

Deteksi Awal Penyakit Retinopati Hipertensi dengan Pendekatan Analisis Fraktal Citra Fundus Retina

Muhammad Yahya Kipti

Jurusan Informatika, Fakultas MIPA,
Universitas Sebelas Maret

Jl. Ir. Sutami 36 A Surakarta 57126

yahya_kipti@yahoo.com

Wiharto

Jurusan Informatika, Fakultas MIPA,
Universitas Sebelas Maret

Jl. Ir. Sutami 36 A Surakarta 57126

wi_harto@yahoo.com

Esti Suryani

Jurusan Informatika, Fakultas MIPA,
Universitas Sebelas Maret

Jl. Ir. Sutami 36 A Surakarta 57126

estisuryani@staff.uns.ac.id

ABSTRACT

Retinopati hipertensi adalah suatu kondisi dengan karakteristik perubahan vaskularisasi retina pada populasi yang menderita hipertensi. Keadaan pembuluh darah retina sering dipakai sebagai ukuran keadaan pembuluh darah organ tubuh lain, dan kelainan pada mata atau retina akibat hipertensi dapat digunakan sebagai petunjuk kelainan pembuluh darah otak, jantung, retinopati atau stroke. Penelitian ini mengusulkan suatu metode untuk diagnosa awal penyakit retinopati hipertensi menggunakan pendekatan analisis fraktal citra fundus retina serta penggunaan SVM (Support Vector Machine) untuk klasifikasi retina normal atau retinopati hipertensi. Tahap pertama dilakukan segmentasi terhadap citra fundus retina menggunakan green channel, CLAHE, average filter, background exclusion, thresholding, dan masking. Untuk ekstraksi ciri digunakan analisis fraktal menggunakan metode box counting untuk mendapatkan dimensi fraktal serta metode gliding box untuk mendapatkan lacunarity. Pengujian dilakukan menggunakan metode k-fold cross validation dengan k=5. Pada tiap pengujian menggunakan 3 macam kernel (linear, polynomial, dan radial) dan kombinasi ciri yang berbeda yaitu dimensi fraktal serta lacunarity dengan ukuran box 2^1 sampai 2^9 . Hasil pengujian berupa nilai accuracy 0.78, precision 0.77, sensitivity 0.8, specificity 0.76, dan AUC 0.76 menunjukkan bahwa kernel polynomial dengan menggunakan ciri dimensi fraktal dan lacunarity dengan ukuran box 2^7 memperoleh hasil yang paling baik dibandingkan dengan yang lain. Berdasarkan hasil penelitian, dapat disimpulkan bahwa deteksi retinopati hipertensi dengan pendekatan analisis fraktal memiliki kinerja yang cukup baik.

Keywords

Analisis Fraktal, Dimensi Fraktal, Lacunarity, Pengolahan Citra, Retinopati Hipertensi, Segmentasi.

1. PENDAHULUAN

Prevalensi hipertensi atau tekanan darah di Indonesia cukup tinggi. Selain itu, akibat yang ditimbulkannya menjadi masalah kesehatan bagi masyarakat [1]. Hipertensi merupakan salah satu faktor resiko yang paling berpengaruh terhadap penyakit jantung dan pembuluh darah (penyakit kardiovaskular). Hipertensi sering tidak menunjukkan gejala, sehingga baru disadari setelah menyebabkan gangguan organ seperti gangguan fungsi jantung, retinopati atau stroke [1]. Tidak jarang hipertensi ditemukan secara tidak sengaja pada waktu pemeriksaan kesehatan rutin atau datang dengan keluhan lain.


Sebagian besar kasus penyakit hipertensi di masyarakat belum terdiagnosa. Prevalensi hipertensi di Indonesia berdasarkan hasil pengukuran pada umur ≥ 18 tahun sebesar 25,8%. Jadi

cakupan nakes hanya 36,8%, sebagian besar (63,2%) kasus hipertensi di masyarakat tidak terdiagnosis [2]. Penyakit hipertensi merupakan penyakit yang jika tidak mendapat penanganan dengan baik akan menyebabkan komplikasi, salah satunya adalah retinopati hipertensi.

