

INTEGRASI FITUR WARNA, TEKSTUR DAN RENYI FRAKTAL UNTUK KLASIFIKASI PENYAKIT DAUN KENTANG MENGGUNAKAN LINEAR DISCRIMINANT ANALYSIS

Mutmainnah Muchtar¹, Rafiqah Arjaliyah Muchtar²

¹ Program Studi Ilmu Komputer, Universitas Sembilanbelas November Kolaka

² Program Studi Pendidikan Biologi, Universitas Halu Oleo Kendari
muchtarmutmainnah@gmail.com

ABSTRAK

Penyakit pada daun tanaman kentang dapat secara signifikan mengurangi hasil panen dan kualitas produksi, sehingga diperlukan pendekatan otomatis berbasis pengolahan citra digital dalam mengidentifikasi penyakit secara tepat dan efektif. Penelitian ini bertujuan untuk meningkatkan efektivitas identifikasi penyakit pada daun kentang melalui pendekatan klasifikasi citra. Metode yang diajukan menggabungkan fitur-fitur momen warna, fitur tekstur menggunakan *Gray-Level Co-occurrence Matrix* (GLCM), dan dimensi fraktal Renyi. *Linear Discriminant Analysis* (LDA) digunakan sebagai metode klasifikasi utama. Terdapat 456 citra daun kentang dengan tiga kelas yaitu kelas sehat, *early blight*, dan *late blight* yang digunakan dalam penelitian ini. Fitur momen warna yang diekstraksi adalah fitur *mean*, *variance*, *skewness*, dan *kurtosis*. Sedangkan fitur GLCM yang digunakan adalah *contrast*, *correlation*, *energy*, dan *homogeneity*. Hasil eksperimen menunjukkan bahwa LDA memberikan akurasi tertinggi sebesar 98.46%, mengungguli metode klasifikasi lainnya seperti SVM, KNN, dan Random Forest. Integrasi fitur momen warna, tekstur, dan dimensi fraktal Renyi memberikan kontribusi penting dalam pengembangan teknik klasifikasi penyakit daun kentang dan berpotensi untuk menjadi landasan untuk meningkatkan upaya identifikasi penyakit pada tanaman secara keseluruhan.

Keyword : *Fraktal Renyi, GLCM, Klasifikasi, LDA, Momen Warna*

1. PENDAHULUAN

Tanaman kentang (*Solanum tuberosum*) adalah komoditas pertanian krusial yang memainkan peran vital dalam pemenuhan kebutuhan pangan di seluruh dunia, termasuk di Indonesia[1]. Namun, produktivitas tanaman ini sering kali terancam oleh serangan penyakit, khususnya *early blight* dan *late blight*, yang dapat menyebabkan penurunan signifikan dalam hasil panen dan kualitas[2]. Daun kentang yang terinfeksi *early blight* ditandai dengan bercak coklat tua hingga hitam dengan tepi jelas, seringkali bervariasi ukurannya dan muncul di berbagai bagian daun. Daun mengalami pengeringan dan kehilangan kehijauan secara bertahap. Sebaliknya, *late blight* menunjukkan bercak hijau tua hingga hitam dengan tepi kabur, memberikan kesan basah. Penting untuk memperhatikan perbedaan ciri-ciri fisik ini karena pengenalan dini penyakit pada daun kentang memungkinkan tindakan pencegahan yang lebih efektif. Oleh karena itu, diperlukan sistem deteksi yang efektif guna mengidentifikasi dan mengklasifikasikan penyakit pada daun kentang[3].

Seiring dengan kemajuan teknologi pengolahan citra digital, penelitian-penelitian sebelumnya telah mempertimbangkan penggunaan fitur-fitur seperti warna, tekstur, dan dimensi fraktal sebagai indikator pada klasifikasi daun tanaman. Melihat potensi masing-masing fitur, penelitian ini bertujuan untuk mengintegrasikan fitur-fitur tersebut dalam suatu sistem klasifikasi penyakit daun kentang. Penelitian ini bertujuan untuk

meningkatkan akurasi klasifikasi penyakit daun kentang dengan mengintegrasikan berbagai fitur ekstraksi dari citra daun. Tiga kelas utama yang menjadi fokus adalah daun sehat, daun yang terkena *early blight*, dan daun yang terkena *late blight*. Metode klasifikasi yang digunakan dalam penelitian ini adalah *Linear Discriminant Analysis* (LDA) [4], yang dikenal efektif dalam menangani masalah klasifikasi multi-kelas dan diharapkan dapat meningkatkan akurasi identifikasi penyakit pada daun.

Tiga set fitur yang berbeda yang akan digabungkan dalam penelitian ini adalah: Momen Warna, Fitur Tekstur *Gray-Level Co-occurrence Matrix* (GLCM), dan Fitur Fraktal Renyi. Fitur Momen Warna, yang melibatkan *mean*, *variance*, *skewness*, dan *kurtosis*, memberikan informasi tentang properti statistik distribusi warna dalam citra daun. Kedua, fitur tekstur GLCM, termasuk *contrast*, *correlation*, *energy*, dan *homogeneity*, menangkap nuansa tekstur yang penting untuk diskriminasi penyakit. Ketiga, fitur dimensi fraktal Renyi bertujuan untuk mengukur pola fraktal yang rumit dalam citra daun, meningkatkan kemampuan untuk membedakan berbagai kondisi penyakit yang muncul pada daun kentang.

