

# Analisis Ekstraksi Fitur untuk Deteksi Retinopati Diabetik menggunakan Teknik Machine Learning

## *Feature Extraction Analysis for Diabetic Retinopathy Detection Using Machine Learning Techniques*

<sup>1</sup>Loneli Costaner\*, <sup>2</sup>Lisnawita, <sup>3</sup>Guntoro, <sup>4</sup>Abdullah

<sup>1,2,3</sup>Teknik Informatika, Fakultas Ilmu Komputer, Universitas Lancang Kuning – Riau

<sup>4</sup>Sistem Informasi, Fakultas Teknik Ilmu Komputer, Universitas Islam Indragiri – Riau

\*e-mail: [lonelicostaner@unilak.ac.id](mailto:lonelicostaner@unilak.ac.id)

(*received:* 10 September 2024, *revised:* 12 September 2024, *accepted:* 21 September 2024)

### Abstrak

Retinopati diabetik adalah komplikasi serius dari diabetes yang dapat mengakibatkan kebutaan jika tidak dideteksi dan diobati secara dini. Deteksi otomatis retinopati diabetik memerlukan teknik ekstraksi fitur yang efektif untuk meningkatkan akurasi diagnosis. Penelitian ini bertujuan untuk mengembangkan metode deteksi retinopati diabetik dengan memanfaatkan Local Binary Pattern (LBP) yang dikombinasikan dengan wavelet transform, dan kemudian mengklasifikasikan fitur-fitur tersebut menggunakan Support Vector Machine (SVM). Metode yang digunakan mencakup ekstraksi fitur dari citra retina menggunakan LBP dan wavelet transform. Fitur yang diekstraksi kemudian diklasifikasikan menggunakan SVM untuk mengevaluasi kinerja dalam mendeteksi retinopati diabetik. Hasil analisis menunjukkan bahwa fitur dominan terletak pada baris kelima dengan nilai 0,57006, yang menunjukkan efektivitas metode LBP dalam ekstraksi fitur. Model yang dikembangkan menunjukkan kinerja tinggi dengan akurasi 95,59%, precision 96%, recall 97,96%, dan F1-score 96,97%. Metode ekstraksi fitur yang dikombinasikan dengan SVM terbukti efektif dan andal dalam mendeteksi retinopati diabetik, menawarkan tingkat kesalahan yang rendah dan akurasi tinggi, sehingga berpotensi menjadi alat bantu yang berharga dalam diagnosis klinis

**Kata kunci:** diabetic retinopathy, feature extraction, LBP, wavelet transform, SVM

### Abstract

Diabetic retinopathy is a serious complication of diabetes that can lead to blindness if not detected and treated early. Automated detection of diabetic retinopathy requires effective feature extraction techniques to enhance diagnostic accuracy. This study aims to develop a method for detecting diabetic retinopathy by utilizing Local Binary Pattern (LBP) combined with wavelet transform, and then classifying the extracted features using Support Vector Machine (SVM). The approach includes feature extraction from retinal images using LBP and wavelet transform. The extracted features are subsequently classified with SVM to evaluate performance in detecting diabetic retinopathy. Analysis results show that the dominant feature is found in the fifth row with a value of 0.57006, indicating the effectiveness of the LBP method in feature extraction. The developed model demonstrates high performance with an accuracy of 95.59%, precision of 96%, recall of 97.96%, and F1-score of 96.97%. The combination of feature extraction methods with SVM proves to be effective and reliable in detecting diabetic retinopathy, offering low error rates and high accuracy, thus potentially serving as a valuable tool in clinical diagnosis

**Keywords:** diabetic retinopathy, feature extraction, LBP, wavelet transform, SVM

## 1 Pendahuluan

Retinopati diabetik adalah komplikasi serius dari diabetes yang dapat mengakibatkan kebutaan jika tidak dideteksi dan diobati secara dini [1]. Deteksi dini retinopati diabetik sangat penting untuk mencegah kerusakan lebih lanjut pada retina. Metode tradisional untuk mendiagnosis kondisi ini seringkali mengandalkan pemeriksaan manual citra retina, yang dapat memakan waktu dan rentan

<http://sistemasi.ftik.unisi.ac.id>

terhadap kesalahan manusia [2]. Untuk mengatasi keterbatasan ini, sistem deteksi otomatis telah dikembangkan dengan memanfaatkan teknik ekstraksi fitur canggih untuk meningkatkan akurasi diagnosis [3].

