

OPTIMIZATION OF LBP TEXTURE FEATURE EXTRACTION USING CORRELATION AND MI FOR SVM BASED DIABETIC RETINOPATHY CLASSIFICATION

OPTIMASI EKSTRAKSI FITUR TEKSTUR LBP MENGGUNAKAN KORELASI DAN MI UNTUK KLASIFIKASI RETINOPATI DIABETIK BERBASIS SVM

Loneli Costaner¹, Lisnawita², Guntoro³

Fakultas Ilmu Komputer^{1,2,3}

Universitas Lancang Kuning, alan Yos Sudarso KM. 8, Rumbai, Pekanbaru, Riau
email lonelicostaner@unilak.ac.id¹, Lisnawita@unilak.ac.id², Guntoro@unilak.ac.id³

Abstract – Diabetic retinopathy (DR) is a leading cause of blindness, making early detection based on retinal fundus images crucial. This study proposes a DR classification method with a primary contribution in feature optimization: integrating the LBP Contrast feature with a Local Binary Pattern (LBP) histogram and performing hybrid feature selection based on Mutual Information (MI) to assess relevance and correlation analysis to reduce redundancy. This method was tested using 168 images from the public Messidor dataset, with 100 images for training and 68 for testing to evaluate performance. Classification was performed using a Support Vector Machine (SVM) with a linear kernel, where model performance was evaluated before and after optimization to measure the significance of the improvement. The results showed a significant improvement after optimization, with accuracy increasing from 88% to 94%, recall increasing from 88% to 100%, and F1-score increasing from 0.92 to 0.96. Although precision decreased slightly from 96% to 93%, increasing recall to 100% is considered more crucial in a medical context as it minimizes the risk of missed positive cases. These findings confirm that the proposed feature optimization approach can significantly improve the accuracy and reliability of the DR detection system, offering potential clinical relevance for supporting early intervention.

Keywords - Diabetic Retinopathy, Local Binary Pattern, Mutual Information, SVM, Fundus Image.

Abstrak – Retinopati Diabetik (DR) merupakan salah satu penyebab utama kebutaan, sehingga deteksi dini berbasis citra fundus retina sangat penting. Penelitian ini mengusulkan sebuah metode klasifikasi DR dengan kontribusi utama pada optimasi fitur, yaitu mengintegrasikan fitur LBP Contrast dengan histogram Local Binary Pattern (LBP) dan melakukan seleksi fitur hibrida berbasis Mutual Information (MI) untuk menilai relevansi serta analisis korelasi untuk mengurangi redundansi. Metode ini diuji menggunakan 168 citra dari dataset publik Messidor, dengan 100 citra untuk pelatihan dan 68 untuk pengujian guna mengevaluasi performa. Klasifikasi dilakukan menggunakan Support Vector Machine (SVM) dengan kernel linier, di mana performa model dievaluasi sebelum dan sesudah optimasi untuk mengukur signifikansi peningkatannya. Hasil menunjukkan peningkatan yang signifikan setelah optimasi dengan akurasi naik dari 88% menjadi 94%, recall meningkat dari 88% menjadi 100%, dan F1-score dari 0,92 menjadi 0,96. Meskipun presisi sedikit menurun dari 96% menjadi 93%, peningkatan recall menjadi 100% dianggap lebih krusial dalam konteks medis karena mampu meminimalkan risiko kasus positif yang terlewat. Temuan ini menegaskan bahwa pendekatan optimasi fitur yang diusulkan mampu meningkatkan akurasi dan keandalan sistem deteksi DR secara signifikan, menawarkan potensi relevansi klinis untuk mendukung intervensi dini.

Kata Kunci - Retinopati Diabetik, Local Binary Pattern, Mutual Information, SVM, Citra Fundus.

I. PENDAHULUAN

Retinopati Diabetik (DR) merupakan salah satu komplikasi paling serius dari penyakit diabetes melitus yang dapat menyebabkan kerusakan permanen pada retina, hingga berujung pada kebutaan. Menurut data dari World Health Organization (WHO), kasus kebutaan akibat DR terus mengalami peningkatan secara global, terutama di negara berkembang dengan tingkat prevalensi diabetes yang tinggi [1][2]. Kondisi ini umumnya berkembang secara perlahan dan asimtomatik pada tahap awal, sehingga deteksi dini menjadi sangat krusial untuk mencegah kerusakan retina yang tidak dapat diperbaiki. Pemahaman terhadap manifestasi visual DR dan upaya identifikasi otomatis melalui teknologi berbasis citra medis menjadi semakin penting dalam konteks pelayanan kesehatan modern [3].

Kemajuan dalam bidang teknologi pengolahan citra digital dan kecerdasan buatan telah membuka peluang besar untuk mendukung diagnosis otomatis Retinopati Diabetik melalui analisis citra fundus retina [4][5]. Citra fundus merupakan hasil pemotretan bagian dalam mata yang menampilkan struktur penting seperti pembuluh darah, makula, dan disk optik. Pada penderita DR, citra fundus menunjukkan karakteristik khas seperti mikroaneurisma, perdarahan retina, eksudat keras, dan perubahan vaskular lainnya [6]. Namun, karakteristik ini sering kali muncul dalam skala kecil, kontras rendah, dan tersebar secara tidak teratur, sehingga menimbulkan tantangan besar dalam proses analisis otomatis [7][8][9]. Di sinilah pentingnya teknik ekstraksi fitur untuk menangkap pola visual yang relevan dan membedakan antara citra normal dan citra dengan indikasi DR [10]. Berbagai metode ekstraksi fitur telah digunakan dalam penelitian sebelumnya untuk mendeteksi pola pada citra fundus, salah satunya menggunakan algoritma Local Binary Pattern (LBP) [11][12]. LBP dikenal sebagai metode yang efektif untuk mengekstraksi informasi tekstur lokal dengan representasi histogram yang ringkas [13]. Teknik ini memetakan nilai intensitas piksel di sekitar titik pusat menjadi kode biner, sehingga menghasilkan fitur yang mencerminkan tekstur mikro pada citra. Namun demikian, LBP standar memiliki keterbatasan, yaitu menghasilkan fitur yang sangat banyak, bersifat redundan, dan tidak semua fitur tersebut bersifat diskriminatif terhadap kelas target [14][15][16][17][18]. Kondisi ini dapat menyebabkan menurunnya akurasi klasifikasi serta meningkatkan beban komputasi sistem.

