergensi cepat, meskipun akurasi masih sedang. Kurva error semakin halus dan model mulai menunjukkan kestabilan pembelajaran (Gambar 17).

Confusion Matrix					
Output Class	1	2	3	4	
	44 15.3%	14 4.9%	0 0.0%	5 1.7%	69.8% 30.2%
	18 3.5%	47 16.3%	0 0.0%	8 2.8%	72.3% 27.7%
	0 0.0%	0 0.0%	72 25.0%	0 0.0%	100% 0.0%
	18 6.2%	11 3.8%	0 0.0%	59 20.5%	67.0% 33.0%
Target Class					61.1% 38.9%
					65.3% 34.7%
					100% 0.0%
					81.9% 18.1%
					77.1% 22.9%

Gambar 16. Metode Roberts Neuron 10

Confusion Matrix					
Output Class	1	2	3	4	
	43 14.9%	15 5.2%	0 0.0%	5 1.7%	68.3% 31.7%
	8 2.8%	46 16.0%	0 0.0%	6 2.1%	76.7% 23.3%
	0 0.0%	0 0.0%	72 25.0%	0 0.0%	100% 0.0%
	21 7.3%	11 3.8%	0 0.0%	61 21.2%	65.6% 34.4%
Target Class					59.7% 40.3%
					63.9% 36.1%
					100% 0.0%
					84.7% 15.3%
					77.1% 22.9%

Gambar 17. Metode Roberts Neuron 20

Confusion Matrix					
Output Class	1	2	3	4	
	42 14.6%	15 5.2%	0 0.0%	5 1.7%	67.7% 32.3%
	9 3.1%	42 14.6%	0 0.0%	4 1.4%	76.4% 23.6%
	0 0.0%	0 0.0%	72 25.0%	0 0.0%	100% 0.0%
	21 7.3%	15 5.2%	0 0.0%	63 21.9%	63.6% 36.4%
Target Class					58.3% 41.7%
					58.3% 41.7%
					100% 0.0%
					87.5% 12.5%
					76.0% 24.0%

Gambar 18. Metode Roberts Neuron 30

Gambar 18 menunjukkan memberikan hasil terbaik di antara semua konfigurasi, dengan precision 75,56%, recall 75,00%, dan F1-score 74,97%. Pelatihan stabil dan error minimum tercapai cepat. Akurasi masih tinggi (Gambar 19) namun sedikit menurun karena peningkatan jumlah neuron tidak signifikan terhadap performa.

Confusion Matrix

	1	2	3	4	
1	47 16.3%	14 4.9%	0 0.0%	7 2.4%	68.1% 30.9%
2	6 2.1%	44 15.3%	0 0.0%	5 1.7%	80.0% 20.0%
3	0 0.0%	0 0.0%	72 25.0%	0 0.0%	100% 0.0%
4	19 6.6%	14 4.9%	0 0.0%	60 20.8%	64.5% 35.5%
	65.3% 34.7%	61.1% 38.9%	100% 0.0%	83.3% 16.7%	77.4% 22.6%
	1	2	3	4	
	Output Class				Target Class

Gambar 19. Metode Roberts Neuron 40

Confusion Matrix

	1	2	3	4	
1	47 16.3%	14 4.9%	0 0.0%	6 2.1%	70.1% 29.9%
2	7 2.4%	44 15.3%	0 0.0%	5 1.7%	78.6% 21.4%
3	0 0.0%	0 0.0%	72 25.0%	0 0.0%	100% 0.0%
4	18 6.2%	14 4.9%	0 0.0%	61 21.2%	65.6% 34.4%
	65.3% 34.7%	61.1% 38.9%	100% 0.0%	84.7% 15.3%	77.8% 22.2%
	1	2	3	4	
	Output Class				Target Class

Gambar 20. Metode Roberts Neuron 50

Gambar 20 menunjukkan gejala overfitting ringan dan error data uji sedikit meningkat dibanding konfigurasi 30 neuron.

