

Deteksi Glaukoma pada Citra Fundus Retina menggunakan Metode *Local Binary Pattern* dan *Support Vector Machine*

FEBI NURFAJAR, RITA MAGDALENA, SOFIA SA'IDAH

Universitas Telkom, Indonesia
Email: febinurfajar@student.telkomuniversity.ac.id

Received 17 Mei 2022 | *Revised* 10 Juni 2022 | *Accepted* 14 Juli 2022

ABSTRAK

Glaukoma merupakan sebuah penyakit yang menyerang indera penglihatan dan dapat mengakibatkan kebutaan yang bersifat permanen. Meskipun penyakit ini tidak bisa disembuhkan, tetapi gejala kerusakannya dapat diminimalkan dengan melakukan pendeteksian secara dini. Deteksi glaukoma dapat dilakukan secara manual oleh oftalmologis, tetapi metode ini terbilang subyektif sebab hasil pengamatannya bergantung pada domain pengetahuan dokter, sementara di sisi lain teknik pencitraan medis modern, seperti OCT, CSLO, dan HRT berbiaya tinggi dan ketersediaan perangkatnya relatif terbatas. Pada penelitian ini, sebuah sistem berbasis machine learning untuk mendeteksi glaukoma pada citra fundus retina telah dirancang melalui proses pengolahan citra digital menggunakan metode Local Binary Pattern dan Support Vector Machine. Performansi sistem diuji pada 146 citra fundus yang terdiri dari citra fundus sehat dan glaukoma. Dengan menggunakan metode yang diusulkan, sistem mampu memberikan tingkat akurasi terbaik pada 93.15%, sensitivitas 92.30%, dan spesifisitas 93.61%.

Kata kunci: *Glaukoma, Local Binary Pattern, Support Vector Machine*

ABSTRACT

Glaucoma is a disease that attacks the sense of sight and can lead to permanent blindness. Although this disease cannot be cured, the symptoms of the damage can be minimized by early detection. Glaucoma detection can be done manually by an ophthalmologist, but this method is somewhat subjective because the results of the observations depend on the domain of the doctor's knowledge, whereas on the other hand, modern medical imaging techniques, such as OCT, CSLO, and HRT, are high in cost and the availability of devices is relatively limited. This research proposed a machine learning-based system to detect glaucoma in retinal fundus images through digital image processing using the Local Binary Pattern and Support Vector Machine methods. The performance of the system was tested on 146 fundus images consisting of healthy fundus images and glaucoma. By using the proposed method, the system provide the best accuracy rate at 93.15%, sensitivity 92.30%, and specificity 93.61%.

Keyword: *Glaucoma, Local Binary Pattern, Support Vector Machine*

1. PENDAHULUAN

Glaukoma merupakan suatu penyakit yang menyerang indera penglihatan dan menjadi salah satu penyebab utama dari kebutaan di dunia selain katarak (**InfoDATIN Kementerian Kesehatan RI, 2019**). Berbeda dengan katarak, kebutaan akibat glaukoma bersifat permanen atau tidak dapat kembali seperti semula (**Weinreb, dkk, 2014**). Diperkirakan pada tahun 2020 sebanyak lebih dari 76 juta orang di dunia menderita kebutaan akibat glaukoma dan akan mengalami kenaikan yang signifikan menjadi 111,8 juta orang pada tahun 2040 (**Tham, dkk, 2014**). Banyak dari pasien penderita glaukoma tidak menyadari penyakit yang dialaminya karena perkembangan penyakit glaukoma berlangsung lambat (**InfoDATIN Kementerian Kesehatan RI, 2019**). Oleh karena itu, deteksi dini pada seseorang yang terindikasi glaukoma perlu dilakukan untuk meminimalisir kerusakan yang terjadi pada syaraf optik. Saat ini, proses pengamatan struktur retina bisa dilakukan melalui berbagai teknik, mulai dari pengamatan secara langsung oleh oftalmologis hingga menggunakan peralatan medis modern seperti *Optical Coherence Tomography* (OCT), *Confocal Scanning Laser Ophthalmoscopy* (CSLO) dan *Heidelberg Retinal Tomography* (HRT) (**Munarto, dkk, 2016**). Namun, metode-metode tersebut memiliki kekurangan, misalnya metode pertama memiliki tingkat subyektivitas yang cukup tinggi dalam proses pengamatan sedangkan peralatan-peralatan medis modern yang disebutkan ketersediaannya relatif terbatas dan berbiaya tinggi. Saat ini, proses deteksi glaukoma sudah banyak dilakukan dengan memanfaatkan teknologi *computer vision* menggunakan *machine learning* maupun *deep learning*.