Keterbatasan ini mengarah pada adanya research gap yang jelas. Banyak studi sebelumnya cenderung hanya menggunakan histogram LBP standar tanpa optimasi lanjut. Kombinasi LBP dengan fitur statistik tekstur lainnya seperti kontras lokal masih jarang dieksplorasi secara sistematis. Lebih lanjut, strategi untuk mengatasi redundansi dan irrelevansi fitur LBP melalui seleksi fitur hibrida berbasis Mutual Information (MI) dan korelasi belum banyak diterapkan dalam domain deteksi DR. Berdasarkan celah tersebut, penelitian ini diajukan untuk menjawab beberapa pertanyaan penting. Pertama, apakah penggabungan fitur histogram LBP dengan fitur LBP Contrast dapat meningkatkan kualitas representasi tekstur untuk klasifikasi diabetic retinopathy (DR). Kedua, bagaimana efektivitas metode seleksi fitur berbasis Mutual Information (MI) dan korelasi dalam memilih sub-set fitur LBP yang paling informatif dan tidak redundan. Ketiga, seberapa signifikan peningkatan performa klasifikasi dalam hal akurasi, recall, dan F1-score yang dapat dicapai oleh model SVM setelah fitur LBP dioptimasi. Untuk mengatasi masalah tersebut, penelitian ini mengusulkan sebuah kerangka kerja optimasi fitur yang dirancang untuk meningkatkan akurasi dan efisiensi proses klasifikasi DR berbasis citra fundus. Pendekatan ini dimulai dari penggabungan histogram LBP dengan fitur LBP Contrast, yaitu ukuran variasi lokal dari intensitas piksel yang memberikan informasi tambahan tentang heterogenitas tekstur pada citra fundus [19][15]. Selanjutnya, dilakukan seleksi fitur berbasis analisis statistik (seperti nilai rata-rata, standar deviasi, *p-value*, *Cohen's d*, dan *False Discovery Rate*) serta Mutual Information untuk mengukur kekuatan hubungan antara fitur dan label kelas. Selain itu, proses reduksi korelasi antar fitur digunakan untuk menghindari duplikasi informasi dan memastikan hanya fitur yang benar-benar relevan yang digunakan dalam proses klasifikasi [20][21].

Berdasarkan latar belakang tersebut, fokus utama penelitian ini adalah mengembangkan metode optimasi fitur tekstur berbasis LBP pada citra fundus untuk mengklasifikasi Retinopati Diabetik. Pendekatan ini tidak hanya menggabungkan informasi tekstur dan kontras, tetapi juga melakukan seleksi fitur yang relevan dan menghindari redundansi melalui evaluasi statistik dan korelasi antar fitur. Diharapkan, penelitian ini dapat menghasilkan sistem klasifikasi berbasis machine learning yang lebih akurat, efisien, dan dapat diandalkan dalam konteks aplikasi klinis nyata untuk mendukung diagnosis dini Retinopati Diabetik.

II. SIGNIFIKASI STUDI

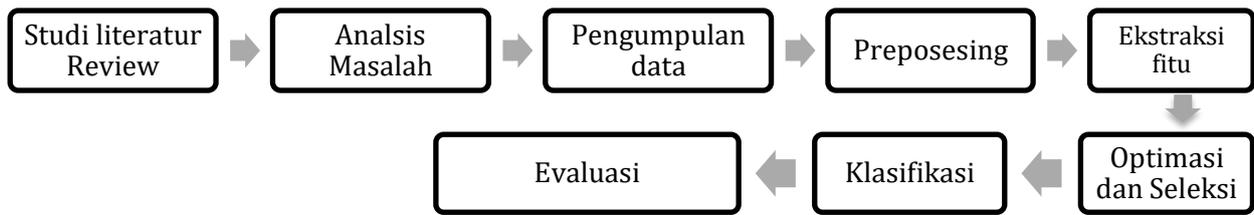
Penelitian ini memberikan kontribusi signifikan dengan mengembangkan sebuah metode deteksi DR yang tidak hanya akurat, tetapi juga efisien dan dapat diinterpretasikan. Dari sisi nilai kebaruannya terletak pada perancangan kerangka kerja optimasi fitur hibrida. Metode ini memperkaya representasi tekstur dengan mengintegrasikan histogram LBP dan LBP Contrast, lalu secara sistematis menyaringnya menggunakan MI untuk relevansi dan analisis korelasi untuk mengurangi redundansi. Pendekatan ini menghasilkan model yang lebih transparan dan efisien secara komputasi, menjadi alternatif yang kuat bagi metode deep learning yang bersifat "kotak hitam". Implikasi praktis dan klinis dari penelitian ini sangat relevan, dimana capaian pada recall 100%, model ini bisa dikatakan handal untuk berfungsi sebagai alat skrining otomatis di layanan kesehatan primer, membantu menandai kasus yang memerlukan rujukan ke dokter spesialis. Hal ini berpotensi besar mengurangi beban kerja tenaga medis dan mempercepat alur diagnosis. Karena tidak memerlukan sumber daya komputasi tinggi, sistem ini sangat mungkin diadopsi di rumah sakit atau klinik dengan sumber daya terbatas. Pada akhirnya, dengan memfasilitasi deteksi dini yang akurat, penelitian ini berkontribusi langsung pada tujuan kesehatan masyarakat yang lebih besar, yaitu mencegah kebutaan permanen akibat komplikasi diabetes.