Dipilihnya LDA karena kemampuannya untuk mengoptimalkan pemisahan kelas dan memfasilitasi identifikasi penyakit dengan tepat. Identifikasi dan klasifikasi penyakit daun kentang menjadi cukup sulit karena variasi yang luas dalam warna, tekstur, dan struktur fraktal yang dihasilkan oleh berbagai

jenis penyakit. Integrasi ketiga set fitur ini diharapkan dapat memberikan representasi yang lebih komprehensif, memungkinkan pemisahan yang lebih baik antara citra daun terinfeksi *early blight*, *late blight*, dan yang sehat. Sehingga membantu petani dalam menerapkan strategi pengelolaan penyakit pada kentang secara tepat waktu dan terarah.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Beberapa penelitian terkait pemanfaatan teknologi pengolahan citra digital dalam klasifikasi penyakit pada daun tanaman kentang telah dilakukan. Penelitian oleh Rakhmawati [1] mengklasifikasikan penyakit daun kentang ke dalam 3 kelas (sehat, *early blight*, dan *late blight*) menggunakan fitur tekstur dan fitur warna serta pengklasifikasi SVM (*Support Vector Machine*) kernel RBF. Fitur tekstur yang digunakan adalah 5 fitur GLCM dan 2 fitur momen warna. Penelitian ini menghasilkan akurasi sebesar 87%. Selanjutnya, Amatullah [5] dalam penelitiannya juga melakukan identifikasi penyakit daun kentang berdasarkan fitur tekstur dan warna. Fitur tekstur yang digunakan adalah GLCM, sedangkan fitur warna yang digunakan adalah RGB. Metode KNN (*K-Nearest Neighbor*) diterapkan dengan akurasi sebesar 80%. Islam [6] melakukan klasifikasi penyakit pada 300 citra daun kentang ke dalam 3 kelas dengan menggunakan segmentasi berdasarkan ruang warna Lab* serta metode klasifikasi *multiclass* SVM. Hasil pengujian menunjukkan akurasi sebesar 95%. Sedangkan Iqbal [3] berhasil mencapai akurasi sebesar 97% dalam sistem klasifikasi penyakit daun kentang secara otomatis menggunakan *machine learning*. Sementara itu, Muchtar [7] menerapkan integrasi fitur dimensi fraktal dan lacunarity dalam melakukan klasifikasi 18 kelas citra daun tumbuhan, mencapai akurasi 95.9 % menggunakan metode Random Forest. Secara keseluruhan, penelitian-penelitian ini menunjukkan bahwa teknologi pengolahan citra digital memiliki potensi besar dalam mendukung klasifikasi penyakit daun kentang dengan akurasi yang memadai. Peluang untuk mengintegrasikan fitur-fitur warna dan tekstur dapat menjadi strategi yang menjanjikan dalam mengatasi kompleksitas variasi penyakit dan kondisi citra.

2.2. Model Warna RGB dan HSV

Model warna adalah suatu representasi sistematis dari warna dalam bentuk koordinat yang memungkinkan kita memahami dan memanipulasi informasi warna. Terdapat beberapa model warna dalam pengolahan citra digital, namun dua model warna yang umum digunakan adalah RGB (*Red, Green, Blue*) dan HSV (*Hue, Saturation, Value*). Model warna RGB menggunakan kombinasi intensitas warna merah, hijau, dan biru untuk menciptakan berbagai warna[8]. Setiap piksel dalam

citra direpresentasikan sebagai campuran intensitas dari ketiga warna dasar tersebut, membentuk spektrum warna yang luas. Sementara itu, model warna HSV menyajikan warna dalam tiga dimensi, yaitu Hue (H), Saturation (S), dan Value (V). Hue mewakili jenis warna dalam bentuk sudut, Saturation mengukur kecerahan warna, dan Value menentukan kecerahan atau kegelapan warna. Model ini lebih intuitif dalam menggambarkan karakteristik warna, seperti kejelasan dan kecerahan. Konversi dari model warna RGB ke model warna HSV dapat dilakukan dengan menggunakan rumus matematis berikut[9]:

$$Max = (R, G, B) \quad (1)$$

$$Min = (R, G, B) \quad (2)$$

$$Delta = Max - Min \quad (3)$$

$$Hue(H) = \begin{cases} 60 \times \left(\frac{Max - R}{Delta} \right), & \text{jika } Max = R \\ 60 \times \left(2 + \frac{G - B}{Delta} \right), & \text{jika } Max = G \\ 60 \times \left(4 + \frac{B - R}{Delta} \right), & \text{jika } Max = B \end{cases} \quad (4)$$

$$Saturation(S) = \begin{cases} 0, & \text{jika } Max = Min \\ \frac{Delta}{Max}, & \text{jika } Max \neq 0 \end{cases} \quad (5)$$