Penelitian terkini telah mengeksplorasi berbagai teknik pembelajaran mesin dan metode ekstraksi fitur untuk deteksi otomatis retinopati diabetik. Local Binary Pattern (LBP) telah banyak digunakan dalam pengolahan citra medis karena kemampuannya dalam menangkap tekstur dan pola lokal pada citra retina [4][5]. Beberapa penelitian menunjukkan bahwa LBP efektif dalam klasifikasi tekstur citra retina dan memberikan hasil yang menjanjikan dalam deteksi penyakit mata [6][7]. Namun, kelemahan utama dari LBP adalah ketidakmampuannya untuk menangkap informasi fitur multi-skala dan global yang penting untuk deteksi penyakit yang lebih kompleks [8]. Di sisi lain, wavelet transform merupakan metode ekstraksi fitur yang unggul dalam analisis multi-skala dan memberikan representasi yang lebih komprehensif dari fitur citra. Penelitian menunjukkan bahwa wavelet transform dapat mengidentifikasi pola dan fitur dengan resolusi yang berbeda-beda, menjadikannya berguna untuk analisis citra medis [9] [10]. Kelemahan utama dari metode ini adalah kompleksitas komputasinya dan sensitivitas terhadap parameter yang digunakan dalam transformasi [11]. Kombinasi dari LBP dan wavelet transform dapat memanfaatkan keunggulan masing-masing metode untuk memperbaiki kelemahan yang ada, dengan LBP menangkap tekstur lokal dan wavelet transform menangkap informasi multi-skala yang lebih luas [12].

Penelitian ini akan menerapkan LBP dengan wavelet transform untuk ekstraksi fitur dan menggunakan Support Vector Machine (SVM) untuk klasifikasi [13]. Penggunaan gabungan ini bertujuan untuk meningkatkan akurasi deteksi retinopati diabetik dengan mengatasi kelemahan masing-masing metode dan memanfaatkan keunggulan yang ditawarkan. Kebaruan dari penelitian ini terletak pada menerapkan metode LBP dan wavelet transform yang tidak hanya memperbaiki kelemahan tetapi juga meningkatkan akurasi dan keandalan deteksi retinopati diabetik. Dengan menerapkan LBP dengan wavelet transform dan penggunaan SVM untuk klasifikasi akan menghasilkan metrik kinerja yang lebih tinggi dibandingkan dengan menggunakan metode-metode ini secara individu. Tujuan dari penelitian ini adalah untuk mengembangkan dan mengevaluasi pendekatan kombinasi algoritma untuk menentukan efektivitasnya dalam mendeteksi retinopati diabetik dengan akurasi dan keandalan yang tinggi

## **2 Tinjauan Literatur**

Deteksi retinopati diabetik (DR) merupakan salah satu tantangan utama dalam bidang medis, terutama mengingat implikasinya terhadap kebutaan permanen jika tidak segera didiagnosis dan ditangani. Sejumlah penelitian telah mengeksplorasi teknik-teknik deteksi otomatis menggunakan berbagai algoritma pembelajaran mesin, ekstraksi fitur, dan teknik seleksi fitur untuk meningkatkan akurasi deteksi. Dari tinjauan terhadap jurnal terkait retinopati diabetik, terdapat beberapa kesimpulan yang mendasari arah penelitian selanjutnya, khususnya yang berkaitan dengan analisis ekstraksi fitur menggunakan Local Binary Pattern (LBP) dan wavelet, serta seleksi fitur untuk deteksi DR dengan Support Vector Machine (SVM).

Penelitian pertama oleh Tyasnurita dan Pamungkas [14] menggunakan regresi logistik untuk klasifikasi retinopati diabetik berdasarkan citra retina. Mereka menyoroti pentingnya seleksi fitur yang tepat, di mana model dengan atribut lengkap menghasilkan akurasi yang lebih tinggi (80,17%) dibandingkan dengan model yang disederhanakan. Penelitian ini menunjukkan bahwa pemilihan fitur yang relevan berperan besar dalam meningkatkan performa deteksi. Sementara itu, Rachman et al. [15] membandingkan metode Euclidean untuk klasifikasi citra retina dan menekankan pentingnya preprocessing dalam meningkatkan hasil klasifikasi. Mereka menggunakan ekstraksi fitur tekstur statistik orde pertama, termasuk mean, variance, skewness, kurtosis, dan entropy. Penelitian ini menunjukkan bahwa dataset yang dioptimalkan dengan penghapusan disk optik meningkatkan akurasi klasifikasi dari 50% menjadi 64,81%. Hal ini menegaskan bahwa teknik ekstraksi fitur dan preprocessing dapat mempengaruhi akurasi klasifikasi secara signifikan. Penelitian lainnya oleh Reubun et al. [16], yang membahas prevalensi retinopati diabetik di klinik utama, tidak secara langsung mengaplikasikan teknik pembelajaran mesin, tetapi memberikan konteks mengenai tingginya prevalensi RD dan kebutuhan mendesak akan alat diagnostik otomatis yang lebih akurat. Studi ini memberikan justifikasi lebih lanjut bagi pengembangan metode deteksi otomatis berbasis