A. Studi literatur

Penelitian dalam deteksi DR berbasis citra fundus telah mengalami kemajuan signifikan dalam lima tahun terakhir, dengan berbagai pendekatan yang menekankan pada ekstraksi fitur dan klasifikasi. Beberapa studi terdahulu telah memberikan kontribusi yang signifikan namun menyisakan ruang untuk perbaikan. Penelitian oleh Jadhav dkk (2021) dan Yadav dkk (2022) memang menunjukkan akurasi tinggi melalui deep learning dan transfer learning, namun tidak mengeksplorasi fitur tekstur klasik seperti LBP dan cenderung bersifat "black box" tanpa interpretasi fitur yang jelas [22][23]. Sementara itu, adrimen dkk (2021) dan Kundu dkk (2023) menggunakan LBP, tetapi hanya sebatas histogram tanpa penggabungan contrast atau seleksi fitur, yang menyebabkan potensi redundansi dan lemahnya efisiensi klasifikasi [24][1]. Di sisi lain, pendekatan seleksi fitur menggunakan MI dan korelasi telah terbukti efektif dalam studi Zhou dkk (2022), namun belum diterapkan dalam domain citra fundus [25]. Inspirasi juga datang dari Malhi dkk (2023), yang menegaskan bahwa kombinasi LBP dan analisis korelasi mampu memperkaya deskripsi tekstur, meskipun tidak secara langsung digunakan dalam deteksi DR [1][26]. Berdasarkan hasil telaah literatur, masih terdapat sejumlah celah penting yang belum terisi secara optimal.

B. Metodologi Penelitian

Tahapan tahapan dalam penelitian ekstraksi fitur gambar fundus pada DR dapat dilihat dilihat pada gambar dibawah ini.



Gambar 1 Tahapan Penelitian

Gambar diatas merupakan tahapan penelitian berupa studi literatur, analisis masalah, pengumpulan data, preprocessing, optimasi dan seleksi, klasifikasi dan evaluasi. Berikut penjelasan tahapan penelitian untuk klasifikasi dan optimasi.

1. Studi literatur dan Analisis masalah

Tahap awal dilakukan dengan mengkaji literatur terkini terkait ekstraksi fitur LBP, teknik optimasi fitur berbasis Mutual Information dan korelasi, serta penerapan klasifikasi SVM dalam diagnosis berbasis citra retina. Analisis masalah dilakukan untuk mengidentifikasi keterbatasan pendekatan sebelumnya.

2. Pengumpulan data

Dataset yang digunakan adalah Messidor yang berisi 168 citra fundus retina. Data dibagi menjadi 100 citra untuk pelatihan, 68 citra untuk pengujian. Pemilihan dataset didasarkan pada ketersediaan label dan kualitas citra medis yang representatif.

3. Preprocessing

Tujuan tahap ini adalah standarisasi dan efisiensi komputasi. Ada beberapa langkah pada tahap preprocessing antara resize mengubah dimensi citra dari 1500×1152 menjadi 300×300 piksel untuk menstandarkan ukuran semua gambar. Kemudian gambar dikonversi citra RGB menjadi grayscale untuk mengurangi dimensi data dari 3 channel ke 1 channel yang dibutuhkan untuk intensitas pixel analisis tekstur serta mengubah skala nilai intensitas pixel menjadi 0,1 sehingga tidak bias.

$$Grayscale : I_{gray} = 0.299R + 0.587G + 0.114B \tag{1}$$

$$Normalisasi : I_{norm} = I_{gray} / 255 \tag{2}$$

4. Ekstraksi fitur

Ekstraksi fitur tekstur dilakukan menggunakan histogram LBP untuk menghitung distribusi nilai pola lokal biner di seluruh citra dan LBP Contrast untuk menghitung variasi lokal intensitas sebagai pelengkap histogram. LBP dihitung menggunakan radius = 1 dan 8 tetangga. Hasilnya berupa vektor fitur histogram dan nilai kontras yang mewakili struktur tekstur retina.

$$Local\ Binay\ Pattern : LBP_{P,R}(x_c, y_c) = \sum_{p=0}^{P-1} s(i_p - i_c) \cdot 2^p \tag{3}$$

$$Histogram\ LBP : H(k) = \sum_{i,j} \delta(LBP(i, j) = k), \quad k = 0, 1, \dots, 255 \tag{4}$$

$$LBP\ Contrast : Contrast = \sqrt{\frac{1}{P} \sum_{p=0}^{P-1} (i_p - i_c)^2} \tag{5}$$

5. Optimasi dan seleksi

Langkah ini bertujuan menyaring fitur yang paling relevan dan informatif, penggabungan fitur histogram LBP dan LBP Contrast, kemudian melakukan analisis statistik fitur dengan Mean, Standar Deviasi, p-value (uji-t), Cohen’s d, False Discovery Rate (FDR), Coefficient of Variation (CV). Sedangkan Mutual Information (MI) untuk menilai kekuatan hubungan fitur terhadap label kelas. Selanjutnya dilakukan reduksi korelasi fitur, dimana fitur yang memiliki korelasi tinggi ($r > 0.85$) dieliminasi agar tidak redundant.

$$a. \text{Penggabungan fitur} : F_{gabungan} = [H1, H2, \dots, Hn, Contrast] \tag{6}$$

b. Evaluasi statistic fitur

$$\text{Mean : } \mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (7)$$

$$\text{Standar deviasi } \sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (8)$$

$$\text{c. Mutual Informati } MI(X; Y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right) \quad (9)$$

$$\text{d. Korelasi pearson } r_{xy} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} \quad (10)$$

6. Klasifikasi

Klasifikasi dilakukan dalam dua skenario, pertama menggunakan fitur tanpa optimasi (baseline) kedua menggunakan fitur yang telah dioptimasi. Algoritma yang digunakan adalah SVM dengan kernel linier, karena sesuai untuk dataset berdimensi menengah cepat dan mudah diinterpretasikan dan stabil terhadap overfitting bila disertai seleksi fitur

$$\text{Fungsi hiperplane } f(x) = wTx + b \quad (11)$$

$$\text{Fungsi optimasi } \min_{w, b} \frac{1}{2} \|w\|^2 + C \sum \xi_i \quad (12)$$

7. Metrik evaluasi

Evaluasi performa model dilakukan dengan menggunakan confusion matrix dengan menampilkan jumlah True Positive (TP), False Positive (FP), False Negative (FN), True Negative (TN)

Metrik Klasifikasi:

Akurasi : $(TP + TN) / (TP + FP + FN + TN)$

Presisi : $TP / (TP + FP)$

Recall : $TP / (TP + FN)$

F1 Score : $F1 = 2 \cdot (\text{Precision} \cdot \text{Recall} / (\text{Precision} + \text{Recall}))$

Hasil persentasi evaluasi metrik akan dibandingkan dari ekstraksi fitur tanpa optimasi dengan ekstraksi fitur yang sudah dioptimasi dan seleksi sehingga dapat dilihat performa mana yang lebih baik.