$$Value(V) = Max \quad (6)$$

2.3. Momen Warna

Momen warna atau *color moment* adalah sekumpulan statistik yang digunakan untuk mengukur distribusi warna dalam suatu citra. Dengan menganalisis momen warna, kita dapat memahami properti statistik dari sebaran nilai piksel warna dalam citra. Untuk citra warna, momen warna dapat dihitung untuk setiap saluran warna, seperti saluran Merah (R), Hijau (G), dan Biru (B) pada citra RGB. Untuk memperoleh momen warna pada citra RGB, kita dapat menghitung momen-momen statistik seperti *mean* (rata-rata), *varians* (varians), *skewness* (kecondongan), dan *kurtosis* (kurtosis)[9]. Berikut adalah rumus momen warna untuk saluran warna pada citra RGB:

$$Mean = \frac{1}{N} \sum_{i=1}^N I_i \quad (7)$$

$$Variance = \frac{1}{N} \sum_{i=1}^N (I_i - \mu)^2 \quad (8)$$

$$Skewness = \frac{\frac{1}{N} \sum_{i=1}^N (I_i - \mu)^3}{\left(\frac{1}{N} \sum_{i=1}^N (I_i - \mu)^2 \right)^{3/2}} \quad (9)$$

$$Kurtosis = \frac{\frac{1}{N} \sum_{i=1}^N (I_i - \mu)^4}{\left(\frac{1}{N} \sum_{i=1}^N (I_i - \mu)^2 \right)^2} \quad (10)$$

dengan N adalah jumlah piksel, I_i adalah nilai intensitas dan μ adalah *mean*. Dengan menghitung momen warna ini untuk masing-masing saluran warna, kita dapat memahami distribusi intensitas warna pada citra RGB dan menggunakannya sebagai fitur dalam analisis citra, termasuk dalam kasus identifikasi penyakit pada daun kentang.

2.4. Gray Level Co-occurrence Matrix (GLCM)

GLCM adalah suatu matriks yang merepresentasikan kemunculan bersama-sama dari dua piksel dengan tingkat keabuan tertentu dalam suatu citra. GLCM umumnya digunakan untuk mengekstrak fitur tekstur dari citra[10]. Dengan menghitung probabilitas bersama kemunculan berbagai pasangan nilai tingkat keabuan pada berbagai arah atau orientasi, GLCM memberikan informasi tentang sejauh mana distribusi nilai keabuan saling berkorelasi dalam citra.

Beberapa fitur tekstur yang dapat dihitung dari GLCM melibatkan analisis statistik dari probabilitas bersama ini. Pertama, "*Contrast*" mengukur perbedaan tingkat keabuan antara dua piksel, memberikan gambaran tentang keragaman nilai tingkat keabuan dalam citra. Kedua, "*Correlation*" mengukur sejauh mana tingkat keabuan antara dua piksel berkorelasi satu sama lain, menyediakan informasi tentang pola hubungan antar piksel. Selanjutnya, "*Energy*" menggambarkan homogenitas distribusi nilai tingkat keabuan dalam citra, sementara "*Homogeneity*" mengukur sejauh mana tingkat keabuan dalam citra. Persamaan (11)-(14) menunjukkan rumus untuk memperoleh tiap fitur GLCM[6].

$$Contrast = \sum_{i,j} P(i,j)(i-j)^2 \quad (11)$$

$$Correlation = \frac{\sum_{i,j} P(i,j)(i-\mu)(j-\nu)}{\sigma_i \sigma_j} \quad (12)$$

$$Energy = \sum_{i,j} [P(i,j)]^2 \quad (13)$$

$$Homogeneity = \sum_{i,j} \frac{1}{1+|i-j|} P(i,j) \quad (14)$$

Di sini, $P(i,j)$ adalah probabilitas bersama kemunculan tingkat keabuan i dan j , sedangkan μ dan ν adalah rata-rata tingkat keabuan dan σ_i serta σ_j adalah standar deviasi dari tingkat keabuan.

2.5. Dimensi Fraktal Renyi

Dimensi Fraktal adalah konsep dalam geometri fraktal yang digunakan untuk mengukur kompleksitas atau kerapatan suatu objek atau struktur[11]. Dalam geometri tradisional, dimensi objek umumnya merupakan bilangan bulat, seperti

dimensi dua untuk bidang atau dimensi tiga untuk benda ruang. Namun, objek fraktal memiliki dimensi fraktal, yang bisa menjadi bilangan desimal atau pecahan[12]. Dimensi Fraktal Renyi adalah variasi dari dimensi fraktal yang menggunakan konsep dari teori informasi. Dimensi Fraktal Renyi digunakan untuk mengukur struktur fraktal dalam suatu objek atau citra. Rumus umumnya melibatkan parameter orde α dan probabilitas p_i . Pada dasarnya, Dimensi Fraktal Renyi memberikan pemahaman tentang sejauh mana suatu struktur bersifat fraktal pada berbagai skala[13]. Dimensi Fraktal Renyi didefinisikan sebagai berikut:

$$D_\alpha = \frac{1}{\alpha-1} \cdot \log\left(\sum_{i=1}^N p_i^\alpha\right) \quad (15)$$

Di mana:

D_α = dimensi fraktal Renyi.

α = parameter orde dimensi fraktal Renyi.

p_i = probabilitas bahwa suatu piksel termasuk ke dalam objek pada citra.

N = jumlah piksel objek pada citra.