machine learning yang dapat membantu diagnosis dini. Teknik pembelajaran mesin, terutama Support Vector Machine (SVM), telah digunakan dalam beberapa penelitian untuk meningkatkan akurasi deteksi RD. Misalnya, penelitian oleh Nissen et al. [17] berhasil mencapai akurasi 94% dengan menggunakan SVM dalam mendeteksi eksudat pada citra retina. Hasil ini menunjukkan potensi SVM sebagai algoritma yang andal dalam klasifikasi RD, terutama ketika dikombinasikan dengan teknik ekstraksi fitur yang tepat. Ekstraksi fitur menggunakan Local Binary Pattern (LBP) telah terbukti efektif dalam beberapa penelitian untuk deteksi penyakit mata, termasuk glaukoma. Bibi et al. [18] menggunakan LBP untuk mendeteksi glaukoma pada citra fundus retina dan menunjukkan akurasi yang memadai untuk aplikasi medis. Metode LBP dikenal karena kemampuannya dalam menangkap informasi tekstur yang relevan dari citra, yang juga dapat diterapkan pada deteksi retinopati diabetik. Di sisi lain, teknik wavelet juga telah terbukti menjadi metode yang ampuh dalam ekstraksi fitur. Darshankumar et al.[19][20] dalam penelitiannya menggunakan CNN yang dioptimalkan dengan teknik wavelet untuk deteksi dini DR, menghasilkan akurasi yang tinggi (89%). Wavelet dapat mengekstrak fitur multi-skala, yang sangat cocok untuk menangkap variasi lokal dan global pada citra retina. Dengan menggabungkan metode LBP untuk ekstraksi tekstur dan wavelet untuk seleksi fitur, penelitian selanjutnya dapat menghasilkan model yang lebih akurat dan efisien untuk deteksi DR. LBP akan berfungsi menangkap informasi tekstur detail dari retina, sementara wavelet akan mengidentifikasi fitur-fitur penting yang tersembunyi pada berbagai skala, sehingga mengurangi dimensi fitur yang tidak relevan. Kombinasi ini, bila diterapkan dengan SVM, dapat meningkatkan akurasi deteksi DR secara signifikan, sebagaimana ditunjukkan oleh berbagai studi sebelumnya.

### 3 Metode Penelitian

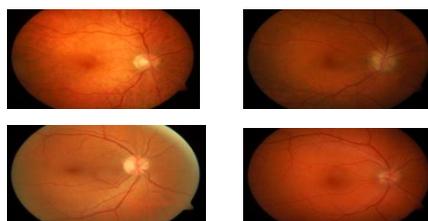
Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk menganalisis kinerja kombinasi ekstraksi fitur menggunakan Local Binary Pattern (LBP) dan wavelet transform dalam mengekstraksi fitur untuk mendeteksi retinopati diabetik. Secara keseluruhan, penelitian ini terdiri dari 5 tahapan utama, yaitu: tahap pertama mempelajari literatur dan dataset gambar retina fundus, tahap kedua preprosesing, ketiga ekstraksi fitur, tahapan klasifikasi dan tahap lima evaluasi kinerja. tahapan ini mencakup seluruh langkah yang diperlukan untuk mencapai tujuan penelitian ini. Adapun metode dalam penelitian ini dapat dilihat pada gambar 1 di bawah ini.



**Gambar 1. Metode penelitian**

#### Tahap Gambar Retina fundus

Dataset citra retina yang digunakan dalam penelitian ini diambil dari sumber dataset publik yang tersedia yaitu dataset kaggle, yang mencakup citra retina dengan berbagai tingkat keparahan retinopati diabetik. Setiap citra telah diklasifikasikan oleh para ahli mata sebagai kategori normal atau terindikasi retinopati diabetik. Gambar retina fundus yang digunakan dapat dilihat pada gambar 2 dibawah ini.



**Gambar 2. Retina fundus**

Tahap Praprosesing, dimana sebelum dilakukan ekstraksi fitur, gambar retina dilakukan preprocessing untuk meningkatkan kualitas citra. Tahapan preprocessing mencakup konversi citra ke skala abu-abu, resize gambar, normalisasi intensitas piksel, dan penghapusan noise menggunakan filter Gaussian. Dimana mengubah citra berwarna (RGB) menjadi citra skala abu-abu. Hal ini dilakukan karena informasi warna seringkali tidak diperlukan dalam proses ekstraksi fitur, di mana R, G, dan B adalah nilai intensitas dari masing-masing kanal merah, hijau, dan biru. Dengan langkah tersebut sehingga fokus bisa diarahkan pada intensitas piksel dengan formula 1 berikut;

$$I_{gray} = 0.2989 \times R + 0.5870 \times G + 0.1140 \times B \quad (1)$$

Kemudian mengubah ukuran gambar agar sesuai dengan dimensi yang dibutuhkan oleh model atau algoritma ekstraksi fitur. Ukuran gambar yang seragam memudahkan proses analisis lebih lanjut dan mengurangi beban komputasi, skala yang digunakan adalah 0.1, berarti ukuran gambar diperkecil menjadi 10% dari ukuran aslinya. Jika ukuran gambar aslinya adalah 500x500 piksel, setelah dilakukan resize dengan skala 0.1,  $500 \times 0.1 = 50$  piksel ukuran gambar yang baru akan memiliki ukuran baru 50x50 piksel. Berikut formula 2 untuk menghitung ukuran gambar setelah dilakukan resize;