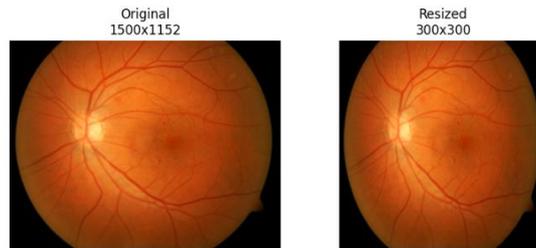
III. HASIL DAN PEMBAHASAN

A. Dataset

Penelitian ini menggaunakan dataset publik, yang secara luas digunakan dalam studi deteksi dan klasifikasi Retinopati Diabetik. Dataset ini terdiri dari 168 citra fundus retina, yang masing masing telah diberi anotasi kelas, yaitu kelas normal dan kelas retinopati diabetik.

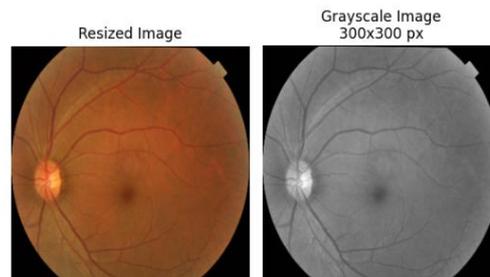
B. Praproses Citra

Sebelum dilakukan proses ekstraksi fitur, seluruh citra fundus dalam dataset terlebih dahulu melalui tahapan praproses guna meningkatkan konsistensi data serta efesiensi pemrosesan. Ada dua tahapan praproses citra yang dilakukan dalam penelitian ini, yang pertama mengubah ukuran citra original 1500×1152 pixel menjadi 300×300 piksel sehingga mengurangi beban komputasi yang tinggi dengan visual pada gambar berikut.



Gambar 2. Praproses citra resize

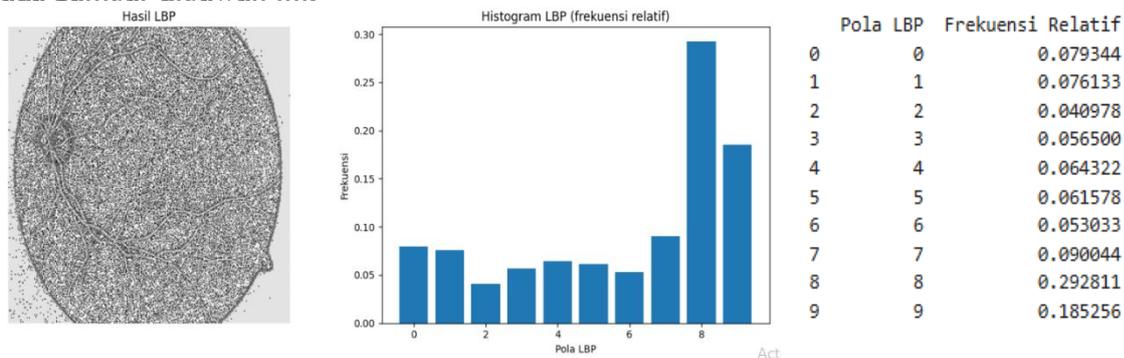
Praproses kedua yaitu mengkonversikan citra kedalam format grayscale (citra skala abu abu), hal ini dilakukan untuk menyederhanakan representasi citra dari format RGB (Red, green dan Blue) menjadi satu saluran intensitas piksel yang dapat dilihat pada gambar dibawah ini.



Gambar 3. Praproses citra grayscale

C. Ekstraksi Fitur

LBP merupakan metode ekstraksi fitur tekstur yang bekerja dengan membandingkan intensitas piksel pusat dengan piksel-piksel sekitarnya dalam pola lingkaran dengan parameter radius 1 piksel dan neighbors 8 titik yang memiliki keseimbangan pada tekstur. Hasil ekstraksi fitur dapat dilihat pada gambar dibawah ini:



Gambar 4. Ekstraksi fitur tekstur gambar fundus

Dari gambar ekstraksi fitur diatas, terlihat gambar histogram LBP yang memiliki dua sumbu, ada sumbu X (bagian bawah) yaitu pola LBP dimana ketika menggunakan parameter radius 1 dan 8 neighbors akan tampil 10 label pola, 0-8 mewakili pola uniform dan pola ke 9 kusus mewakili semua pola non uniform. Sedangkan sumbu Y atau frekuensi yang menunjukkan frekuensi kemunculan masing masing pola LBP pada citra. Terdapat histogram dengan pola 8 memiliki frekuensi tertinggi 0.29 artinya pola ini yang paling sering terlihat, sedangkan pola 1,2,3,4,5,6 memiliki frekuensi yang relatif rendah, pola ini menangkap tekstur atau detail mikro seperti tepi, garis atau perubahan tekstur lain halnya dengan pola 9 yang juga cukup tinggi 0.18 menunjukkan bahwa area dengan tekstur kompleks yang mengalami gangguan kerusakan atau abnormalitas pada retina yang mengindikasikan retinopati diabetik.