Citra daun yang sehat, daun yang terkena *early blight*, dan daun yang terkena *late blight* mungkin memiliki pola fraktal yang berbeda-beda. Dimensi Fraktal Renyi dapat membantu mengukur tingkat kompleksitas atau *irregularity* dalam struktur daun pada tingkat resolusi yang berbeda. Dengan mengintegrasikan Dimensi Fraktal Renyi sebagai fitur dalam analisis citra, penelitian ini diharapkan dapat memberikan gambaran yang lebih mendalam tentang perbedaan struktural antara daun yang sehat dan daun yang terkena penyakit.

2.6. Linear Discriminant Analysis (LDA)

LDA adalah metode statistik yang digunakan untuk menemukan kombinasi linear dari fitur-fitur yang dapat membedakan dua atau lebih kelas. Tujuan utama LDA adalah untuk mengoptimalkan pemisahan antara kelas-kelas sambil meminimalkan varians dalam setiap kelas. Keunggulan LDA melibatkan kemampuannya untuk mengatasi situasi di mana fitur-fitur memiliki korelasi tinggi satu sama lain. LDA juga efektif ketika ukuran sampel dalam setiap kelas relatif seimbang. Persamaan (16)-(19) menunjukkan metode LDA[4].

$$\mu_k = \frac{1}{n_k} \sum_{i=1}^{n_k} x_i^{(k)} \quad (16)$$

$$S_W = \sum_{k=1}^K \sum_{i=1}^{n_k} (x_i^{(k)} - \mu_k)(x_i^{(k)} - \mu_k)^T \quad (17)$$


$$S_B = \sum_{k=1}^K n_k (\mu_k - \mu)(\mu_k - \mu)^T \quad (18)$$

$$S_W^{-1} S_B v = \lambda v \quad (19)$$

dengan μ_k sebagai vektor rata-rata untuk kelas k , n_k adalah jumlah sampel dalam kelas k , dan $x_i^{(k)}$ adalah vektor fitur untuk sampel ke- i dalam kelas k . dengan μ sebagai vektor rata-rata global. di mana v adalah vektor eigen dan λ adalah nilai eigen. Nilai eigen digunakan untuk menemukan vektor proyeksi yang paling signifikan untuk memisahkan kelas-kelas dalam data. Nilai eigen memberikan informasi tentang seberapa besar variasi yang dijelaskan oleh masing-masing vektor eigen. Semakin besar nilai eigen, semakin banyak variasi yang dijelaskan oleh vektor eigen tersebut.

3. METODE PENELITIAN

Penelitian ini diawali dengan pengumpulan 456 data citra daun kentang, yang kemudian di-*preprocessing* dan disegmentasi. Berikutnya, proses ekstraksi fitur dilakukan melalui pendekatan moment warna RGB (*mean, variance, skewness, kurtosis*), fitur tekstur GLCM (*contrast, correlation, energy, homogeneity*), dan fitur dimensi fraktal Renyi. Setelah menentukan label kelas, kami menggunakan *k-fold cross validation* untuk mengevaluasi model. Metode LDA diterapkan pada data latih untuk menemukan proyeksi linear yang optimal. Model LDA kemudian digunakan untuk mengklasifikasikan data uji, dan performansi klasifikasi dievaluasi dengan menggunakan metrik akurasi. Gambar 1 menunjukkan tahapan yang digunakan dalam penelitian ini.



Gambar 1. Metode Penelitian

3.1. Dataset

Dataset yang dikumpulkan untuk penelitian ini terdiri dari 456 citra daun kentang, terdiri dari tiga kelas: daun sehat, daun yang terkena *early blight*, dan daun yang terkena *late blight*. Setiap kelas memiliki jumlah data sebanyak 152 citra. Masing-masing citra memiliki ukuran 256x256 piksel, memberikan representasi visual yang cukup jelas untuk ekstraksi fitur dan analisis. Data ini berasal dari sumber *Kaggle.com*, yang menunjukkan bahwa dataset telah diakuisisi dari *platform* berbagi dataset *online*, yang memastikan keterbukaan dan ketersediaan informasi bagi komunitas penelitian. Dengan jumlah data yang seimbang pada setiap kelas dan ukuran citra yang konsisten, dataset ini memberikan dasar yang baik untuk pengembangan model klasifikasi penyakit daun kentang dengan menggunakan metode-metode analisis citra. Gambar 2 menunjukkan citra daun kentang untuk kelas daun “sehat”, daun “*early blight*” dan daun “*late blight*”.



Gambar 2. Contoh citra kelas “sehat” (baris ke-1), kelas “*early blight*” (baris ke-2) dan kelas “*late blight*” (baris ke-3)

3.2. Preprocessing dan Segmentasi

Preprocessing dan segmentasi dalam analisis citra bertujuan untuk mempersiapkan dan menyederhanakan citra sehingga informasi yang relevan dapat diekstrak dengan lebih baik[10]. Dalam penelitian ini, dilakukan dua tahap utama, yaitu *preprocessing* dan segmentasi[14] untuk mempersiapkan citra daun kentang sebelum analisis lebih lanjut. Proses *preprocessing* dimulai dengan mengkonversi citra dari model warna RGB dan HSV ke citra *grayscale* menggunakan Persamaan (1)-(6). Pada tahap ini, masing-masing *channel* warna (R, G, B, H, S, dan V) diekstraksi untuk menciptakan citra *grayscale* yang merepresentasikan aspek warna dan kecerahan dari citra asli.