Retinopati hipertensi adalah suatu kondisi dengan karakteristik perubahan vaskularisasi retina pada populasi yang menderita hipertensi. Keadaan pembuluh darah retina sering dipakai sebagai ukuran keadaan pembuluh darah organ tubuh lain, dan kelainan pada mata atau retina akibat hipertensi dapat digunakan sebagai petunjuk kelainan pembuluh darah otak, jantung dan juga ginjal [3]. Untuk memastikan ada atau tidaknya penyakit retinopati hipertensi dilakukan dengan pemeriksaan funduskopi oleh dokter spesialis mata dengan menggunakan kamera fundus. Berdasarkan data depkes, jumlah dokter spesialis mata yang terdaftar di Konsil Kedokteran Indonesia (KKI) adalah sebanyak 1.455 orang, dengan distribusi 68% berada di pulau jawa, sedangkan 32% nya tersebar di luar pulau jawa [4]. Jumlah tersebut masih sangat rendah dan didukung distribusi yang tidak merata.

Pemeriksaan funduskopi bertujuan untuk mengetahui gambaran papil, pembuluh darah, retina, makula dan fovea. Pemeriksaan mata secara lengkap dilakukan oleh dokter spesialis mata, tetapi dokter umum bisa berperan dalam mendeteksi dini penyakit retinopati hipertensi dan dalam tata laksana retinopati hipertensi, salah satunya adalah mengendalikan tekanan darah yang tidak normal [5]. Terbatasnya jumlah dokter spesialis mata [4], dokter umum yang tersebar hampir di setiap puskesmas dapat lebih berperan dalam mendiagnosa, sehingga dapat menangani pasien retinopati hipertensi lebih awal.

Penyakit retinopati hipertensi diklasifikasikan menjadi 4 stadium. Stadium I salah satu karakteristiknya adalah *tortuosity arterioles retina*. Stadium II mempunyai karakteristik penyempitan definit pembuluh darah, stadium III dengan salah satu karakteristik retinopati (*cotton-wol spot*, *arteriosclerosis*, *hemoragik*) dan stadium IV salah satu karakteristiknya adalah *edema neuroretinal* termasuk *papilledema*, *garis siegrest*, *elschig spot* [6].



Gambar 1. a) Retina tortuosity, b) Retina non tortuosity [6]

Berdasarkan klasifikasi tersebut, karakteristik awal (stadium 1) penyakit retinopati hipertensi adalah *tortuosity arterioles*. *Tortuosity* merupakan gambaran pembuluh darah retina yang berliku-liku (lengkungan tajam, normalnya tidak tajam).

Perubahan pembuluh darah retina yang berupa *tortuosity arterioles* atau pembuluh darah retina yang berliku-liku (lengkungan tajam) tersebut dapat dianalisis menggunakan analisis fraktal. Penggunaan analisis fraktal dalam menganalisa citra fundus retina, dapat memberikan gambaran secara global terhadap arsitektur jaringan pembuluh darah retina. Analisis fraktal, mempunyai beberapa variabel diantaranya dimensi fraktal dan *lacunarity*. Dimensi fraktal dapat digunakan untuk mengetahui hubungan perubahan pembuluh darah retina terhadap mortalitas yang disebabkan penyakit jantung coroner [7]. Untuk mendeskripsikan karakteristik dari sebuah fraktal dari dimensi yang sama dengan tekstur yang berbeda menggunakan *Lacunarity* [8]. *Lacunarity* melengkapi dimensi fraktal yang hanya dapat mengetahui seberapa banyak tempat yang terisi data. *Lacunarity* digunakan untuk perhitungan distribusi dari derajat kekosongan (*lacunas*) dalam citra [9].