D. Optimasi fitur menggunakan korelasi dan mutual information

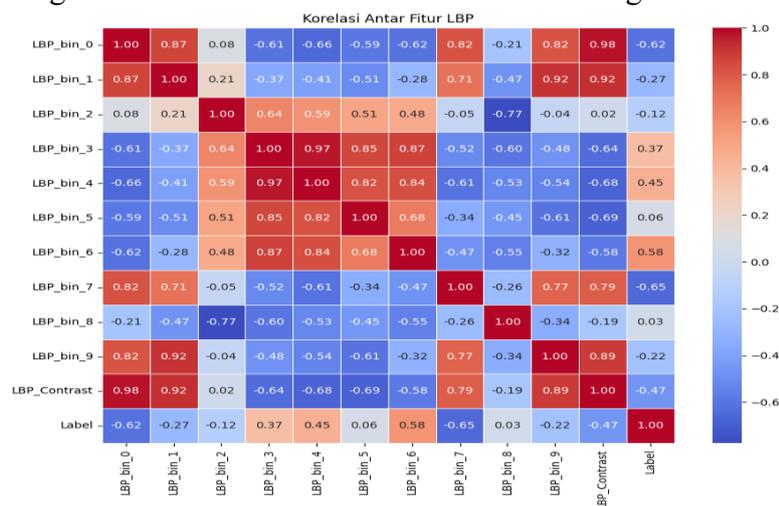
Ada beberapa strategi untuk optimasi dan meningkatkan representasi fitur, pertama dilakukan penggabungan antara histogram LBP yang menangkap pola tekstur lokal secara statistik dan Fitur

LBP contrast merepresentasikan variasi intensitas local antar piksel, hal ini akan menyajikan kekayaan tekstur yang berperan penting dalam membedakan citra normal dan yang terindikasi DR. Berikut tabel hasil evaluasi statistik fiturnya.

Tabel Hasil evaluasi statistik fitur

N o	Fitur	Mean_ DR	Mean_ Non_ DR	Std_ DR	Std_ Non_ DR	p-value	Cohen' s d	FDR	CV_ DR	Mutual Info
1	LBP_bin_0	0.071	0.089	0.008	0.009	7.46×10^{-12}	-1.944	1.741	0.123	0.262
2	LBP_bin_1	0.076	0.080	0.005	0.009	6.71×10^{-3}	-0.692	0.173	0.075	0.184
3	LBP_bin_2	0.043	0.044	0.003	0.004	2.31×10^{-1}	-0.301	0.042	0.090	0.079
4	LBP_bin_3	0.069	0.059	0.010	0.006	1.45×10^{-4}	0.988	0.608	0.151	0.111
5	LBP_bin_4	0.088	0.069	0.016	0.008	3.33×10^{-6}	1.232	1.033	0.185	0.154
6	LBP_bin_5	0.080	0.079	0.013	0.006	5.83×10^{-1}	0.137	0.012	0.161	0.067
7	LBP_bin_6	0.061	0.052	0.004	0.005	2.88×10^{-10}	1.755	1.439	0.075	0.239
8	LBP_bin_7	0.088	0.097	0.003	0.005	1.88×10^{-13}	-2.131	1.677	0.040	0.291
9	LBP_bin_8	0.247	0.243	0.030	0.064	7.53×10^{-1}	0.078	0.001	0.125	0.205
10	LBP_bin_9	0.173	0.182	0.014	0.023	3.06×10^{-2}	-0.548	0.108	0.085	0.195
11	LBP_Contrast	8.733	9.379	0.477	0.533	9.76×10^{-7}	-1.306	0.785	0.054	0.244

Evaluasi fitur menggunakan parameter mean dan standard deviasi, p-value, cohen's d, false discovery rate, coefficient of variation dan mutual information. Dapat dilihat pada tabel diatas fitur mutual information tertinggi ≥ 0.24 seperti LBP_bin_0 (0.291), LBP_bin_6 (0.239), LBP_bin_7 (0.291) dan LBP_Contrast (0.244). Selanjutnya dilakukan analisis korelasi antar fitur untuk menghindari redundansi. Fitur-fitur yang memiliki korelasi tinggi (dengan threshold > 0.85) dianggap membawa informasi yang tumpang tindih. Fitur dengan nilai korelasi tinggi akan dieliminasi, dan hanya fitur paling informatif dan tidak redundant yang dipertahankan untuk klasifikasi. Langkah ini bertujuan untuk menyederhanakan model, meningkatkan efisiensi, dan mencegah overfitting. Berikut matriks korelasi antar fitur. Berikut gambar matrik korelasi antar fitur;

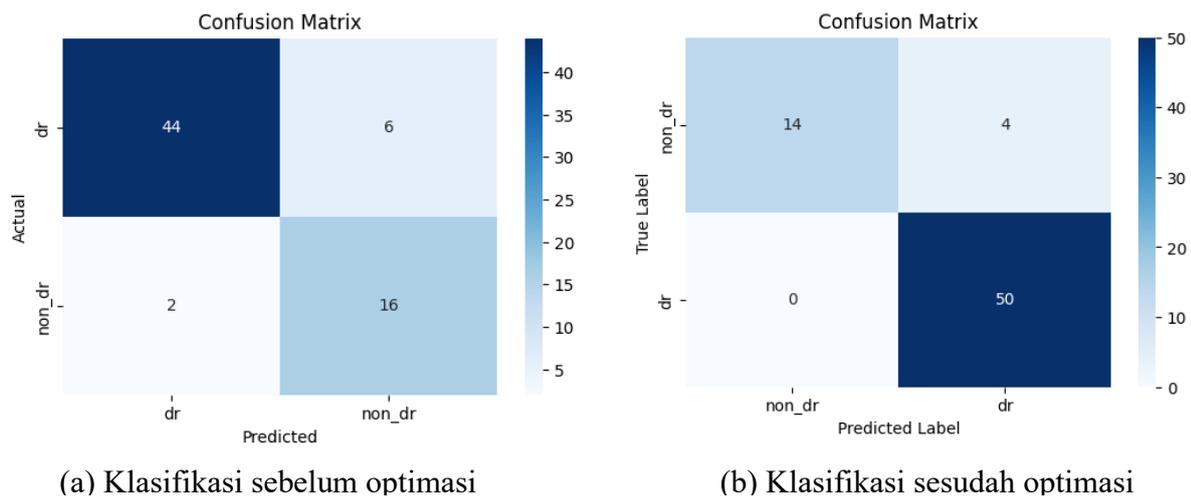


Gambar 5. Matrik korelasi antar fitur

Dari gambar diatas terdapat warna merah tua (mendekati 1) = korelasi positif sangat tinggi, Warna biru tua (mendekati -1) = korelasi negatif tinggi dan warna putih/abu = korelasi lemah atau tidak signifikan (mendekati 0). Teknik ini digunakan untuk mendeteksi redundance fitur sehingga memilih fitur independen dan informatif yang tidak saling bergantung secara statistik. Korelasi > 0.85 dianggap sebagai tanda fitur saling duplikat secara statistik berikut fitur yang dieliminasi LBP_bin_0 dikarekan korelasi sangat tinggi dengan LBP_bin_9 (0.92), LBP_contras (0.98).