$$Ukuran\ Baru = Ukuran\ Asli \times 0.1 \quad (2)$$

Fungsi: Menyesuaikan nilai intensitas piksel agar berada dalam rentang tertentu, misalnya [0, 1] atau [0, 255], untuk mengurangi variasi intensitas yang tidak relevan dan meningkatkan kontras. Di mana I adalah nilai piksel asli, I<sub>min</sub> adalah nilai intensitas piksel terendah dalam gambar, dan I<sub>max</sub> adalah nilai tertinggi. Berikut formula 3 (jika normalisasi dilakukan ke rentang [0, 1]) intensitas :

$$I_{norm} = \frac{I - I_{min}}{I_{max} - I_{min}} \quad (3)$$

Tahap Ekstaksi fitur dengan Local Binary Pattern (LBP): Metode ini digunakan untuk menangkap pola tekstur lokal dari citra retina. LBP menghasilkan vektor fitur berdasarkan distribusi tekstur yang ada di sekitar setiap piksel. sebuah piksel pusat P dalam citra grayscale dan 8 piksel tetangga di sekelilingnya. Untuk setiap piksel tetangga, kita bandingkan nilai intensitasnya dengan nilai intensitas piksel pusat P. Jika nilai intensitas tetangga lebih besar dari atau sama dengan P, kita tetapkan bit ke 1; sebaliknya, kita tetapkan bit ke 0. Bandingkan nilai intensitas dapat dilihat pada formula 4 dibawah ini;

$$LBP_i = \begin{cases} 1 & \text{jika } I_{neighbor} \geq I_{center} \\ 0 & \text{sebaliknya} \end{cases} \quad (4)$$

Hasil dari perbandingan ini membentuk sebuah pola biner 8-bit. Pola ini diinterpretasikan sebagai angka biner yang dikonversi menjadi bilangan desimal. di mana LBP<sub>i</sub> adalah bit ke-i dari pola biner dan i adalah indeks bit. Konversi biner ke desimal dapat dilihat pada formula 5 dibawah ini;

$$LBP_{decimal} = \sum_{i=0}^7 LBP_i \times 2^i \quad (5)$$

Wavelet Transform: Untuk mengatasi keterbatasan LBP dalam menangkap informasi skala besar dan global, digunakan wavelet transform. Transformasi ini memecah citra ke dalam beberapa level frekuensi yang memungkinkan ekstraksi fitur pada berbagai skala, yang selanjutnya digabungkan dengan hasil LBP. Daubechies wavelets, termasuk db4, adalah tipe wavelet yang diperkenalkan oleh Ingrid Daubechies. Jenis wavelet yang digunakan dalam kode tersebut adalah Daubechies wavelet, khususnya Daubechies 4 (dikenal sebagai 'db4'), daubechies wavelets memiliki sifat ortogonal dan dapat digunakan untuk dekomposisi sinyal dengan kualitas tinggi. Discrete Wavelet Transform (DWT), menguraikan sinyal ke dalam komponen frekuensi yang berbeda dengan menggunakan wavelet filter dan downsampling. Untuk sinyal x[n], koefisien aproksimasi cA dan koefisien detail cD dapat dihitung sebagai berikut: Koefisien Aproksimasi (cA) dapat dilihat pada formula 6 dibawah ini;

$$cD[j, k] = \sum x[n] \cdot \phi_{j,k}[n] \quad (6)$$

Di mana  $\phi_{j,k}[n]$  adalah filter low-pass yang dihasilkan dari Daubechies wavelet pada level  $j$  dan posisi  $k$ . Koefisien Aproksimasi ( $cA$ ) dapat dilihat berikut pada formula 7 berikut ini;

$$cD[j, k] = \sum_n x[n] \cdot \psi_{j,k}[n] \quad (7)$$

Di mana  $\psi_{j,k}[n]$  adalah filter high-pass yang dihasilkan dari Daubechies wavelet pada level  $j$  dan posisi  $k$ .