Berdasarkan gambaran permasalahan di atas, diperlukan sebuah metode yang dapat membantu dalam melakukan diagnosa awal terhadap penyakit retinopati hipertensi menggunakan analisis fraktal citra fundus retina.

2. DASAR TEORI

Terdapat beberapa teori yang mendukung dalam penelitian ini yaitu sebagai berikut.

2.1 Pengolahan Citra Digital

Pengolahan citra merupakan cara pemrosesan citra dengan menggunakan perangkat computer agar mudah diinterpretasi oleh manusia atau mesin. Pengolahan citra umumnya diterapkan untuk melakukan pemodifikasian, perubahan, penggabungan maupun perbaikan kualitas citra. Pada pengolahan citra, yang menjadi disiplin dalam pemrosesan gambar adalah input dan output [10].

Pada penelitian ini digunakan citra kanal hijau. Citra kanal hijau memiliki refleksi cahaya paling baik sehingga dapat dihasilkan informasi yang signifikan tentang pembuluh darah dan struktur retina lain. Citra kanal hijau didapatkan dari komposisi warna *Red* (merah), *Green* (hijau) dan *Blue* (biru) dalam suatu citra, seperti ditunjukkan pada persamaan di bawah :

$$g = 0.2989 * R + 0.5870 * G + 0.1140 * B \quad (1)$$

Di mana R, G, dan B merepresentasikan komponen warna merah, hijau dan biru [11].

2.2 Perbaikan Citra

Tidak semua citra masukan bisa layak langsung dilakukan klasifikasi atau segmentasi. Ketidaklayakan itu disebabkan karena kualitas citra yang kurang baik sehingga apabila langsung dilakukan proses segmentasi hasilnya kurang akurat. Banyak faktor-faktor penyebab mengapa suatu citra memiliki kualitas yang kurang baik, salah satunya adalah kontras yang terlalu gelap atau terang. Kontras menyatakan sebaran terang (*lightness*) dan gelap (*darkness*) di dalam sebuah gambar. Secara intuitif kontras citra dapat dibedakan menjadi tiga kategori [12], yaitu:

- Kontras rendah: citra nampak gelap atau sangat terang. Karakteristik pada histogramnya terkelompok pada suatu nilai grayscale tertentu.

- Kontras bagus: pada kontras bagus suatu citra memiliki karakteristik histogram citranya memiliki sebaran yang relatif seragam.
- Kontras tinggi: citra dengan kontras yang tinggi didominasi oleh warna gelap atau terang. Ciri pada histogram terlihat dua puncak maksimum.

2.2.1 CLAHE

Permasalahan peningkatan kontras yang terlalu over pada AHE dapat diatasi dengan menggunakan CLAHE (*Contrast Limited Adaptive Histogram Equalization*), yaitu memberikan nilai batas pada histogram. Nilai batas ini disebut dengan *clip limit* dimana menyatakan batas maksimum tinggi suatu histogram. Cara menghitung

g clip limit suatu histogram dapat didefinisikan sebagai berikut:

$$\beta = \frac{M}{N} \left(1 + \frac{\alpha}{100} (s_{max} - 1) \right) \quad (2)$$

Variabel M menyatakan luas region size, N menyatakan nilai grayscale (256) dan N merupakan clip faktor menyatakan penambahan batas limit suatu histogram yang bernilai antara 0 sampai 100. Histogram diatas nilai *clip limit* dianggap kelebihan (excess) piksel yang akan didistribusikan kepada area sekitar dibawah *clip limit* sehingga histogram merata. Ilustrasi distribusi excess piksel pada Persamaan 2.