Sudah banyak metodologi-metodologi yang diusulkan terkait deteksi dan klasifikasi glaukoma. Pada tahun 2014, (**Xiong, dkk, 2014**) mengusulkan metode *Principle Component Analysis* (PCA) untuk mengekstrak fitur dari citra fundus retina yang sudah melalui tahapan *preprocessing*. Metode klasifikasi Bayes berbasis model Gaussian diimplementasikan pada proses pengujian sistem dan akurasi yang diperoleh sebesar 78%. Pada 2016, (**Mustofa, dkk, 2016**) mengusulkan metode *Adaptive Thresholding* untuk proses segmentasi terhadap *optic cup*, *optic disk*, dan pembuluh darah retina dari citra fundus. Fitur *Cup-to-Disk Ratio* (CDR) dan Imperior, Superior, Nasal, dan Temporal (ISNT) dari citra lalu digunakan sebagai indikator untuk klasifikasi glaukoma menggunakan *Support Vector Machine* (SVM). Hasilnya, akurasi rata-rata yang dihasilkan sebesar 80%. Pada tahun 2016, (**Dey & Bandyopadhyay, 2016**) menggunakan metode PCA untuk mengekstrak fitur dari citra fundus retina yang telah melalui serangkaian operasi *preprocessing* dan juga SVM untuk pengklasifikasinya. Tingkat akurasi yang mampu diberikan oleh sistem sebesar 86%. Pada tahun 2018, (**Ahn, dkk, 2018**) melakukan penelitian terkait deteksi glaukoma menggunakan model berbasis *deep learning*. Dengan menggunakan metode *Convolutional Neural Network*, dua skema penelitian dilakukan. Skema terbaik dari penelitian tersebut adalah dengan menggunakan algoritma Google's TensorFlow dan menghasilkan tingkat akurasi sebesar 87.9%. Sementara itu, pada tahun 2019, sebuah penelitian dilakukan untuk mendeteksi dua penyakit sekaligus, yakni glaukoma dan diabetik retinopati. Metode yang diusulkan dalam penelitian tersebut adalah Jaringan Syaraf Tiruan. Hasilnya, akurasi yang diperoleh dari pengujian sistem rata-rata sebesar 91,06% (**Al Rivan & Juangkara, 2019**).

Dalam penelitian ini, metode *Local Binary Pattern* (LBP) dan *Support Vector Machine* (SVM) diusulkan untuk melakukan deteksi glaukoma pada citra fundus retina. LBP diusulkan karena

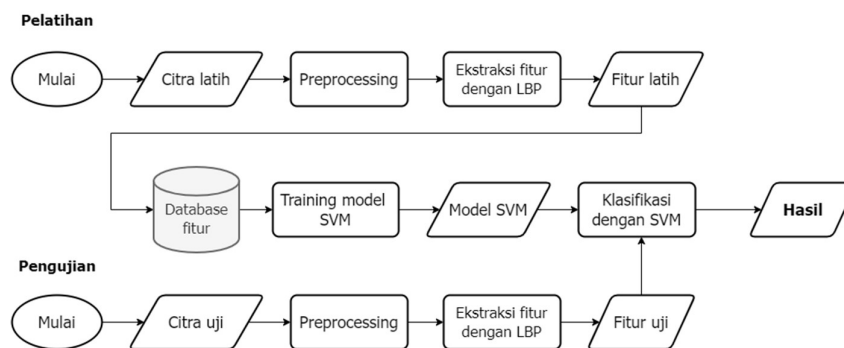
metode ini memiliki sejumlah kelebihan, di antaranya memiliki kemampuan komputasi yang sederhana dan metode ini hanya menghitung representasi fitur lokal sehingga tahan terhadap perubahan iluminasi cahaya (Nanni, dkk, 2010). Tidak hanya itu, metode ini juga memiliki sifat tahan terhadap perubahan rotasi dan warna (terutama *grayscale*) (Song, dkk, 2013). Sementara itu, SVM diusulkan karena metode ini memiliki kemampuan yang efektif dalam pengenalan pola, di mana kelebihan-kelebihannya antara lain: (1) SVM dapat menggeneralisasi data di dalam ruang fitur berdimensi tinggi dengan jumlah sampel pelatihan yang kecil; (2) SVM dapat memberikan hasil yang optimal melalui proses transformasi menggunakan *quadratic programming*; (3) SVM dapat menangani dan memproses data yang bersifat *non-linearly seperable* atau tidak dapat dipisahkan secara linear (Men, dkk, 2017). Dalam prosesnya, SVM juga tidak memerlukan sampel data pelatihan dengan jumlah yang besar demi menghindari terjadinya *overfitting* (Nanda, dkk, 2018). Kedua metode tersebut diusulkan sebab *dataset* yang digunakan dalam penelitian ini relatif sedikit dan masing-masing data memiliki elemen tekstur yang bervariasi, terutama dalam hal iluminasi. Hasil yang diharapkan dari penelitian ini adalah model sistem yang dapat mendeteksi glaukoma berdasarkan citra fundus retina dan mengklasifikasikannya ke dalam dua kelas, yaitu glaukoma dan normal. Selain itu, sistem yang dirancang juga diharapkan mampu memberikan performansi sistem yang lebih baik dari penelitian-penelitian sebelumnya.

2. METODOLOGI PENELITIAN

Pada bagian ini akan didefinisikan tiga tahapan utama dalam proses perancangan sistem, di antaranya *preprocessing* terhadap citra, ekstraksi fitur menggunakan *Local Binary Pattern*, dan klasifikasi menggunakan *Support Vector Machine*.

2.1 Diagram Alir Sistem

Proses perancangan sistem terdiri dari dua tahap, yaitu tahap pelatihan dan tahap pengujian. Tahapan dari kedua proses tersebut ditunjukkan oleh diagram alir pada Gambar 1 di bawah ini.