Tahap Klasifikasi, dimana setelah fitur diekstraksi, vektor fitur yang diperoleh diklasifikasikan menggunakan algoritma Support Vector Machine (SVM). SVM dipilih karena kemampuannya dalam menangani masalah klasifikasi dengan margin optimal. Parameter SVM dioptimalkan untuk mendapatkan model yang paling sesuai dengan data. SVM menggunakan fungsi kernel  $K(x_i, x_j)$  untuk memetakan data ke dimensi yang lebih tinggi. Berikut formula 8 untuk klasifikasi menggunakan SVM.

$$f(x) = \sum_{i=1}^n \alpha_i y_i K(X_i, X) + b \quad (8)$$

Tahap Evaluasi Kinerja, dimana kinerja model dikaji berdasarkan beberapa metrik evaluasi, yaitu akurasi, precision, recall, dan F1-score. Evaluasi ini dilakukan melalui metode validasi silang (cross-validation) untuk memastikan hasil yang generalisasi dan akurat. Secara matematis, jika TP adalah True Positive, TN adalah True Negative, FP adalah False Positive, dan FN adalah False Negative, maka rumusnya dapat ditulis pada formula 9 sebagai berikut:

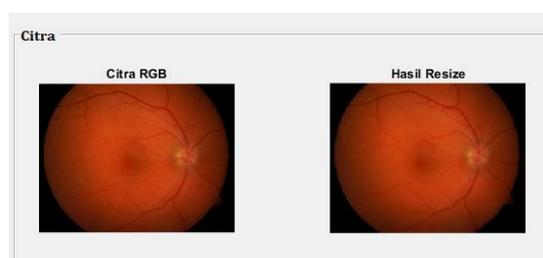
$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \times 100 \% \quad (9)$$

#### 4 Hasil dan Pembahasan

Proses ekstraksi fitur citra dalam penelitian ini terdiri dari input citra dan tahap ekstraksi fitur pada citra dengan metode local binary pattern, kemudian fitur gambar akan diklasifikasi dengan support vector machine. Analisis penentuan retinopathi diabetes dengan menggunakan matlab.

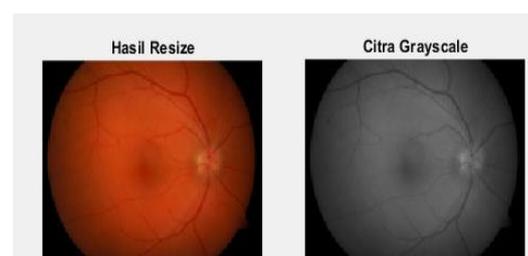
Tahap Preprocessing dalam penelitian menganalisis gambar fundus mata guna mendeteksi retinopati diabetik menggunakan dataset yang disediakan dataset Kaggle. Retinopati diabetik merupakan komplikasi serius dari diabetes yang berpotensi menyebabkan kebutaan. Melalui penelitian ini, kami menggunakan 168 gambar dari dataset Kaggle untuk melakukan analisis awal. Dimana data latih 100 sebesar gambar dan data uji 68 gambar retina fundus. Data yang sudah ready kemudian dimasukkan kedalam aplikasi untuk di lakukan processing berikut formula membaca data yang sudah disiapkan;

Resize gambar sebelum proses ekstraksi bertujuan untuk memastikan konsistensi ukuran, mengurangi beban komputasi, mempercepat pelatihan model, menyesuaikan input model, dan mengurangi noise. Mengubah ukuran dimensi gambar dengan faktor skala 0.1, menyimpannya, dan menampilkannya. Dengan faktor skala 0.1, ukuran dimensi gambar akan menjadi 10% dari ukuran aslinya. Dimana gambar dengan dimensi 1500 x 1152 kemudian di resize dengan skala 0.1 menjadi dimensi 150 x 115. Hasil resize dimensi gambar dapat dilihat pada gambar 3 di bawah ini.



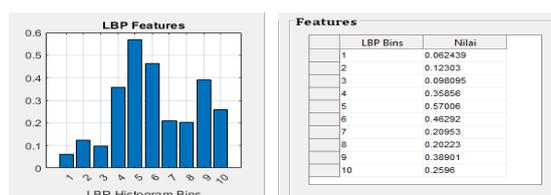
Gambar 3. Hasil resize skala 0.1

Mengonversi gambar berwarna ke grayscale penting untuk mengurangi dimensi data dari tiga saluran (RGB) menjadi satu saluran, sehingga mengurangi kompleksitas dan mempercepat proses pemrosesan. Berikut hasil nya dapat dilihat pada gambar 4 dibawah ini;



**Gambar 4. Hasil konversi grayscale**

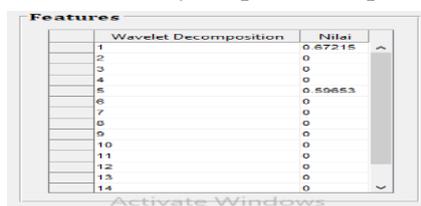
Tahap ekstraksi fitur Local binary pattern Proses selanjutnya melakukan ekstraksi fitur dengan teknik local binary pattern, Ekstraksi fitur menggunakan Local Binary Pattern (LBP) pada gambar fundus retinopati diabetik adalah teknik yang digunakan untuk menangkap tekstur lokal dari gambar. Fitur LBP dapat digunakan untuk mengidentifikasi pola-pola tekstur yang relevan dengan adanya retinopati diabetes. Berikut hasil ekstraksi fitur dengan nilai bins LBP dan Histogram nya, hasilnya dapat dilihat pada gambar 5 dibawah ini;