2.2.2 Average Filter

Average Filter adalah salah satu yang paling sederhana dari operasi lokal atas gambar, yang juga disebut sebagai "Metode rata-rata lingkungan" [13]. Ide esensial dari standar average filter adalah untuk mengganti nilai pusat pixel $g(x, y)$ dengan nilai rata-rata dari sejumlah standar dari piksel tetangga $g(x, y)$ seperti yang ditunjukkan pada :

$$g(x, y) = \frac{1}{N \times M} \sum_{i=1}^{N \times M} g_i \quad (3)$$

M dan N adalah ukuran pixel filter yang digunakan.

2.2.3 Masking

Masking citra merupakan teknik untuk memisahkan suatu objek tertentu (yang diinginkan) dengan objek lain (yang tidak diinginkan) dengan berdasarkan pengelompokan nilai spektral pada data digital. Nilai digital yang dikelompokkan (kelas) akan menghasilkan layar dengan nilai digital baru dengan nilai biner (0-1). Citra hasil filtering dilakukan masking agar nantinya latar belakang (*background*) berwarna hitam pada citra retina, tidak dihitung sebagai obyek.

2.2.4 Thresholding

Thresholding atau dalam bahasa Indonesia pengembangan merupakan sebuah metode yang paling sederhana untuk melakukan segmentasi. Operasi *thresholding* membagi citra menjadi dua wilayah, yaitu wilayah objek dan wilayah latar belakang. Wilayah objek diset berwarna putih sedangkan sisanya diset berwarna hitam (atau sebaliknya). Hasil dari operasi pengembangan adalah citra biner yang hanya mempunyai dua derajat keabuan : hitam dan putih [12].

Teknik *thresholding* dapat dilakukan dengan melakukan pengecekan terhadap fungsi T dalam bentuk persamaan

$$T = T[x, y, p(x, y), f(x, y)] \quad (4)$$

Dimana $p(x,y)$ adalah nilai piksel dari suatu titik tertentu dan $f(x,y)$ merupakan intensitas piksel (x,y) . Kemudian citra dengan threshold tersebut akan dibagi menjadi dua bagian dengan definisi seperti berikut

$$g(x,y) = \begin{cases} 1, & \text{jika } f(x,y) > T \\ 0, & \text{jika } f(x,y) \leq T \end{cases} \quad (5)$$

Piksel dengan nilai 1 menunjukkan objek, sedangkan piksel bernilai 0 adalah latar belakang citra. Global thresholding adalah posisi dimana T hanya tergantung pada $f(x,y)$, sedangkan local thresholding adalah posisi dimana T tergantung pada $f(x,y)$ dan nilai $p(x,y)$. Apabila T tergantung pada koordinat x dan y , maka disebut dengan dynamic thresholding atau adaptive thresholding. [10].

2.3 Analisis Fraktal

2.3.1 Fraktal

Fraktal berasal dari bahasa latin yaitu fractus yang berarti pecah (broken) atau tidak teratur (irregular). Pada dasarnya, fraktal merupakan geometri sederhana yang dapat dipecah-pecah menjadi beberapa bagian yang memiliki bentuk seperti bentuk sebelumnya dengan ukuran yang lebih kecil [9]. Fraktal memiliki sifat-sifat *self-similarity*, *self-affinity*, *self-inverse*, dan *self-squaring*. Sifat *self-similarity* menunjukkan bahwa fraktal terdiri atas bagian-bagian yang berbentuk serupa satu sama lain. *Self-affinity* menggambarkan bahwa fraktal disusun atas bagian-bagian yang saling terangkai satu sama lain. *Self-inverse* artinya suatu bagian dari fraktal dapat merupakan susunan terbalik dari susunan lainnya, sedangkan *self-squaring* dapat diartikan bahwa suatu bagian dari fraktal merupakan peningkatan kerumitan dari bagian terdahulu [14]. Fraktal adalah segala bentuk yang memiliki kemiripan dengan dirinya sendiri [8].