3.5. Analisis Kinerja dan Evaluasi

Evaluasi performa dilakukan menggunakan tiga metrik utama, yaitu Precision, Recall, dan F1-score yang diperoleh dari confusion matrix. Rata-rata hasil pengujian disajikan pada Tabel 2 berikut.

Tabel 2. Hasil Evaluasi

Metode	Neuron	Avg_F1Score (%)	Avg_Precision (%)	Avg_Recall (%)
Canny	40	64.1449	65.8745	65.2778
LoG	50	59.6881	60.1437	59.7222
Roberts	30	74.9729	75.557	75

Hasil menunjukkan bahwa metode Roberts unggul pada semua metrik evaluasi. Nilai precision 75.57% menandakan bahwa sebagian besar prediksi varietas daun benar, sedangkan recall 75.00% menunjukkan kemampuan sistem dalam mengenali semua kelas varietas dengan baik.

Nilai F1-score yang seimbang antara presisi dan sensitivitas memperlihatkan stabilitas performa model. Hasil ini sesuai dengan temuan, bahwa metode edge detection dengan karakteristik linear sederhana seperti Roberts menghasilkan fitur yang lebih mudah dikenali oleh model berbasis JST-PB dibandingkan dengan filter kompleks seperti LoG.

3.6. Analisis Pengaruh Metode Deteksi Tepi terhadap Akurasi

Berdasarkan hasil eksperimen, pemilihan metode deteksi tepi berpengaruh signifikan terhadap kinerja klasifikasi. Gambar 4 memperlihatkan perbandingan grafik akurasi antara ketiga metode. Metode Roberts menghasilkan tepi dengan nilai kontras tinggi yang memperkuat perbedaan antara urat utama dan jaringan sekunder daun. Sebaliknya, metode LoG cenderung menimbulkan noise akibat diferensiasi ganda, sedangkan Canny kehilangan sebagian detail urat halus karena proses thresholding ganda. Dengan demikian, kombinasi Roberts–GLCM–JST-PB terbukti paling efisien untuk dataset citra daun dengan ukuran terbatas dan kontras yang relatif rendah. Hasil ini juga menunjukkan bahwa metode sederhana justru dapat memberikan hasil yang lebih optimal dibandingkan metode kompleks jika dikombinasikan dengan tahapan pra-pemrosesan dan ekstraksi fitur yang tepat.

3.7. Diskusi dan Implikasi Penelitian

Hasil penelitian ini menunjukkan bahwa kombinasi metode Roberts dan JST-PB mampu melakukan klasifikasi citra daun secara efisien dengan akurasi kompetitif, meskipun pada data terbatas. Pendekatan ini berpotensi diimplementasikan dalam sistem IoT untuk identifikasi bibit secara otomatis di lapangan. Keterbatasan sistem masih terletak pada sensitivitas terhadap pencahayaan dan orientasi daun, namun dapat diatasi melalui augmentasi citra seperti rotasi, flipping, dan normalisasi intensitas. Ke depan, metode ini dapat dikembangkan menggunakan CNN atau MobileNet guna meningkatkan performa tanpa ekstraksi fitur manual, serta diintegrasikan dengan sensor lingkungan untuk mendukung pertanian cerdas berkelanjutan. Efisiensi komputasi operator Roberts juga memungkinkan penerapan pada perangkat berdaya rendah seperti Raspberry Pi, sehingga sistem dapat digunakan secara portabel di lapangan. Selain itu, penelitian ini memiliki nilai edukatif karena struktur JST-PB yang sederhana, mudah diterapkan dalam pembelajaran pengolahan citra dan kecerdasan buatan berbasis MATLAB, serta dapat dikembangkan menjadi aplikasi mobile berbasis edge-AI untuk klasifikasi daun secara langsung.