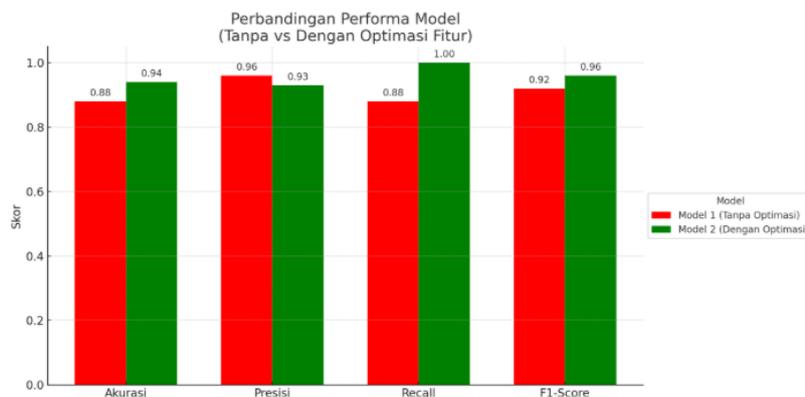
Selanjutnya Pola LBP_bin_1 dikarekan korelasi sangat tinggi dengan lbp_bin_9 (0.94), lbp_bin_0 (0.87), dan lbp_contras (0.92) yang terakhir LBP_bin_3 dikarenakan mirip dengan LBP_bin_4 (0.97), lbp_bin_5 (0.85). Sedangkan fitur informative dan tidak redundan seperti lbp_bin_2, lbp_bin_4, lbp_bin_5, lbp_bin_6, lbp_bin_7, lbp_bin_8, lbp_bin_9, lbp_contrast.

Selanjutnya proses klasifikasi SVM hasil ekstraksi fitur LBP dan Optimasi ekstraksi fitur LBP dapat di lihat pada gambar (a) Klasifikasi belum optimasi dibawah dimana hasil akurasi 0.88 %, dr memiliki presisi 0.96%, recall 0.88%, f1-score 0.92%, support 50%. Sedangkan non dr memiliki presisi 0.73%, recall 0.89%, f1-score 0.80% dan support 18%. Klasifikasi selanjutnya dengan hasil ekstraksi fitur LBP yang sudah dioptimasi korelasi dan mutual informasi pada gambar (b) hasil akurasi 0.94 %, Presisi 0.93%, recall 1.00%, f1-score 0.96%, support 50%. Sedangkan non dr memiliki presisi 1.00%, recall 0.78%, f1-score 0.88% dan support 18%.



Gambar 6. Evaluasi confusion metric SVM Fitur LBP

Pada gambar (a) diatas dapat dievaluasi dimana kasus dr yang berhasil diprediksi TP 44 gambar, sedangkan FN ada 6 gambar yang salah diprediksi sebagai non dr. Selanjutnya kasus non dr yang salah prediksi FP 2 gambar, sedangkan TN ada 16 gambar yang benar diprediksi sebagai non dr. Sedangkan pada gambar (b) diatas dapat dievaluasi dimana kasus non dr yang berhasil diprediksi TN 14 gambar, sedangkan FP ada 4 gambar yang salah diprediksi sebagai dr. Selanjutnya kasus dr tidak ada yang salah prediksi FN 0 gambar, sedangkan TP ada 50 gambar yang benar diprediksi sebagai dr. Untuk melihat perbandingan performa model dapat dilihat pada gambar dibawah ini.



Gambar 7. Perbandingan performa Tanpa dan dengan optimasi fitur

Setelah di optimasi hasil klasifikasi menunjukkan peningkatan performa, dimana akurasi naik dari 0.88% menjadi 0.94%, recall meningkat signifikan dari 0.88 menjadi 1.00, artinya semua kasus DR

berhasil terdeteksi dan F1-score naik dari 0.92 ke 0.96, menunjukkan keseimbangan presisi dan recall. Meskipun presisi sedikit menurun dari 0.96 ke 0.93, ini merupakan trade-off yang wajar karena recall meningkat signifikan dan ini lebih penting dalam konteks medis. Peningkatan performa setelah optimasi fitur membawa implikasi klinis yang sangat positif, model mampu mendeteksi seluruh kasus DR tanpa terlewat (recall = 1.00), yang sangat penting untuk mencegah progresi penyakit. Deteksi dini yang akurat memungkinkan intervensi lebih awal, menurunkan risiko komplikasi, dan mendukung pengambilan keputusan oleh tenaga medis.

E. Pembahasan

Hasil penelitian menunjukkan bahwa optimasi fitur yang diusulkan berhasil meningkatkan performa klasifikasi secara signifikan. Akurasi model meningkat dari 88% menjadi 94%, dan yang terpenting, recall mencapai 100% setelah optimasi. Peningkatan ini menegaskan bahwa strategi penggabungan fitur LBP Contrast dengan seleksi berbasis MI dan korelasi efektif dalam menyaring fitur yang paling informatif dan tidak redundan. Meskipun presisi sedikit menurun dari 96% menjadi 93%, ini merupakan *trade-off* yang dapat diterima dalam konteks medis, di mana kemampuan untuk mendeteksi semua kasus positif (*recall* tinggi) jauh lebih krusial untuk mencegah diagnosis yang terlewat.