Pada tahap segmentasi, citra *grayscale* dari *channel* H (Hue) dalam model warna HSV dipilih untuk digunakan. *Channel* warna H dipilih karena lebih menonjolkan ciri tekstur pada permukaan daun yang terkena penyakit. Citra *grayscale* ini kemudian diubah menjadi citra biner menggunakan metode *thresholding*[15]. Penggunaan metode *thresholding* bertujuan untuk memisahkan area yang menunjukkan ciri-ciri khusus pada daun, utamanya

area daun yang rusak atau terdapat bercak, sehingga memfasilitasi proses analisis lebih lanjut.

3.3. Ekstraksi Fitur

Proses ekstraksi fitur pada penelitian ini terdiri atas 3 tahap. Tahap pertama adalah ekstraksi fitur momen warna. Proses ini mencakup ekstraksi empat fitur momen warna, yaitu *mean*, *variance*, *skewness*, dan *kurtosis*, yang diambil dari masing-masing citra *grayscale* kanal R, G, dan B. Hal ini menghasilkan fitur vektor berukuran 1x12 untuk setiap citra, mencerminkan karakteristik distribusi intensitas warna pada berbagai kanal. Untuk memperoleh fitur ini, digunakan Persamaan (7)-(10).

Tahap kedua dalam ekstraksi fitur tekstur menggunakan metode GLCM pada citra *grayscale channel* H (Hue). GLCM menghasilkan fitur tekstur seperti kontras, korelasi, energi, dan homogeneity, yang memberikan informasi tentang pola tekstur pada permukaan daun. Fitur vektor berukuran 1x4 dihasilkan dalam tahap ini untuk tiap citra. Persamaan (11)-(14) digunakan untuk memperoleh fitur GLCM.

Selanjutnya, ekstraksi fitur tekstur yang diwakili oleh dimensi fraktal Renyi dilakukan pada citra biner hasil segmentasi. Fitur ini memberikan informasi tentang kompleksitas struktural citra, yang menghasilkan fitur vektor berukuran 1x1 untuk tiap citra. Kemudian, dilakukan penggabungan fitur, sehingga ketika 3 fitur vektor ini digabungkan maka pada akhirnya diperoleh sebuah vektor berukuran 1x17 untuk tiap citra.

3.4. Klasifikasi dan Validasi


Proses klasifikasi dilakukan dengan menerapkan metode *Linear Discriminant Analysis* (LDA). Metode ini digunakan untuk membangun model klasifikasi yang optimal berdasarkan fitur-fitur ekstraksi sebelumnya, termasuk fitur warna, tekstur, dan dimensi fraktal Renyi. Teknik validasi yang diterapkan adalah *k-fold cross-validation*, di mana dataset yang terdiri dari tiga kelas dengan masing-masing 152 citra dibagi menjadi *k* subset. Setiap iterasi melibatkan penggunaan *k-1* subset sebagai data latih dan subset yang tersisa sebagai data uji [12].

Gambar 3 menunjukkan proses *k-fold cross validation*. Untuk penelitian ini, jika *k* = 10 dan 3 kelas, masing-masing berisi 152 citra daun kentang, prosesnya akan berlangsung sebagai berikut:

1. Dataset dari 456 citra daun kentang dibagi menjadi 10 *fold*.
2. Selama setiap iterasi proses *cross validation*:
 - Satu *fold* (sekitar 45 citra) dijadikan sebagai set validasi.
 - Sisa 9 *fold* (sekitar 411 citra) digunakan untuk melatih model.
 - Model dilatih pada set pelatihan dan dievaluasi pada set validasi.

3. Proses ini diulang 10 kali, dengan setiap *fold* digunakan sekali sebagai set validasi.
4. Metrik kinerja (seperti akurasi) dari setiap iterasi kemudian diambil rata-ratanya untuk mendapatkan perkiraan yang lebih andal terhadap kinerja model.

Dengan menggunakan metode ini, kinerja model dievaluasi secara komprehensif melalui beberapa iterasi, menghasilkan estimasi yang lebih stabil terkait akurasi dan performa klasifikasi pada dataset penyakit daun kentang.



Gambar 3. Ilustrasi *k-fold cross validation*

3.5. Perhitungan Performansi

Dalam penelitian ini, perhitungan performansi akurasi digunakan sebagai metrik utama untuk mengevaluasi sejauh mana model klasifikasi mampu mengidentifikasi kelas dengan benar. Akurasi dihitung dengan membagi jumlah prediksi yang benar (*true positives*) dengan jumlah total citra yang dievaluasi. Persamaan akurasi dapat dijelaskan sebagai berikut:


$$\text{Akurasi} = \frac{\text{Jumlah True Positive}}{\text{Jumlah Total Citra}} \quad (20)$$

dimana *True Positives (TP)* mengacu pada citra yang terklasifikasi dengan benar ke dalam kelas yang seharusnya, sedangkan Jumlah Total Citra adalah total keseluruhan citra yang dinilai, yaitu sebanyak 456 citra.

4. HASIL DAN PEMBAHASAN


Penelitian ini dirancang dalam rangka menguji dan membandingkan performa berbagai fitur pada identifikasi penyakit daun kentang. Penggunaan perangkat lunak Matlab R2015b[15] dalam tahap *preprocessing*, segmentasi, dan ekstraksi fitur memungkinkan penggabungan tiga jenis fitur, yaitu moment warna, GLCM, dan dimensi fraktal Renyi.