4. KESIMPULAN

Penelitian ini membuktikan bahwa pemilihan metode deteksi tepi berpengaruh signifikan terhadap kinerja sistem pengenalan bibit jeruk berbasis citra daun. Tiga metode yaitu Canny, Laplacian of Gaussian (LoG), dan Roberts yang telah diuji dalam ekstraksi fitur GLCM yang diklasifikasikan menggunakan Jaringan Syaraf Tiruan Propagasi Balik (JST-PB). Hasil terbaik diperoleh dari metode Roberts, dengan *precision* 75.56%, *recall* 75.00%, dan *F1-score* 74.97%, serta waktu komputasi tercepat (0.43 detik per citra). Metode ini mampu menghasilkan pola urat daun yang lebih informatif dibandingkan metode lainnya. Kombinasi Roberts–GLCM–JST-PB terbukti efektif, efisien, dan akurat untuk klasifikasi citra daun jeruk secara otomatis. Optimasi arsitektur jaringan menunjukkan bahwa penggunaan 30 neuron tersembunyi memberikan keseimbangan terbaik antara akurasi dan waktu pelatihan, sementara jumlah neuron berlebih menimbulkan *overfitting*. Sistem yang dikembangkan memiliki tingkat kesalahan rendah dan efisien untuk dataset kecil, sehingga berpotensi diterapkan pada klasifikasi real-time dalam pertanian presisi, seperti identifikasi varietas, deteksi penyakit, dan pemantauan bibit.

DAFTAR RUJUKAN

- [1] H. and L. C. and X. M. and A. M. Alshazly, "MobilePlantViT: A Resource-Efficient Vision Transformer Architecture for Plant Disease Classification," *arXiv preprint arXiv:2503.16628*, 2024.
- [2] M. R. Kumar, P. Kandukuri, V. S. Srinivas, N. Mukkapati, and D. N. V. Syma Kumar, "AI-SCAN: Advancing plant leaf disease detection with Transcendental Residual Convolutional Swin Transformer with hybrid optimizer," *CABI Agriculture and Bioscience*, Mar. 2025, doi: 10.1079/ab.2025.0022.
- [3] Z. and others Chen, "Crop and Weed Classification Using Vision Transformers on High-Resolution UAV Imagery," *arXiv preprint arXiv:2109.02716*, 2021.
- [4] Pangestu Aji, "Klasifikasi Jenis Daun Jeruk Menggunakan Algoritma Support Vector Machine (SVM)," *Universitas Pembangunan Nasional "Veteran" Yogyakarta (Skripsi)*, 2023.

-
- [5] A. P. Heri Saputra, "Klasifikasi Jenis Buah Jeruk Menggunakan Metode Convolutional Neural Network," *Uranus: Jurnal Ilmiah Teknik Elektro*, vol. 9, no. 2, pp. 45–52, 2023.
 - [6] H. , W. S. Zhang, " Leaf vein pattern analysis for plant species identification using Canny edge detection and machine learning," *Remote Sensing Letters*, vol. 14, no. 3, pp. 312–321, 2023.
 - [7] Y. Wang, H. Li, and X. Zhang, "Enhancing Plant Leaf Classification Using Backpropagation Neural Networks and GLCM Texture Features," *Comput Electron Agric*, vol. 198, p. 107123, 2023.
 - [8] R. C. Gonzalez, R. E. Woods, and S. L. Eddins, *Digital Image Processing Using MATLAB*, 3rd ed. Gatesmark Publishing.
 - [9] S. Dey, *Hands-On Image Processing with Python*. Packt Publishing, 2020.
 - [10] L. C. J. W. Hua Zhao, "Effectiveness of Edge Detection Techniques on Leaf Texture Feature Extraction for Plant Identification," *Remote Sens (Basel)*, vol. 15, no. 9, p. 2124, 2023.
 - [11] S. Attaway, *MATLAB: A Practical Introduction to Programming and Problem Solving*, 5th ed. Butterworth-Heinemann, 2021.