2.3.2 Dimensi Fraktal

Fraktal memiliki dimensi yang berbeda dengan dimensi benda dalam kehidupan sehari-hari yang merupakan dimensi ruang Euclid, yaitu 1, 2, dan 3. Nilai dimensi pada objek-objek Euclid berupa bilangan bulat. Misalnya garis berdimensi 1 karena memiliki panjang, bidang berdimensi 2 karena memiliki panjang dan lebar, sedangkan ruang memiliki dimensi 3 karena memiliki panjang, lebar dan kedalaman.

Metode untuk menghitung dimensi fraktal suatu citra ialah metode Box Counting yang dinyatakan dengan Persamaan (2.6). Konsepnya ialah membagi citra menjadi persegi-persegi yang lebih kecil dengan ukuran tertentu.

$$D = \frac{\log(N)}{\log(1/r)} \quad (6)$$

dengan N banyaknya kotak yang berisi objek, D dimensi fraktal objek, dan r adalah rasio.

Adapun langkah-langkah metode Box Counting menurut Backes & Bruno adalah sebagai berikut [15] :

- Citra dibagi ke dalam kotak-kotak dengan ukuran r . nilai r berubah dari 1 sampai $2k$, dengan $k = 0, 1, 2, \dots$ dan seterusnya, dan $2k$ tidak boleh lebih besar dari ukuran citra. Bila citra berukuran $2m \times 2m$ maka nilai k akan berhenti sampai m .
- Menghitung banyaknya kotak N yang berisi bagian-bagian objek pada citra. Nilai N sangat tergantung pada r .

- Menghitung nilai $\log(1/r)$ dan $\log(N)$.
- Membuat garis lurus menggunakan nilai $\log(1/r)$ dan $\log(N)$.
- Menghitung kemiringan (slope) dari garis lurus dengan persamaan (7) [11]. Nilai slope ini merupakan dimensi fraktal dari citra berdasarkan persamaan (2.8).

$$\alpha = \frac{(\sum_{k=1}^n xy) - \frac{(\sum_{k=1}^n x)(\sum_{k=1}^n y)}{n}}{(\sum_{k=1}^n x^2) - \frac{(\sum_{k=1}^n x)^2}{n}} \quad (7)$$

$$FD = -\alpha \quad (8)$$

dengan α adalah nilai kemiringan (*slope*), n banyaknya data yang digunakan, x adalah nilai $\log(1/r)$, y adalah nilai $\log(N)$, dan FD adalah nilai dimensi fraktal.

2.3.3 Lacunarity

Teknik untuk menghitung Lacunarity pertama kali diperkenalkan secara umum oleh Mandelbort [8]. Banyak metode yang bisa digunakan untuk menghitung nilai Lacunarity suatu citra. Metode yang paling sering digunakan adalah metode Gliding box yang diperkenalkan oleh Allain dan Cloitre dan dipopulerkan oleh Plotnick et al. Allain dan Cloitre memulai konsep langsung dan perhitungan yang mudah dalam metode Gliding Box untuk menghitung nilai Lacunarity [16].

Menurut metode ini, sebuah kotak tertentu dengan ukuran sisi r , memproses seluruh citra yang akan dicari nilai Lacunarity-nya dengan mendata massa kotak, S . Langkah-langkah metode Gliding Box ini dimulai dengan cara menempatkan *box* atau kotak persegi dengan ukuran citra $r \times r$ di pojok kiri atas citra, selanjutnya kotak tersebut akan mengecek setiap piksel yang berisi 1 atau 0 sampai akhirnya seluruh piksel terlewati oleh *box* tersebut. Kotak ini bergerak dari pojok kiri atas citra melewati piksel per piksel dari citra tersebut sampai akhirnya seluruh piksel dalam citra teridentifikasi. Saat kotak ini berada pada piksel tertentu, program akan menghitung setiap nilai piksel yang dilewati yang dianggap sebagai objek dalam citra tersebut.