Gambar 1. Diagram Alir Proses Perancangan Sistem

Berdasarkan Gambar 1 di atas, baik pelatihan ataupun pengujian sistem memiliki alur proses yang serupa. Proses ini meliputi tahap *preprocessing*, di mana pada tahap ini citra asli diperbaiki sedemikian rupa untuk memperoleh komposisi citra yang lebih baik. Kemudian, citra keluaran *preprocessing* diolah menggunakan metode LBP. Pada proses pelatihan, fitur latih yang diperoleh kemudian disimpan dalam *database* untuk nantinya dijadikan input pada algoritma SVM. Dari proses ini lalu diperoleh model SVM, yang mana di sisi pengujian, hasil

model ini akan dijadikan acuan oleh SVM dalam mengklasifikasikan data uji ke dalam kelas yang sesuai berdasarkan kecocokan antara fitur uji dan fitur latih yang tersedia

2.2 Dataset Citra

Dataset citra yang digunakan untuk penelitian ini merupakan dataset sekunder yang diperoleh dari *database* publik milik Medical Image Analysis Group, Universidad de La Laguna, Spanyol, yaitu RIM-ONE DL (**Batista, dkk, 2020**). Dataset ini terdiri dari 485 citra fundus retina berjenis RGB, berbentuk persegi dengan ukuran beragam. Sebanyak 313 citra dari dataset merupakan citra fundus sehat dan 172 citra lainnya merupakan citra fundus yang terindikasi glaukoma. Dalam penelitian ini, dataset akan dipartisi secara acak ke dalam dua subdivisi, yaitu pelatihan dan pengujian, dengan masing-masing persentase partisi 70% dan 30%. Rincian dari distribusi dataset disajikan dalam Tabel 1 berikut ini.

Tabel 1. Distribusi Dataset dalam Penelitian

Dataset	Pelatihan	Pengujian	Total
Normal	219	94	313
Glaukoma	120	52	172
Total	339	146	485

2.3 Preprocessing

Preprocessing merupakan tahapan awal yang dilakukan pada citra sebelum diproses ke tahapan selanjutnya. Terdapat empat operasi *preprocessing* yang diterapkan pada citra di sini, di antaranya adalah pengubahan dimensi citra, normalisasi, konversi warna, penghapusan derau, dan CLAHE.

2.3.1 Pengubahan Dimensi Citra

Citra fundus yang semula memiliki ukuran yang beragam diubah dimensinya menjadi 256x256. Untuk gambar dengan panjang sisi tetap, peningkatan resolusi piksel akan menurunkan ukuran relatif setiap piksel. Mengurangi ukuran piksel berarti meningkatkan kemungkinan presisi pengukuran. Oleh karena itu, gambar beresolusi tinggi diperlukan untuk memberikan pengukuran partikel yang akurat dan konsisten (**Horwath, dkk, 2020**). Ukuran 256x256 dipilih karena pada prosesnya, tidak hanya memberikan resolusi yang optimal, tetapi juga memberikan waktu komputasi yang singkat jika dibandingkan dengan ukuran yang lebih besar, seperti 512x512.

2.3.2 Normalisasi

Setelah semua citra memiliki dimensi yang seragam, langkah selanjutnya adalah proses normalisasi. Normalisasi terkadang disebut sebagai *histogram stretching* atau *contrast stretching*, yang artinya adalah mengubah rentang intensitas piksel yang berbeda ke dalam distribusi normal supaya citra menjadi lebih optimal untuk diproses. Pada tahap ini, citra berwarna (RGB) akan dinormalisasi ke dalam rentang piksel [0, 1].

2.3.3 Konversi Warna

Pada tahap ini, citra fundus berwarna sesudah dinormalisasi dikonversi menjadi citra skala abu (*grayscale*). Komposisi citra *grayscale* yang hanya terdiri dari satu kanal lebih mudah untuk diproses dibandingkan citra RGB, misalnya dalam proses peningkatan kontras pada citra.


2.3.4 Penghapusan Derau

Proses selanjutnya adalah menghilangkan derau atau *noise* pada citra. Dalam tahap ini, metode yang dipilih adalah filter Gaussian 2-dimensi. Filter gaussian dipilih karena cocok digunakan untuk menghilangkan derau yang bersifat sebaran normal, seperti derau pada citra yang umumnya muncul pada citra hasil proses digitasi menggunakan kamera (Wedianto & Sari, 2016).

2.3.5 CLAHE

Setelah derau dihilangkan, tahapan terakhir adalah peningkatan kontras pada citra. Metode yang digunakan adalah *Contrast Limited Adaptive Histogram Equalization* (CLAHE). Dengan menggunakan CLAHE, citra hasil keluaran akan memiliki peningkatan kontras dan intensitas piksel yang terdistribusi seragam (Irawan, dkk, 2019).

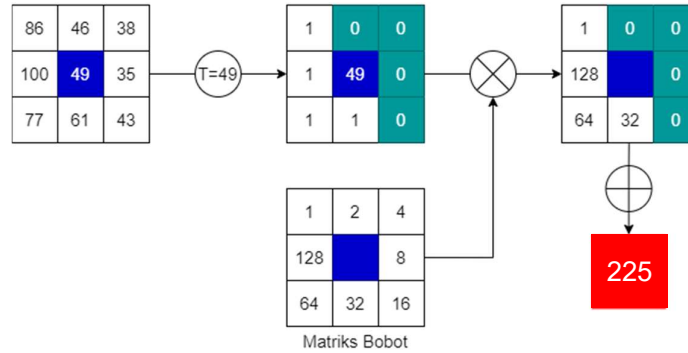
Tahapan dari proses *preprocessing* diperlihatkan pada Gambar 2 berikut ini.