Sedangkan untuk tahap klasifikasi dan validasi digunakan perangkat lunak RapidMiner Studio[16].



Gambar 4. Ekstraksi fitur Momen Warna

Gambar 4 menunjukkan proses *preprocessing* yang telah dilakukan sesuai dengan tahapan penelitian yang diusulkan. Diperoleh 12 buah fitur momen warna yang terdiri atas fitur *mean*, *variance*, *skewness*, dan *kurtosis* dari masing-masing kanal R,G dan B. Sedangkan Gambar 5 menunjukkan proses *preprocessing* dan segmentasi yang telah dilakukan untuk memperoleh 4 fitur GLCM pada citra HSV kanal *Hue*. 4 fitur GLCM ini adalah *contrast*, *correlation*, *energy* dan *homogeneity*. Kemudian terdapat pula 1 fitur dimensi fraktal Renyi pada citra biner hasil segmentasi. Selanjutnya tiap-tiap fitur kemudian diintegrasikan menjadi satu buah fitur vektor yang berisi 17 buah atribut fitur hasil penggabungan. 17 fitur inilah yang kemudian diperoleh pada seluruh data yang berjumlah 456 citra. Pada akhirnya, diperoleh matrix fitur dengan ukuran 456×17 . Tiap kelas kemudian diberi label yang sesuai untuk kemudian dilakukan proses klasifikasi dengan menggunakan metode LDA.



Gambar 5. Ekstraksi fitur tekstur GLCM dan Dimensi Fraktal Renyi

Skenario pengujian pertama menitikberatkan pada perhitungan performa setiap fitur secara terpisah, mengukur akurasi saat hanya satu jenis fitur digunakan. Selanjutnya, fitur-fitur ini

digabungkan dan dibandingkan untuk mengevaluasi peningkatan performa yang mungkin terjadi dengan metode klasifikasi LDA. Pada skenario kedua, penelitian akan mengeksplorasi pengaruh nilai k pada teknik validasi *k-fold cross-validation* terhadap akurasi. Skenario ini memberikan informasi terkait bagaimana variasi nilai k dapat mempengaruhi hasil validasi dan akurasi secara keseluruhan. Terakhir, dalam skenario ketiga, penelitian akan membandingkan performa metode klasifikasi LDA dengan metode klasifikasi lainnya yang digunakan dalam penelitian sebelumnya, yaitu SVM[12], KNN[5], dan Random Forest[2]. Eksperimen ini bertujuan untuk menentukan metode mana yang memberikan akurasi terbaik dalam identifikasi penyakit daun kentang. Pendekatan ini memungkinkan evaluasi lebih lanjut terhadap kecocokan metode klasifikasi dengan karakteristik data yang dihadapi. Melalui tiga skenario eksperimen ini, diharapkan penelitian dapat memberikan pemahaman mendalam tentang kontribusi masing-masing fitur, optimalisasi teknik validasi, dan perbandingan antara metode klasifikasi yang berbeda.

Tabel 1 menggambarkan pengaruh jumlah fitur dan integrasi fitur terhadap akurasi klasifikasi. Pada pengujian ini, digunakan metode LDA untuk klasifikasi dengan teknik validasi *k-fold cross validation*. Ketika hanya menggunakan fitur momen warna, akurasi bisa mencapai 97.58%. Ketika hanya menggunakan fitur GLCM, akurasi hanya mencapai 60.75%, sedangkan hanya dengan fitur dimensi fraktal Renyi mencapai 62.07%. Namun, ketika menggabungkan fitur momen warna dan GLCM, akurasi meningkat menjadi 98.03%. Lebih lanjut, dengan menggabungkan fitur momen warna, GLCM, dan fraktal Renyi, akurasi tertinggi tercapai sebesar 98.46%.

Tabel 1. Pengaruh jumlah fitur terhadap akurasi

Fitur	Ukuran fitur vektor per citra	Akurasi (%)
Momen Warna (Mean, Variance, Skewness, Kurtosis)	1×12	97.58
GLCM (Contrast, Correlation, Energy, Homogeneity)	1×4	60.75
Dimensi Fraktal Renyi	1×1	62.07
Momen Warna + GLCM	1×16	98.03
Momen Warna + GLCM + Dimensi Fraktal Renyi	1×17	98.46

Tabel 2 menunjukkan *confusion matrix* dari klasifikasi yang telah dilakukan. Terlihat bahwa untuk kelas “*early blight*” dan “*late blight*” mengalami kesalahan klasifikasi pada 2 citra di kelasnya, sehingga didapatkan nilai *recall* yang sama yaitu sebesar 98.68%. Kelas “*sehat*” menunjukkan nilai *recall* yang sedikit lebih rendah

yaitu sebesar 98.03% karena terdapat 3 citra yang mengalami kesalahan klasifikasi pada kelas ini. Dari hasil ini dapat disimpulkan bahwa integrasi fitur momen warna, GLCM, dan dimensi fraktal Renyi secara bersama-sama memberikan kontribusi signifikan terhadap peningkatan akurasi klasifikasi, melebihi hasil dari penggunaan setiap fitur secara terpisah.