Frekuensi dari distribusi isi piksel yang didapat dalam setiap *box* dilambangkan dengan $n(M, r)$ yang selanjutnya akan digunakan untuk menentukan $Q(M, r)$ sebagai distribusi peluang dari setiap nilai dalam *box* yang didapat dari pembagian distribusi per piksel dengan jumlah total maksimal dari jalannya *box* tersebut yang dilambangkan dengan $N(r)$. Selanjutnya kedua distribusi tersebut akan diproses dengan rumus berikut :

$$Z(1) = \sum M Q(M, r) \quad (9)$$


$$Z(2) = \sum M^2 Q(M, r) \quad (10)$$

Dari kedua persamaan di atas didapat rumus untuk menghitung *lacunarity* dengan ukuran *box* r , $\Lambda(r)$ sebagai berikut :

$$\Lambda(r) = \frac{Z(2) - (Z(1))^2}{(Z(1))^2} \quad (11)$$

2.4 Support Vector Machine

SVM dapat dijelaskan secara sederhana sebagai usaha mencari *hyperplane* terbaik yang berfungsi sebagai pemisah dua buah kelas pada *input space pattern* yang merupakan anggota dari dua buah kelas : +1 dan -1 dan berbagi alternative garis pemisah (*discrimination boundaries*). Margin adalah jarak antara *hyperplane* tersebut dengan *pattern* terdekat dari masing-masing kelas. *Pattern* yang paling dekat ini disebut sebagai *support vector*. Usaha untuk mencari lokasi *hyperplane* ini merupakan inti dari proses pembelajaran pada SVM [17].



Gambar 2.1 Hyperlane pada SVM [17]

Pada gambar 2.1 dapat kita lihat *plane* pemisah yang memisahkan semua obyek berdasarkan *class*. pertama dan *plane* kedua membatasi *class* ke dua, sehingga dapat diperoleh persamaan. Data yang tersedia dinotasikan sebagai $\vec{x} \in \mathbb{R}^d$ sedangkan label masing-masing dinotasikan $y_i \in \{-1, +1\}$ untuk $i = 1, 2, \dots, l$, yang mana l adalah banyaknya data. Diasumsikan kedua kelas -1 dan $+1$ dapat terpisah secara sempurna oleh *hyperplane* berdimensi d , yang didefinisikan :

$$\vec{w} \cdot \vec{x} + b = 0 \quad (12)$$

Keterangan :

\vec{x} = vector input

\vec{w} = vector bobot

b = bias

Pattern \vec{x} yang termasuk kelas -1 (sampel negatif) dapat dirumuskan sebagai *pattern* yang memenuhi pertidaksamaan :

$$\vec{w} \cdot \vec{x} + b \leq -1 \quad (13)$$

Sedangkan *pattern* \vec{x} yang termasuk kelas $+1$ (sampel positif) memenuhi pertidaksamaan :

$$\vec{w} \cdot \vec{x} + b \geq +1 \quad (14)$$

Margin terbesar dapat ditemukan dengan memaksimalkan nilai jarak Antara *hyperplane* dan titik terdekatnya, yaitu $1/\|\vec{w}\|$. Hal ini dapat dirumuskan sebagai *Quadratic Programming (QP) Problem*, yaitu mencari titik minimal persamaan (5) dengan memperhatikan *constraint* persamaan (8).

$$\min_{\vec{w}} \tau(\vec{w}) = \frac{1}{2} \|\vec{w}\|^2 \quad (15)$$

$$y_i(\vec{x}_i \cdot \vec{w} + b) - 1 \geq 0, \forall i \quad (16)$$

Keterangan :

$\min_{\vec{w}} \tau(\vec{w})$ = quadratic problem

$\frac{1}{\|\vec{w}\|}$ = jarak antara *hyperlane* dengan titik terdekat

Problem ini dapat dipecahkan dengan berbagai teknik komputasi, diantaranya dengan *Lagrange Multiplier*.

$$L(w, b, \alpha) = \frac{1}{2} \|\vec{w}\|^2 - \sum_{i=1}^l \alpha_i (y_i((\vec{x}_i \cdot \vec{w}_i + b) - 1)) \quad (17)$$

Keterangan :

L = *Lagrange Multiplier*.