Gambar 2. Hasil *Preprocessing* Citra Setelah (a) Pengubahan Ukuran dan Normalisasi (b) Konversi Warna Ke *Grayscale* (c) Penghapusan Derau (d) CLAHE

2.4 Local Binary Pattern

Local Binary Pattern (LBP) merupakan operator untuk deskripsi tekstur yang didasarkan pada tanda-tanda perbedaan antara piksel tetangga dan piksel pusat (Prakasa, 2016). Menggunakan LBP, citra fundus yang berukuran 256x256 dibagi ke dalam sel-sel matriks baris dan kolom. Metode ini bekerja dalam sebuah ketetanggaan sirkuler berdasarkan nilai radius (R) dan jumlah titik piksel (P). Nilai intensitas piksel dari setiap sel dalam ketetanggaan dibandingkan dengan sebuah sel pusat yang berperan sebagai ambang batas nilai (*threshold*). Dengan kata lain, jika menggunakan $P = 8$ dan $R = 1$, maka akan ada delapan piksel tetangga yang dibandingkan dengan satu piksel pusat (berbentuk matriks 3x3). Piksel tetangga akan bernilai satu jika nilainya lebih besar dari nilai piksel pusat dan bernilai nol jika sebaliknya. Hasil yang diperoleh berupa kode biner, dan kode ini disebut sebagai pola biner (*binary pattern*). Pola biner tersebut kemudian dikalikan dengan sebuah matriks bobot dan hasil penjumlahan dari masing-masing titik piksel disebut sebagai representasi LBP.



Gambar 3. Langkah Perhitungan LBP

2.4.1 Rotation Invariant

Metode LBP yang asli pada dasarnya tidak tahan terhadap rotasi (*non rotation invariant*), sehingga hal tersebut membatasi beberapa pekerjaan tertentu. Maka dari itu, operator LBP *rotation invariant* dirumuskan untuk membuat kode LBP lebih tahan terhadap orientasi tekstur dan rotasi citra serta membuat identifikasi tekstur jauh lebih efisien dengan mengurangi jumlah kode LBP yang mungkin. Metode ini secara umum dirumuskan dengan Persamaan (1).

$$LBP_{P,R}^{ri} = \min\{ROR(LBP_{P,R}, i)\} \mid i = 0, 1, \dots, P - 1 \quad (1)$$

Superskrip *ri* menyatakan '*rotation invariant*'. Fungsi $ROR(x, i)$ secara sirkuler menggeser bilangan biner P -bit x sebanyak i kali ke kanan ($|i| < P$). Singkatnya, pola LBP yang diperoleh dari teknik ini dihasilkan dengan memutar pola LBP asli secara melingkar sampai nilai minimumnya tercapai (Song, dkk, 2013). Misalnya, dalam $LBP_{8,R}^{ri}$ akan terdapat 36 pola LBP yang berbeda. Oleh karena itu, $LBP_{8,R}^{ri}$ menghasilkan 36 histogram LBP.

2.4.2 Uniform

Dalam pengujian menggunakan *rotation invariant*, beberapa pola LBP muncul lebih sering daripada yang lain, mayoritas lebih dari 90%. Pola LBP yang muncul paling banyak adalah transisi dari satu ke nol ($0 \rightarrow 1$) atau sebaliknya dalam sebuah kode biner sirkuler. Pola yang muncul tersebut kemudian disebut sebagai pola seragam (*uniform pattern*). Pendefinisian pola seragam dalam sebuah ketetangaan sirkuler G dijabarkan dengan Persamaan (2).

$$U(G_p) = |s(g_{p-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^P |s(g_p - g_c) - s(g_{p-1} - g_c)| \quad (2)$$

Semua pola dengan $U < 2$ didefinisikan sebagai '*uniform*' dan total pola LBP yang mungkin adalah $P(P - 1) + 3$, di mana P adalah jumlah titik piksel (disebut juga dengan *sampling point*) dalam sebuah ketetangaan (Liu, dkk, 2017). Sehingga, dalam $LBP_{8,R}^{u2}$ atau dengan delapan titik piksel yang digunakan, total pola LBP yang dihasilkan adalah 59 pola LBP.

2.4.3 Rotation Invariant Uniform

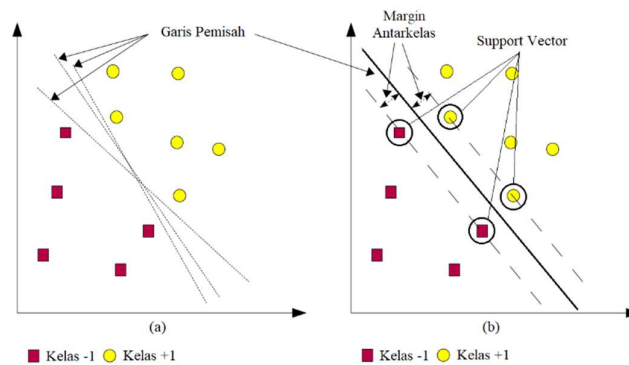
Operator LBP *rotation invariant uniform* diperoleh dari kombinasi antara operator $LBP_{P,R}^{ri}$ dan operator $LBP_{P,R}^{u2}$. Operator tersebut didefinisikan dengan Persamaan (3).

$$LBP_{P,R}^{riu2} = \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c), & U(G_p) \leq 2 \\ P + 1, & \text{lainnya} \end{cases} \quad (3)$$

Di mana superskrip *riu2* menyatakan 'rotation invariant uniform'. Menggunakan $LBP_{P,R}^{riu2}$, pola LBP yang mungkin dipetakan dari sebuah citra direduksi menjadi $P + 2$. Sebagai contoh, total pola yang mungkin dalam operator $LBP_{8,R}^{riu2}$ atau delapan titik piksel yang digunakan adalah sepuluh pola, menjadikan dimensi pola LBP yang dihasilkan menggunakan operator ini lebih rendah secara signifikan (Liu, dkk, 2017).