Tabel 2. *Confusion Matrix* dari hasil klasifikasi dengan menggabungkan semua fitur

	true sehat	true early blight	true late blight	class precision
pred. sehat	149	0	1	99.33%
pred. early blight	0	150	1	99.34%
pred. late blight	3	2	150	96.77%
class recall	98.03%	98.68%	98.68%	

Tabel 3. Contoh citra dari tiap kelas yang mengalami kesalahan klasifikasi

Citra	Kelas	Hasil Klasifikasi
 "citra65.jpg"	sehat	late blight
 "citra251.jpg"	early blight	late blight
 "citra403.jpg"	late blight	early blight

Sementara itu, Tabel 3 menunjukkan beberapa contoh citra yang mengalami kesalahan klasifikasi. Meskipun hasil pengujian mencapai tingkat akurasi yang tinggi sebesar 98,46%, terdapat sedikit kesalahan klasifikasi yang mungkin disebabkan oleh beberapa faktor. Kemiripan fisik citra antar kelas dapat mengakibatkan kesulitan bagi model dalam membedakan antara kelas-kelas yang memiliki karakteristik visual yang serupa. Faktor ini dapat mencakup variasi dalam posisi daun serta kondisi pencahayaan.

Tabel 4. Pengaruh nilai k pada k -fold cross validation terhadap akurasi

k	Akurasi (%)
2	97,37
3	97,59
4	97,59
5	98,46
6	98,03
7	98,02

k	Akurasi (%)
8	98,25
9	98,46
10	98,03

Tabel 4 menunjukkan hasil pengujian terkait pengaruh nilai k terhadap akurasi klasifikasi. Teknik validasi k -fold cross-validation membagi dataset menjadi k subset yang sama ukurannya, di mana salah satunya digunakan sebagai data validasi sementara sisanya digunakan sebagai data pelatihan. Prosedur ini diulang k kali, di mana setiap kali, satu subset yang berbeda dipilih sebagai subset validasi, sementara subset lainnya digunakan untuk pelatihan. Hasil pengujian menunjukkan variasi nilai akurasi dengan perubahan nilai k . Sebagai contoh, akurasi tertinggi ditemukan ketika nilai k sama dengan 5 dan 9, mencapai 98.46%. Sebaliknya, beberapa nilai k lainnya, seperti 2, 3, dan 4, memberikan akurasi yang lebih rendah. Hasil ini menunjukkan bahwa pemilihan nilai k dapat mempengaruhi kinerja model. Untuk data ini, $k=9$ dan $k=5$ menunjukkan akurasi tertinggi dengan nilai 98.46%.

Tabel 5. Perbandingan Akurasi LDA dengan classifier lainnya

Classifier	Keterangan	Akurasi (%)
LDA	-	98.46
SVM	kernel=linear	91.88
KNN	$k=5$	84.44
Random Forest	criterion=gain ratio	92.34

Dalam perbandingan metode klasifikasi untuk identifikasi penyakit daun kentang, Tabel 5 menunjukkan hasil akurasi dari beberapa classifier yang berbeda. Beberapa classifier ini dipilih karena sering digunakan pada penelitian-penelitian sebelumnya dalam bidang klasifikasi daun. Proses perbandingan metode ini dilakukan secara empiris dengan menggunakan perangkat lunak RapidMiner Studio. Pengujian dilakukan dengan menggunakan teknik validasi k -fold cross validation dengan $k=9$. Metode LDA menunjukkan akurasi tertinggi sebesar 98.46%, yang secara tidak langsung mendemonstrasikan kemampuannya yang sangat baik dalam membedakan kelas penyakit. SVM dengan kernel linear mencapai akurasi sebesar 91.88%, sementara KNN dengan $k=5$ dan Random Forest dengan kriteria *gain ratio* memiliki akurasi masing-masing sebesar 84.44% dan 92.34%. Hasil ini memberikan gambaran bahwa LDA mendominasi dalam tugas klasifikasi penyakit daun kentang pada dataset yang digunakan dalam penelitian ini. Meskipun SVM, KNN, dan Random Forest memberikan performa yang baik, LDA tetap menjadi pilihan unggul dengan akurasi yang secara signifikan lebih tinggi. Dengan demikian, pemilihan metode klasifikasi memainkan peran penting dalam keberhasilan identifikasi penyakit daun kentang, dan

LDA menonjol sebagai pilihan yang efektif dalam kasus ini.

5. KESIMPULAN DAN SARAN

Melalui integrasi fitur momen warna, tekstur GLCM, dan dimensi fraktal Renyi menggunakan metode Linear Discriminant Analysis (LDA), penelitian ini mencapai tingkat akurasi sebesar 98.46%. Hasil eksperimen menunjukkan bahwa pendekatan ini mengungguli metode klasifikasi lainnya seperti SVM, KNN, dan Random Forest. Penggabungan fitur-fitur tersebut membuka potensi peningkatan keandalan sistem dalam mengidentifikasi penyakit daun kentang. Dengan demikian, penelitian ini memberikan kontribusi signifikan dalam pengembangan sistem klasifikasi penyakit pada daun kentang. Penelitian selanjutnya dapat mempertimbangkan uji coba lebih lanjut pada variasi kondisi citra dan jenis penyakit untuk memvalidasi keandalan sistem dalam berbagai situasi. Pengoptimalan parameter dan eksplorasi model klasifikasi alternatif juga dapat menjadi fokus penelitian mendatang.