**Gambar 5. Hasil ekstraksi histogram dan nilai bins LBP**

LBP Bins merupakan nomor bin atau segmen dalam histogram LBP yang digunakan untuk merepresentasikan frekuensi pola biner tertentu yang ditemukan dalam suatu area atau blok gambar. Nilai pada setiap bin dalam histogram LBP menunjukkan berapa kali pola biner tersebut muncul dalam gambar yang sedang dianalisis. Nilai-nilai ini mencerminkan distribusi tekstur dalam gambar; bin dengan nilai tinggi menandakan bahwa pola LBP tersebut dominan. Perbedaan nilai antar bin mengindikasikan variasi tekstur dalam gambar; nilai yang seragam menunjukkan tekstur yang konsisten, sementara variasi besar antar bin menunjukkan kompleksitas tekstur yang lebih tinggi. Sebagai contoh, pada bin ke-5, nilai sebesar 0.51707 menunjukkan bahwa pola biner yang sesuai dengan bin tersebut muncul lebih sering dibandingkan dengan pola biner di bin lainnya, yang menjadikannya fitur penting dalam pengenalan objek atau klasifikasi gambar.

Setelah ekstraksi fitur menggunakan Local Binary Pattern (LBP), dilakukan seleksi fitur lebih lanjut menggunakan transformasi wavelet untuk citra retina fundus pada kasus diabetic retinopathy. Transformasi wavelet memecah sinyal atau citra menjadi komponen frekuensi yang berbeda untuk mengisolasi detail tekstur yang relevan, hasil nya dapat dilihat pada gambar 6 dibawah ini;



**Gambar 6. Hasil ekstraksi wavelet transformasi**

Wavelet decomposition yang ditampilkan, hanya dua baris (baris 1 dan 5) yang memiliki nilai tidak nol, yaitu 0.67215 pada baris 1 dan 0.59653 pada baris 5. Nilai-nilai ini menunjukkan bahwa hanya dua komponen frekuensi tersebut yang dianggap signifikan atau relevan setelah proses transformasi wavelet dilakukan. Dalam transformasi wavelet, citra atau sinyal diuraikan ke dalam beberapa sub-komponen frekuensi, dan hanya komponen yang memiliki informasi penting yang dipertahankan.

Tahap Klasifikasi Support machine learning (SVM), Setelah melakukan seleksi fitur menggunakan transformasi wavelet, di mana hanya dua fitur signifikan yang diidentifikasi (nilai 0.67215 dan 0.59653), Support Vector Machine (SVM) digunakan untuk klasifikasi. Proses ini dimulai dengan pelatihan model SVM menggunakan fitur yang telah dipilih untuk menemukan hyperplane yang memisahkan dua kelas, yaitu diabetik retinopati dan non-diabetik retinopati. SVM

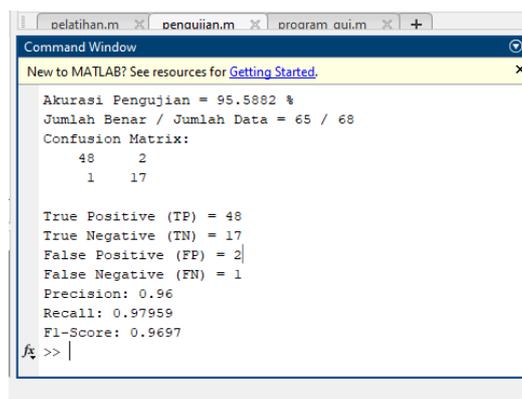
mengoptimalkan fungsi objektif yang menggabungkan regularisasi bobot dan kesalahan klasifikasi untuk menentukan hyperplane dengan margin maksimal. Setelah model terlatih, keputusan untuk klasifikasi data baru dibuat berdasarkan tanda dari fungsi keputusan  $f(x)=wTx+bf(x) = w^T x + bf(x)=wTx+b$ . Model dievaluasi dengan mengukur akurasi dan metrik kinerja lainnya pada data uji untuk memastikan kemampuannya dalam memprediksi kelas dengan akurat, berikut pada gambar 7 klasifikasi DR.



**Gambar 7. Hasil klasifikasi dengan SVM**

Dari gambar 7 diatas terlihat hasil klasifikasi dari image086.png dideteksi diabetetic retinopathy artinya gambar retina tersebut ada kelainan tertentu atau tidak normal

Tahap Evaluasi confusion matrik, model SVM digunakan untuk memprediksi label kelas dari setiap sampel dalam data uji berdasarkan fitur yang telah dipilih. Akurasi dihitung sebagai rasio antara jumlah prediksi yang benar dan total jumlah sampel. Confusion matrix merupakan representasi tabular yang menunjukkan distribusi hasil prediksi model ke dalam empat kategori utama yang dapat dilihat pada gambar 8 dibawah ini.