2.5 Support Vector Machine

Support Vector Machine (SVM) merupakan salah satu metode dalam supervised learning yang biasanya digunakan untuk klasifikasi (Support Vector Classification) dan regresi (Support Vector Regression). Strategi yang dilakukan oleh metode ini adalah menemukan hyperplane pemisah yang optimal (optimal separating hyperplane) dengan cara memaksimalkan margin antarkelas dari sekumpulan data (Vapnik, 1995). Hyperplane merupakan sebuah fungsi yang digunakan untuk klasifikasi di dalam ruang kelas berdimensi tinggi dan dapat digunakan sebagai pemisah antarkelas.



Gambar 4. Hyperplane yang Memisahkan Kelas -1 dan +1

Gambar 4 di atas memperlihatkan beragam alternatif garis pemisah atau hyperplane. Hyperplane terbaik antara kedua kelas dapat ditemukan dengan mengukur margin antarkelas (yaitu jarak antara hyperplane dengan objek terdekat dari masing-masing kelas) dan mencari titik maksimalnya. Gambar 4(b) menunjukkan hyperplane terbaik, direpresentasikan oleh garis solid yang terletak tepat pada tengah-tengah kedua kelas, yaitu +1 dan -1. Objek atau pola yang paling dekat dengan hyperplane disebut sebagai support vector, karena mereka membangun hyperplane dengan margin maksimum tepat di tengah-tengah (Nguyen, 2017). Inilah alasan mengapa metode klasifikasi ini disebut Support Vector Machine (SVM). Pada gambar di atas, support vector ditunjukkan pada objek yang berada dalam lingkaran hitam.

Pada dasarnya, SVM merupakan salah satu varian dari linear classifier, sehingga SVM cenderung mampu menyelesaikan masalah yang bersifat linearly separable. Di sisi lain, salah satu kendala dalam proses klasifikasi adalah penyebaran data yang cenderung beragam, sehingga akan sulit dipisahkan secara linear. Untuk menangani hal tersebut, konsep fungsi kernel dirumuskan. Pada prosesnya, fungsi kernel bekerja dengan cara mengubah ruang vektor pada data asli menjadi ruang vektor baru dengan dimensi yang lebih tinggi supaya data bisa dipisahkan secara linear dengan mudah (Cristianini & Shawe-Taylor, 2000). Terdapat

empat jenis fungsi kernel yang umum digunakan, antara lain kernel Linear, *Radial Basis Function* (RBF) Gaussian, Polinomial, dan sigmoid (**Nanda, dkk, 2018**).

Pada penelitian ini, SVM akan mengklasifikasikan vektor fitur dari citra fundus retina ke dalam dua kelas, yaitu kelas glaukoma dan normal.

3. HASIL DAN PEMBAHASAN

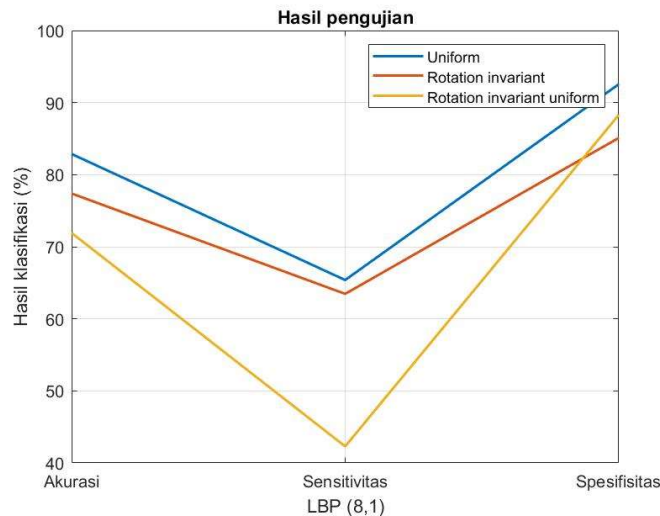
Proses pengujian terhadap sistem dilakukan secara berurutan dengan mempertimbangkan parameter uji yang dipakai. Sebagai contoh, setelah pengujian pertama dilakukan, parameter uji terbaik yang diperoleh akan digunakan untuk pengujian selanjutnya, dan seterusnya. Hal ini dilakukan supaya hasil pengujian yang diperoleh optimal.