Untuk mengukur signifikansi penelitian ini, penting untuk membandingkan dengan penelitian lain. Akurasi 94% yang dicapai oleh model SVM kami yang dioptimalkan sangat kompetitif di bidang ini. Beberapa studi berbasis deep learning seperti yang dilakukan oleh Bintang dkk (2024) dan Bilal dkk (2024) juga menghasilkan akurasi tinggi, namun seringkali dengan model yang bersifat "kotak hitam" (black box) dan membutuhkan sumber daya komputasi besar [27][28]. Keunggulan utama pendekatan kami adalah tercapainya akurasi tinggi melalui model klasik yang lebih efisien dan dapat diinterpretasikan, menjawab salah satu keterbatasan utama dari model deep learning tersebut. Jika dibandingkan dengan studi yang menggunakan LBP tanpa optimasi seperti oleh Kundu dkk (2023) [1], penelitian kami secara eksplisit menunjukkan dampak positif dari optimasi fitur. Peningkatan akurasi dari 88% (baseline) menjadi 94% (setelah optimasi) membuktikan bahwa proses seleksi dan reduksi redundansi merupakan langkah krusial yang berhasil mengatasi kelemahan LBP standard.

Analisis lebih dalam pada confusion matrix memberikan wawasan penting. Peningkatan recall menjadi 100% (dari 44 TP dan 6 FN menjadi 50 TP dan 0 FN) dicapai dengan konsekuensi naiknya jumlah False Positive (FP) dari 2 menjadi 4 kasus. Ini berarti model yang dioptimalkan menjadi sangat sensitif dalam mendeteksi DR, namun di sisi lain keliru mengklasifikasikan 4 citra sehat sebagai citra DR. Hal ini mengindikasikan bahwa kasus-kasus misklasifikasi kemungkinan besar terjadi pada citra non-DR yang memiliki karakteristik visual yang ambigu. Dimana terdapat citra dengan variasi pencahayaan yang tidak merata, artefak, atau bahkan anomali anatomis jinak (seperti pembuluh darah yang sangat berkelok) yang secara tekstur menyerupai lesi patologi DR. Model yang sangat sensitif terhadap tekstur bisa terjadi keliru menafsirkan pola-pola tersebut. Untuk mengurangi kasus FP tanpa mengorbankan recall, penelitian selanjutnya dapat mengeksplorasi dengan menggunakan model ensemble yaitu menggabungkan beberapa model klasifikasi untuk mendapatkan keputusan yang lebih robust dan mengurangi variansi prediksi. Kemudian analisis lokal dengan menerapkan deteksi berbasis patch untuk melokalisasi area yang dicurigai oleh model, sehingga dokter dapat melakukan verifikasi visual dengan lebih mudah.

IV. KESIMPULAN

Penelitian ini berhasil membuktikan bahwa optimasi fitur tekstur melalui integrasi histogram LBP dan LBP Contrast, yang dilanjutkan dengan seleksi fitur hibrida berbasis Mutual Information dan korelasi, merupakan sebuah kontribusi metodologis yang signifikan untuk klasifikasi Retinopati Diabetik (DR). Pendekatan ini secara efektif meningkatkan performa model SVM, mencapai akurasi 94% dan, yang terpenting, recall 100%, yang menunjukkan kemampuannya untuk mengidentifikasi semua kasus positif DR pada data uji. Dengan performa tersebut, model ini memiliki potensi aplikasi nyata sebagai alat skrining otomatis yang efisien untuk membantu penapisan awal di fasilitas kesehatan, serta sebagai sistem pendukung keputusan bagi tenaga medis. Meskipun demikian, penelitian ini memiliki beberapa keterbatasan, termasuk ukuran dataset yang relatif terbatas (168 citra) dan penentuan parameter (seperti radius LBP dan ambang korelasi) yang masih bersifat empiris. Untuk pengembangan selanjutnya, kami menyusun beberapa tahapan penelitian yang dapat dikembangkan selanjut.

1. Peningkatan Robustitas Model: Mengintegrasikan fitur morfologis (misalnya, bentuk dan ukuran lesi) guna mengurangi kasus false positive dan meningkatkan spesifisitas model tanpa mengorbankan sensitivitas.
2. Validasi Eksternal dan Klinis: Untuk menguji generalisasi model, perlu dilakukan validasi silang antar-dataset (cross-dataset evaluation) menggunakan dataset publik lain seperti IDRiD atau EyePACS. Setelah validasi komputasi, langkah krusial berikutnya adalah merancang studi validasi lapangan (pilot study) bekerja sama dengan institusi medis untuk menguji performa prototipe sistem pada data pasien riil.
3. Eksplorasi Arsitektur Hibrida: Sebagai pengembangan lebih lanjut, dapat dieksplorasi arsitektur ensemble learning yang menggabungkan SVM dengan model lain, atau pendekatan hybrid deep learning di mana fitur LBP yang telah dioptimalkan ini diintegrasikan sebagai input tambahan ke dalam jaringan saraf tiruan untuk meningkatkan daya diskriminatifnya.

REFERENSI

- [1] S. Kundu et al., "LBP Feature Extraction for Early Detection of Diabetic Eye Diseases," *IJRASET*, no. June, pp. 2903–2907, 2023.
- [2] T. Koldoris, "Health and Treatment of Diabetes Mellitus," *Int. J. Health Sci. (Qassim)*, vol. 5, no. 1, 2021.
- [3] X. Jiang, Z. Hu, S. Wang, and Y. Zhang, "Deep Learning for Medical Image-Based Cancer Diagnosis," *Cancers MDPI*, pp. 1–72, 2023.
- [4] L. Costaner, Lisawita, Guntoro, and Abdullah, "Feature Extraction Analysis for Diabetic Retinopathy Detection Using Machine Learning Techniques," *Sist. Sist. Inf.*, vol. 13, no. 5, 2024.
- [5] 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.
- [6] A. Colomer, J. Igual, and V. Naranjo, "Detection of early signs of diabetic retinopathy based on textural and morphological information in fundus images," *Sensors (Switzerland)*, vol. 20, no. 4, pp. 1–21, 2020, doi: 10.3390/s20041005.
- [7] J. J. McAnany, J. C. Park, K. Liu, M. Liu, Y. Chen, and C. dan J. I. L. Felix Y, "Contrast sensitivity is associated with outer retina thickness in early stage diabetic retinopathy," *Acta Ophthalmol.*, pp. 1–8, 2020.
- [8] S. Gupta, S. Thakur, and A. Gupta, "Optimized hybrid machine learning approach for smartphone based diabetic retinopathy detection," *Multimed. Tools Appl.*, pp. 14475–14501, 2022.
- [9] M. Lupidi et al., "Functional correlation between choroidal and retinal vascularity in low - grade diabetic retinopathy," *Acta Diabetol.*, vol. 57, no. 8, pp. 983–990, 2020, doi: 10.1007/s00592-020-01507-7.
- [10] J. P. Kandhasamy, S. Balamurali, S. Kadry, and L. K. Ramasamy, "Diagnosis of diabetic retinopathy using multi level set segmentation algorithm with feature extraction using SVM with selective features,"