**Gambar 8. Hasil evaluasi**

Dari gambar 8 diatas untuk mendapatkan hasil evaluasi dapat implementasikan pada Rumus akurasi: Akurasi = (Jumlah Benar / Jumlah Data  $\times$  100 %, dari total 68 data uji, model memprediksi 66 data dengan benar. Akurasi =  $(66 / 65) \times 100 = 95.5882\%$ .

Hasil Confusion Matrix:

```
48  2
1  17
```

Confusion matrix merupakan representasi tabular yang menunjukkan distribusi hasil prediksi model ke dalam empat kategori utama. True Positive (TP) sebanyak 48 mengindikasikan jumlah sampel yang sebenarnya positif dan diprediksi positif oleh model, misalnya model memprediksi "positif" dan faktanya memang "positif". True Negative (TN) sebanyak 17 menunjukkan jumlah sampel yang sebenarnya negatif dan diprediksi negatif, misalnya model memprediksi "negatif" dan faktanya memang "negatif". False Positive (FP) sebanyak 2 adalah jumlah sampel yang sebenarnya negatif tetapi diprediksi positif oleh model, yang disebut juga error tipe I, contohnya model memprediksi "positif" padahal faktanya "negatif". False Negative (FN) sebanyak 1 adalah jumlah

sampel yang sebenarnya positif tetapi diprediksi negatif oleh model, yang disebut error tipe II, misalnya model memprediksi "negatif" padahal faktanya "positif".

Precision mengukur seberapa banyak dari prediksi positif yang benar-benar positif. Rumus  $Precision = TP / (TP+FP)$  dimana  $Precision = 48 / (48+2) = 48/50 = 0.96 \%$ . Artinya, dari 50 prediksi positif yang dihasilkan model, 96% di antaranya benar. Recall (sensitivitas atau true positive rate) mengukur seberapa baik model mendeteksi semua sampel yang sebenarnya positif. Rumus  $Recall = TP / (TP+FN)$  dimana  $Recall = 48 / (48+1) = 48/49 \approx 0.97959 \%$ . F1-Score yaitu metrik gabungan yang menggabungkan precision dan recall untuk memberikan gambaran performa model secara seimbang.  $F1-Score = 2 \times (Precision \times Recall) / (Precision + Recall)$ , dimana  $F1-Score = 2 \times (0.96 \times 0.97959) / (0.96 + 0.97959) \approx 0.9697 \%$ .

## 5 Kesimpulan

Berdasarkan analisa ekstraksi fitur dengan LBP mendapatkan fitur yang bervariasi, terdapat ekstraksi fitur tertinggi pada baris ke 5 dengan nilai 0.57006, artinya fitur tersebut yang paling dominan. Dimana evaluasi didapat berupa Akurasi Tinggi (95.59%) dimana model mampu mengklasifikasikan data dengan benar dalam sebagian besar kasus. Precision Tinggi (96%) dimana model dapat diandalkan dalam memprediksi sampel positif dengan tingkat kesalahan yang rendah. Recall Tinggi (97.96%) dimana model efektif dalam mendeteksi semua sampel yang sebenarnya positif. F1-Score yang Seimbang (96.97%) dimana keseimbangan antara precision dan recall menunjukkan bahwa model ini andal dan efisien dalam berbagai aplikasi klasifikasi. Saran untuk peneliti selanjutnya perlunya meningkatkan jumlah dataset yang lebih besar agar terbatas pada generalisasi, perlunya optimasi parameter model agar sesuai dengan karakteristik data dan Penggunaan Teknik Feature Engineering Tambahan seperti Histogram of Oriented Gradients (HOG) atau Gabor filters) untuk meningkatkan akurasi dan hasil prediksi.

## Referensi

- [1] E. Abdelmaksoud, S. El-sappagh, S. Barakat, T. Abuhmed, and M. Elmogy, "Automatic Diabetic Retinopathy Grading System Based on Detecting Multiple Retinal Lesions," *IEEE Access*, no. VI, pp. 15939–15960, 2021, doi: 10.1109/ACCESS.2021.3052870.
- [2] N. Mazlan, H. Yazid, H. Arof, and H. Mohd, "Automated Microaneurysms Detection and Classification using Multilevel Thresholding and Multilayer Perceptron," *J. Med. Biol. Eng.*, no. 0123456789, 2020, doi: 10.1007/s40846-020-00509-8.
- [3] D. Parashar and D. K. Agrawal, "Automated Classification of Glaucoma Stages Using Flexible Analytic Wavelet Transform From Retinal Fundus Images," *IEEE*, vol. 1748, no. c, 2020, doi: 10.1109/JSEN.2020.3001972.
- [4] M. Jebran P and S. Gupta, "Microaneurysm detection by multiple feature subset extraction and selection based on SVM-weights and Genetic Algorithm-Neural Network," *Int. Conf. Adv. Comput. Commun. Syst.*, pp. 129–134, 2021, doi: 10.1109/ICACCS51430.2021.9441746.
- [5] M. Miron, A. Culea-florescu, and S. Moldovanu, "Diabetic Retinopathy Image Classification Using Machine Learning and Local Binary Patterns Features," *2023 8th Int. Symp. Electr. Electron. Eng.*, pp. 136–139, 2023, doi: 10.1109/ISEEE58596.2023.10310398.
- [6] D. J. Derwin, S. T. Selvi, and O. J. Singh, "Discrimination of microaneurysm in color retinal images using texture descriptors," *Signal, Image Video Process.*, vol. 14, no. 2, pp. 369–376, 2020, doi: 10.1007/s11760-019-01566-6.
- [7] B. B. Narhari, B. K. Murlidhar, A. D. Sayyad, and G. S. Sable, "Automated diagnosis of diabetic retinopathy enabled by optimized thresholding-based blood vessel segmentation and hybrid classifier," *Bio-Algorithms and Med-Systems*, vol. 17, no. 1, pp. 9–23, 2021.