3.1 Pengujian dan Analisis Pengaruh Jenis Pola LBP


Pada pengujian pertama, sistem diuji menggunakan parameter jenis pola yang dipakai dalam operator LBP. Di sini, parameter yang diujikan meliputi *rotation invariant*, *uniform*, dan *rotation invariant uniform*. Pengujian ini dibantu dengan sejumlah parameter lain, antara lain jumlah titik piksel $P = 8$, ukuran radius $R = 1$, serta kernel linear untuk membantu proses klasifikasi. Hasil pengujian dapat dilihat pada Tabel 2 di bawah ini.

Tabel 2. Hasil Pengujian Pengaruh Jenis Pola LBP

Jenis pola	Akurasi	Sensitivitas	Spesifisitas
$LBP_{8,1}^{ri}$	77.39%	63.46%	85.10%
$LBP_{8,1}^{u2}$	82.87%	65.38%	92.55%
$LBP_{8,1}^{riu2}$	71.91%	42.30%	88.29%



Gambar 5. Kinerja Sistem Terhadap Pengaruh Jenis Pola LBP yang Dipakai



Gambar 6. Fitur yang Dihasilkan dari Pola LBP (a) *Rotation Invariant* (b) *Uniform* (c) *Rotation Invariant Uniform*


Berdasarkan hasil yang disajikan pada Tabel 2 dan Gambar 5 di atas, performansi sistem yang dihasilkan saat menggunakan pola *uniform* (u_2) secara keseluruhan mengungguli hasil dari dua jenis pola lainnya. Jumlah fitur yang dihasilkan ketika menggunakan pola ini pun terlihat jauh lebih banyak dibandingkan yang lainnya, sebagaimana yang ditunjukkan oleh Gambar 6. Dengan demikian, dari pengujian ini dapat diindikasikan bahwa jumlah fitur yang digunakan berbanding lurus dengan hasil yang diperoleh. Dalam hal ini, penggunaan pola *uniform* yang menghasilkan fitur lebih banyak mampu memberikan performansi sistem lebih optimal. Hal ini berbanding terbalik dengan pola *rotation invariant uniform* (riu_2) yang menghasilkan jumlah fitur paling sedikit, di mana performansi yang dihasilkan pun paling rendah. Performansi terbaik yang dicapai sistem menggunakan parameter ini berada pada angka 82.87% untuk akurasi, 65.38% untuk sensitivitas, dan 92.55% untuk spesifisitas.

3.2 Pengujian dan Analisis Pengaruh Ukuran Radius dalam Operator LBP

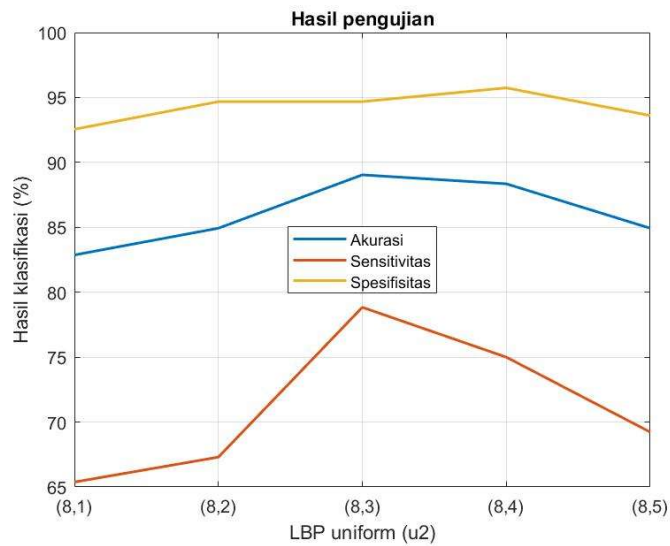
Pada pengujian kedua, sistem diuji menggunakan parameter ukuran radius (R) yang digunakan dalam operator LBP. Ukuran radius yang diujikan adalah ukuran yang umumnya sering digunakan, antara lain 1, 2, 3, 4, dan 5. Parameter jumlah titik piksel yang digunakan dalam pengujian ini adalah $P = 8$. Selain itu juga menggunakan pola *uniform* dan dibantu dengan kernel linear. Hasil pengujian dapat dilihat pada Tabel 3 berikut ini.

Tabel 3. Hasil Pengujian Pengaruh Ukuran Radius dalam Operator LBP

($8, R$)	Akurasi	Sensitivitas	Spesifisitas
$LBP_{8,1}^{u_2}$	82.87%	65.38%	92.55%
$LBP_{8,2}^{u_2}$	84.93%	67.30%	94.68%
$LBP_{8,3}^{u_2}$	89.04%	78.84%	94.68%
$LBP_{8,4}^{u_2}$	88.35%	75.00%	95.74%
$LBP_{8,5}^{u_2}$	84.93%	67.30%	94.68%



Gambar 7. Ketetanggaan Sirkular dengan Ukuran Radius yang Berbeda-beda



Gambar 8. Kinerja Sistem Terhadap Pengaruh Ukuran Radius yang Dipakai

Berdasarkan Tabel 3 di atas, kombinasi parameter LBP yang menghasilkan performansi terbaik adalah (8,3) atau saat radiusnya berjarak tiga piksel ($R = 3$). Seperti yang ditampilkan pada Gambar 7, peningkatan ukuran radius dalam sebuah ketetanggaan sirkular pada hakikatnya akan menyebabkan jarak antarpiksel tetangga terhadap titik pusatnya semakin menjauh. Dalam grafik yang disajikan pada Gambar 8, peningkatan ukuran radius ini pada awalnya memberikan dampak positif terhadap sistem, terbukti dari hasil percobaan pertama sampai ketiga, di mana kinerja sistem berturut-turut meningkat secara konstan. Akan tetapi, pada dua pengujian selanjutnya kinerja sistem yang dihasilkan tercatat semakin menurun. Maka dari itu, dari hasil ini dapat disimpulkan bahwa peningkatan ukuran radius memang dapat memberikan