- Multimed. Tools Appl., vol. 79, no. 15–16, pp. 10581–10596, 2020, doi: 10.1007/s11042-019-7485-8.
- [11] M. H. Shakoor and R. Boostani, “Feature selection and mapping of local binary pattern for texture classification,” *Multimed. Tools Appl.*, pp. 7639–7676, 2023.
- [12] I. Ahmad and V. P. Singh, “Diabetic Retinopathy Detection based on LBP and Statistical Features using Machine Learning,” in *2023 International Conference on Computer, Electronics & Electrical Engineering & their Applications (IC2E3)*, 2023, pp. 1–6. doi: 10.1109/IC2E357697.2023.10262780.
- [13] N. M. Makmur, F. Kwan, A. Dewi, and F. Indra, “Comparing Local Local Binary Binary Pattern and Gray Level Level Co-occurrence Matrix for Feature Extraction in Diabetic Retinopathy Classification,” *Procedia Comput. Sci.*, vol. 227, pp. 355–363, 2023, doi: 10.1016/j.procs.2023.10.534.
- [14] I. Ahmad, V. P. Singh, and M. M. Gore, “Detection of Diabetic Retinopathy Using Discrete Wavelet-Based Center-Symmetric Local Binary Pattern and Statistical Features,” *J. Imaging Informatics Med.*, vol. 38, pp. 1184–1211, 2024, doi: 10.1007/s10278-024-01243-2.
- [15] R. Dowerah and S. Patel, “Comparative analysis of color histogram and LBP in CBIR systems,” *Multimed. Tools Appl.*, pp. 12467–12486, 2024, doi: 10.1007/s11042-023-15955-0.
- [16] M. Garg and G. Dhiman, “A novel content-based image retrieval approach for classification using GLCM features and texture fused LBP variants,” *Neural Comput. Appl.*, vol. 33, no. 4, pp. 1311–1328, 2021, doi: 10.1007/s00521-020-05017-z.
- [17] J. Cheng, Y. Xu, and L. Kong, “Hyperspectral imaging classification based on LBP feature extraction and multimodel ensemble learning,” *Comput. Electr. Eng.*, vol. 92, no. May, p. 107199, 2021, doi: 10.1016/j.compeleceng.2021.107199.
- [18] K. Anvesh, B. M. Reshmi, S. K. Rout, B. K. Sethi, and S. S. Panigrahi, “A Precision Tessellated Fundus Detection: Leveraging Color and Texture Features with SVM Classification,” *Intell. Syst.*, pp. 77–89, 2025, doi: 10.1007/978-981-97-8160-7_7.
- [19] T. Vijayan, M. Sangeetha, A. Kumaravel, and B. Karthik, “Feature Selection for Simple Color Histogram Filter based on Retinal Fundus Images for Diabetic Retinopathy Recognition,” *IETE J. Res.*, pp. 1–9, 2020, doi: 10.1080/03772063.2020.1844082.
- [20] A. S. Jadhav, P. B. Patil, and S. Biradar, “Optimal feature selection-based diabetic retinopathy detection using improved rider optimization algorithm enabled with deep learning,” *Evol. Intell.*, pp. 1–18, 2020, doi: <https://doi.org/10.1007/s12065-020-00400-0>.
- [21] H. Zhou, X. Wang, and R. Zhu, “Feature selection based on mutual information with correlation coefficient,” *Appl. Intell.*, pp. 1–18, 2021.
- [22] A. S. Jadhav, P. B. Patil, and S. Biradar, “Optimal feature selection - based diabetic retinopathy detection using improved rider optimization algorithm enabled with deep learning Restricted Boltzmann machine,” *Evol. Intell.*, vol. 14, no. 4, pp. 1431–1448, 2021, doi: 10.1007/s12065-020-00400-0.
- [23] S. Yadav and P. Awasthi, “Diabetic Retinopathy Detection Using Deep Learning And Inception-V3 Model,” *Int. Res. J. Mod. Eng. Technol. Sci.*, no. 06, pp. 1731–1735, 2022.
- [24] R. Adriman, K. Muchtar, and N. Maulina, “Performance Evaluation of Binary Classification of Diabetic Retinopathy through Deep Learning Techniques using Texture Feature,” *Procedia Comput. Sci.*, vol. 179, no. 2020, pp. 88–94, 2021, doi: 10.1016/j.procs.2020.12.012.
- [25] H. Zhou, X. Wang, and R. Zhu, “Feature selection based on mutual information with correlation coefficient,” *Appl. Intell.*, pp. 5457–5474, 2022.
- [26] A. Malhi, R. Grewal, and H. S. Pannu, “Detection and diabetic retinopathy grading using digital retinal images,” *Int. J. Intell. Robot. Appl.*, no. 0123456789, pp. 1–33, 2023, doi: 10.1007/s41315-022-00269-5.
- [27] A. Bilal et al., “Improved Support Vector Machine based on CNN-SVD for vision-threatening diabetic retinopathy detection and classification,” *PLoS One*, vol. 19, no. 1 January, pp. 1–27, 2024, doi: 10.1371/journal.pone.0295951.
- [28] Y. K. Bintang and H. Imaduddin, “Pengembangan Model Deep Learning Untuk Deteksi Retinopati Diabetik Menggunakan Metode Transfer Learning,” *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.*, vol. 9, no. 3, pp. 1442–1455, 2024, doi: 10.29100/jupi.v9i3.5588.