- [8] N. Matthew, F. Kwan, A. Dewi, and F. Indra, "Comparing Local Local Binary Binary Pattern Pattern and and Gray Gray Level Level Co-occurrence Matrix for Feature Extraction in Diabetic Retinopathy Classification Matrix for Feature Extraction in Diabetic Retinopathy Classificati," *Procedia Comput. Sci.*, vol. 227, pp. 355–363, 2023, doi: 10.1016/j.procs.2023.10.534.
- [9] P. K. Muhuri, Z. Ashraf, and S. Goel, "A Novel Image Steganographic Method based on Integer Wavelet Transformation and Particle Swarm Optimization," *Appl. Soft Comput. J.*, vol. 92, p. 106257, 2020, doi: 10.1016/j.asoc.2020.106257.
- [10] C. Tian, M. Zheng, W. Zuo, B. Zhang, Y. Zhang, and D. Zhang, "Multi-stage image denoising with the wavelet transform," *Sci. Pattern*, vol. 134, 2023.
- [11] H. A. Agboola and J. E. Zaccheus, "Wavelet image scattering based glaucoma detection," *BMC Biomed. Eng.*, pp. 1–11, 2023, doi: 10.1186/s42490-023-00067-5.
- [12] S. Gayathri, V. P. Gopi, and P. Palanisamy, "Automated classification of diabetic retinopathy through reliable feature selection," *Phys. Eng. Sci. Med.*, vol. 43, no. 3, pp. 927–945, 2020, doi: 10.1007/s13246-020-00890-3.
- [13] R. K. Patel and M. Kashyap, "Automated screening of glaucoma stages from retinal fundus images using BPS and LBP based GLCM features," *Int. J. Imaging Syst. Technol.*, vol. 33, no. 1, pp. 246–261, 2022, doi: 10.1002/ima.22797.
- [14] R. Tyasnurita and A. M. Y. Pamungkas, "Deteksi Diabetik Retinopati menggunakan Regresi Logistik," *Ilk. J. Ilm.*, vol. 12, no. 2, pp. 130–135, 2020.
- [15] Y. F. Rachman, K. Kusriani, and H. Alfatta, "Klasifikasi Citra Digitalretina Penderita Diabetes Retinopati Menggunakan Metode Euclidean," *DoubleClick J. Comput. Inf. Technol.*, vol. 3, no. 2, pp. 75–82, 2020.
- [16] R. J. S. Reubun, C. L. Tamtallahuru, and M. Yunita, "Prevalensi Retinopati Diabetik Pada Penderita Diabetes Melitus Di Klinik Utama Provinsi Maluku," *Care J. Ilm. Ilmu Kesehat.*, vol. 10, no. 3, pp. 366–376, 2022.
- [17] T. P. H. Nissen *et al.*, "Performance of a Support Vector Machine Learning Tool for Diagnosing Diabetic Retinopathy in Clinical Practice," *J. Pers. Med.*, pp. 1–13, 2023.
- [18] I. Bibi, J. Mir, and G. Raja, "Automated detection of diabetic retinopathy in fundus images using fused features," *Phys. Eng. Sci. Med.*, vol. 43, no. 4, pp. 1253–1264, 2020, doi: 10.1007/s13246-020-00929-5.
- [19] J. Gao, B. Wang, Z. Wang, Y. Wang, and F. Kong, "A wavelet transform-based image segmentation method," *Optik (Stuttg.)*, vol. 208, no. December 2019, p. 164123, 2020, doi: 10.1016/j.ijleo.2019.164123.
- [20] M. A. I. Mahmood, N. Aktar, and M. F. Kader, "A hybrid approach for diagnosing diabetic retinopathy from fundus image exploiting deep features," *Heliyon*, vol. 9, no. 9, pp. 1–14, 2023, doi: 10.1016/j.heliyon.2023.e19625.