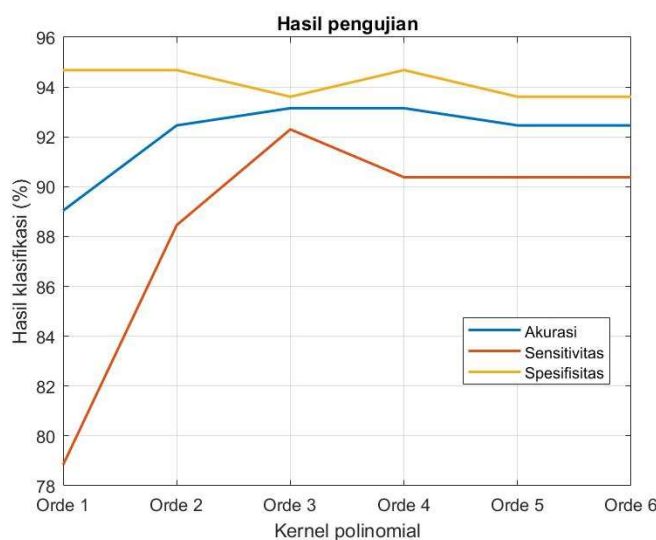
hasil klasifikasi yang lebih baik, tetapi apabila ukuran yang digunakan terlalu besar, hal ini justru membuat hasil klasifikasi menjadi tidak optimal. Dalam pengujian ini, kinerja sistem yang paling optimal dihasilkan pada pengujian ketiga, yaitu ketika $P = 8$ dan $R = 3$. Tingkat akurasi, sensitivitas, dan spesifisitas terbaik yang dihasilkan sistem berturut-turut sebesar 89.04%, 78,84%, dan 94.68%.

3.3 Pengujian dan Analisis Pengaruh Jenis Kernel SVM

Pada pengujian terakhir, sistem diuji menggunakan parameter jenis kernel SVM dalam tahapan klasifikasi. Terdapat empat jenis kernel yang diimplementasikan, antara lain kernel linear, rbf gaussian, polinomial, dan sigmoid. Khusus untuk kernel polinomial, proses pengujian akan dilakukan secara sistematis mengikuti orde yang digunakan, mulai dari 1, 2, 3 dan seterusnya sampai orde yang memberikan kinerja terbaik ditemukan. Parameter lain yang dipakai meliputi pola LBP *uniform* dengan kombinasi jumlah titik piksel dan radius (8,3). Hasil pengujian dapat dilihat pada Tabel 4 di bawah ini.

Tabel 4. Hasil Pengujian Pengaruh Jenis Kernel SVM

Kernel SVM	Akurasi	Sensitivitas	Spesifisitas
Linear	89.04%	78.84%	94.68%
RBF Gaussian	93.15%	90.38%	94.68%
Polinomial:			
Orde 1	89.04%	78.84%	94.68%
Orde 2	92.46%	88.46%	94.68%
Orde 3	93.15%	92.30%	93.61%
Orde 4	93.15%	90.38%	94.68%
Orde 5	92.46%	90.38%	93.61%
Orde 6	92.46%	90.38%	93.61%
Sigmoid	86.30%	73.07%	93.61%



Gambar 9. Kinerja Sistem Terhadap Jenis Kernel yang Dipakai

Berdasarkan Tabel 4 di atas, hasil menunjukkan bahwa dari keempat kernel yang diujikan, kernel polinomial orde tiga memberikan kinerja yang paling baik di antara yang lainnya. Lebih lanjut, kernel polinomial berderajat tiga atau kubik ini secara keseluruhan memberikan kinerja yang paling optimal di antara kernel polinomial orde lainnya. Salah satu keunggulan dari kernel polinomial terletak pada orde atau derajatnya yang dapat diperbesar, yang mana kondisi ini dapat meningkatkan probabilitas data dapat dipisah secara linear dalam ruang berdimensi tinggi. Akan tetapi, jika melihat Gambar 9 di atas, penggunaan kernel berderajat tinggi tidak selalu memberikan hasil pengujian yang lebih baik, terbukti pada percobaan keempat sampai keenam di mana kinerja sistem secara keseluruhan mengalami penurunan. Selain itu, penggunaan orde yang tinggi dapat meningkatkan kompleksitas proses komputasi pada model sistem. Maka dari itu, orde tiga yang digunakan dalam kernel polinomial dapat dikatakan yang paling optimal dalam memisahkan data atau vektor fitur ke dalam kelas yang sesuai.

4. KESIMPULAN

Dalam penelitian ini, pendekatan baru untuk mendeteksi glaukoma pada citra fundus retina telah diusulkan menggunakan metode *Local Binary Pattern* dan *Support Vector Machine*. Proses perancangan sistem mencakup tiga langkah utama, di antaranya *preprocessing* terhadap citra, ekstraksi fitur, dan klasifikasi. Pengujian dilakukan terhadap 146 citra fundus yang terdiri dari citra fundus sehat dan glaukoma. Dengan menggunakan metode yang diusulkan, sistem mampu memberikan performansi terbaik pada tingkat akurasi 93,15%, sensitivitas 92,30%, dan spesifisitas 93,61%. Hasil ini dicapai pada model sistem dengan parameter terbaik dari setiap pengujian yang dilakukan, yakni pola *uniform* dengan ukuran radius $R = 3$ pada operator deskripsi tekstur LBP serta kernel polinomial orde tiga pada pengklasifikasi SVM.