DAFTAR PUSTAKA

- [1] P. U. Rakhmawati, Y. M. Pranoto, and E. Setyati, "Klasifikasi Penyakit Daun Kentang Berdasarkan Fitur Tekstur dan Fitur Warna Menggunakan Support Vector Machine," *Semin. Nas. Teknol. dan Rekayasa*, no. 2527–6042, pp. 1–8, 2018.
- [2] P. Patil, N. Yaligar, and M. S M, "Comparision of Performance of Classifiers - SVM, RF and ANN in Potato Blight Disease Detection using Leaf Images," *2017 IEEE Int. Conf. Comput. Intell. Comput. Res.*, pp. 1–5, 2017.
- [3] M. A. Iqbal and K. H. Talukder, "Detection of Potato Disease Using Image Segmentation and Machine Learning," *2020 Int. Conf. Wirel. Commun. Signal Process. Networking, WiSPNET 2020*, pp. 43–47, 2020, doi: 10.1109/WiSPNET48689.2020.9198563.
- [4] A. Tharwat, T. Gaber, A. Ibrahim, and A. E. Hassanien, "Linear discriminant analysis: A detailed tutorial," *AI Commun.*, vol. 30, no. 2, pp. 169–190, 2017, doi: 10.3233/AIC-170729.
- [5] L. Amatullah, I. Ein, and M. M. Santoni, "Identifikasi Penyakit Daun Kentang Berdasarkan Fitur Tekstur dan Warna Dengan Menggunakan Metode K-Nearest Neighbor," *Semin. Nas. Mhs. Ilmu Komput. dan Apl.*, no. April, pp. 783–791, 2021.
- [6] M. Islam, A. Dinh, K. Wahid, and P. Bhowmik, "Detection of potato diseases using image segmentation and multiclass support vector machine," *Can. Conf. Electr. Comput. Eng.*, pp. 8–11, 2017, doi: 10.1109/CCECE.2017.7946594.
- [7] M. Muchtar, N. Suciati, and C. Fatichah, "FRACTAL DIMENSION AND LACUNARITY COMBINATION FOR PLANT LEAF CLASSIFICATION," *J. Ilmu Komput. dan Inf.*, vol. 9, no. 2, p. 96, Jun. 2016, doi: 10.21609/jiki.v9i2.385.
- [8] M. Muchtar, Y. P. Pasrun, R. Rasyid, N. Miftachurohmah, and M. Mardiwati, "PENERAPAN METODE NAÏVE BAYES DALAM KLASIFIKASI KESEGARAN IKAN BERDASARKAN WARNA PADA CITRA AREA MATA," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 1, Jan. 2024, doi: 10.23960/jitet.v12i1.3879.
- [9] J. Justiawan, R. Sigit, and Z. Arief, "Tooth Color Detection Using PCA and KNN Classifier Algorithm Based on Color Moment," *Emit. Int. J. Eng. Technol.*, vol. 5, no. 1, pp. 139–153, 2017, doi: 10.24003/emitter.v5i1.171.
- [10] M. Muchtar and L. Cahyani, "Klasifikasi Citra Daun dengan Metode Gabor Co-Occurence," *Ultim. Comput.*, vol. VII, no. 2, pp. 39–47, 2015.
- [11] D. Setiabudi, D. Wahyu Herdiyanto, and A. Felayati, "Analisis Kinerja Kompresi Citra Dwt Dan Fraktal Pada Transmisi Citra Dengan Sistem Sc-Fdma," *J. Mnemon.*, vol. 5, no. 2, pp. 150–157, 2022, doi: 10.36040/mnemonic.v5i2.4902.
- [12] M. Muchtar, "Penggabungan Fitur Dimensi Fraktal dan Lacunarity untuk Klasifikasi Daun," Institut Teknologi Sepuluh Nopember, Surabaya, 2015.
- [13] W. Kinsner, "A Unified Approach To Fractal Dimensions," *Int. J. Cogn. Informatics Nat. Intell.*, vol. 1, no. 4, pp. 26–46, 2007, doi: 10.4018/jcini.2007100103.
- [14] M. Orisa and T. Hidayat, "ANALISIS TEKNIK SEGMENTASI PADA PENGOLAHAN CITRA," *J. Mnemon.*, vol. 2, no. 2, pp. 9–13, 2019.
- [15] A. Setiyorini, I. P. N. Purnama, J. Y. Sari, M. Muchtar, and E. Ngii, "Vehicle number plate identification using template matching algorithm for automatic parking system," in *ACM International Conference Proceeding Series*, Apr. 2019, pp. 196–200. doi: 10.1145/3330482.3330483.
- [16] R. Maulidiah, M. Muchtar, N. Aisyah Fitri, I. Asriani, M. Putri Yasmine, and P. Studi, "Pengelompokan Data Pertumbuhan dan Kontribusi Ekonomi Indonesia Menurut Provinsi Menggunakan Metode K-Means Clustering," *J. Teknol. Sist. Inf. dan Sist. Komput. TGD*, vol. 6, no. 2, pp. 436–444, Jul. 2023, [Online]. Available: <https://ojs.trigunadharma.ac.id/index.php/jsk/index>