DAFTAR RUJUKAN

- Ahn, J. M., Kim, S., Ahn, K. S., Cho, S. H., Lee, K. B., & Kim, U. S. (2018). A deep learning model for the detection of both advanced and early glaucoma using fundus photography. *PLoS ONE*, *13*(11), 1–8.
- Al Rivan, M. E., & Juangkara, T. (2019). Identifikasi Potensi Glaukoma dan Diabetes Retinopati Melalui Citra Fundus Menggunakan Jaringan Syaraf Tiruan. *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*, *6*(1), 43–48.
- Batista, F. J. F., Diaz-Aleman, T., Sigut, J., Alayon, S., Arnay, R., & Angel-Pereira, D. (2020). RIM-ONE DL: A Unified Retinal Image Database for Assessing Glaucoma Using Deep Learning. *Image Analysis & Stereology*, *39*(3), 161–167.
- Cristianini, N., & Shawe-Taylor, J. (2000). *An Introduction to Support Vector Machines and other kernel-based learning methods*. Cambridge University Press.
- Dey, A., & Bandyopadhyay, S. (2016). Automated Glaucoma Detection Using Support Vector Machine Classification Method. *British Journal of Medicine and Medical Research*, *11*(12), 1–12.

- Horwath, J. P., Zakharov, D. N., Mégret, R., & Stach, E. A. (2020). Understanding important features of deep learning models for segmentation of high-resolution transmission electron microscopy images. *npj Computational Materials*, *6*(1), 1–9.
- InfoDATIN Kementerian Kesehatan RI. (2019). *Situasi Glaukoma di Indonesia* (hal. 1–9).
- Irawan, S., Hasan, Y., & Tampubolon, K. (2019). PENERAPAN METODE CLAHE UNTUK MEMPERJELAS OBJEK PANTULAN KACA PADA CITRA DIGITAL. *KOMIK (Konferensi Nasional Teknologi Informasi dan Komputer)*, *3*(1).
- Liu, L., Fieguth, P., Guo, Y., Wang, X., & Pietikäinen, M. (2017). Local binary features for texture classification: Taxonomy and experimental study. *Pattern Recognition*, *62*, 135–160.
- Men, S., Yan, L., Liu, J., Qian, H., & Luo, Q. (2017). A classification method for seed viability assessment with infrared thermography. *Sensors*, *17*(4), 845.
- Munarto, R., Permata, E., & Ginanjar, I. A. T. (2016). Klasifikasi Glaukoma Menggunakan Cup to Disk Ratio dan Neural Network. *Simposium Nasional RAPI XV – 2016 FT UMS*, (pp. 370–378).
- Mustofa, A., Tjandrasa, H., & Amaliah, B. (2016). Deteksi Penyakit Glaukoma pada Citra Fundus Retina Mata Menggunakan Adaptive Thresholding dan Support Vector Machine. *Jurnal Teknik ITS*, *5*(2).
- Nanda, M. A., Boro Seminar, K., Nandika, D., & Maddu, A. (2018). A comparison study of kernel functions in the support vector machine and its application for termite detection. *Information*, *9*(1), 5.
- Nanni, L., Lumini, A., & Brahmam, S. (2010). Local binary patterns variants as texture descriptors for medical image analysis. *Artificial intelligence in medicine*, *49*(2), 117–125.
- Nguyen, L. (2017). Tutorial on support vector machine. *Appl. Comput. Math*, *6*, 1–15.
- Prakasa, E. (2016). *Ekstraksi Ciri Tekstur dengan Menggunakan Local Binary Pattern Texture Feature Extraction by Using Local Binary Pattern*. *9*(2), 45–48.
- Song, K.-C., Yan, Y.-H., Chen, W.-H., & Zhang, X. (2013). Research and Perspective on Local Binary Pattern. *Acta Automatica Sinica*, *39*(6), 730–744.
- Tham, Y. C., Li, X., Wong, T. Y., Quigley, H. A., Aung, T., & Cheng, C. Y. (2014). Global prevalence of glaucoma and projections of glaucoma burden through 2040: A systematic review and meta-analysis. *Ophthalmology*, *121*(11), 2081–2090.
- Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*. Springer-Verlag.
- Wedianto, A., & Sari, H. L. (2016). Analisa Perbandingan Metode Filter Gaussian, Mean dan Median Terhadap Reduksi Noise. *Jurnal Media Infotama*, *12*(1).

- Weinreb, R. N., Aung, T., & Medeiros, F. A. (2014). The pathophysiology and treatment of glaucoma: A review. *JAMA - Journal of the American Medical Association*, *311*(18), 1901–1911.
- Xiong, L., Li, H., & Zheng, Y. (2014). Automatic detection of glaucoma in retinal images. *Proceedings of the 2014 9th IEEE Conference on Industrial Electronics and Applications, ICIEA 2014, 81271650*, (pp. 1016–1019).