α_i = nilai bobot setiap titik

y_i = nilai output

Nilai optimal dari Persamaan (19) dapat dihitung dengan meminimalkan L terhadap \vec{w} dan b , dan memaksimalkan L terhadap α_i . Dengan memperhatikan sifat bahwa pada titik *optimal*

gradient $L = 0$, persamaan (17) dapat dimodifikasi sebagai maksimalisasi problem yang hanya mengandung α_i , sebagaimana persamaan (18) berikut.


Maksimasi :

$$\sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j \vec{x}_i \vec{x}_j \quad (18)$$

Dengan *constraint* :

$$\alpha_i \geq 0 \quad (i = 1, 2, 3, \dots, l) \quad \sum_{i=1}^l \alpha_i y_i = 0 \quad (19)$$

Dari hasil perhitungan ini diperoleh α_i yang kebanyakan bernilai positif. Data yang berkorelasi dengan α_i yang positif inilah yang disebut sebagai *support vector*. Ada kalanya dua buah *class* tidak dapat dipisahkan secara linear. Untuk menyelesaikan problem *non linear*, SVM dimodifikasi dengan memasukkan fungsi kernel. Dalam non linear SVM, pertama-tama data x dipetakan oleh fungsi Φ ke ruang vektor yang berdimensi lebih tinggi. Pada ruang vektor yang baru ini, *hyperplane* yang memisahkan kedua *class* tersebut dapat dikonstruksikan



Gambar 2.2 Fungsi Φ memetakan data ke ruang vector yang lebih tinggi [9]

Hal ini disebut sebagai *Kernel Trick*, yang dirumuskan

$$K(\vec{x}_i, \vec{x}_j) = \Phi(\vec{x}_i) \cdot \Phi(\vec{x}_j) \quad (20)$$

Keterangan :

$K(\vec{x}_i, \vec{x}_j)$ = fungsi *kernel*

Φ = fungsi pemetaan dari ruang *input* ke ruang *vector*

Kernel trick memberikan berbagai kemudahan, karena dalam proses pembelajaran SVM, untuk menentukan *support vector*, kita hanya cukup mengetahui fungsi kernel yang dipakai, dan tidak perlu mengetahui wujud dari fungsi non linear Φ . Berikut adalah kernel yang umum dipakai dalam SVM.

Tabel 2.1. Kernel dalam SVM [17]

Jenis Kernel	Definisi
Linear	$K(\vec{x}_i, \vec{x}_j) = (\vec{x}_i \cdot \vec{x}_j)$
Polynomial	$K(\vec{x}_i, \vec{x}_j) = (\vec{x}_i \cdot \vec{x}_j + 1)^p$
Radial	$K(\vec{x}_i, \vec{x}_j) = \exp\left(-\frac{\ \vec{x}_i - \vec{x}_j\ ^2}{2\sigma^2}\right)$

Selanjutnya hasil klasifikasi dari data \vec{x} diperoleh dari persamaan berikut :

$$f(\Phi(\vec{x})) = \vec{w} \cdot \Phi(\vec{x}) + b \quad (21)$$

$$= \sum_{i=1; \vec{x}_i \in SV}^n \Phi(\vec{x}_i) \cdot \Phi(\vec{x}_j) + b \quad (22)$$

$$= \sum_{i=1; \vec{x}_i \in SV}^n \alpha_i y_i K(\vec{x}_i, \vec{x}_j) + b \quad (23)$$

SV pada persamaan di atas dimaksudkan dengan *subset* dari *training set* yang terpilih sebagai *support vector*, dengan kata lain data \vec{x}_i yang berkorespondensi pada $\alpha_i \geq 0$.

3. METODE PENELITIAN

3.1 Studi Literatur dan Pemahaman

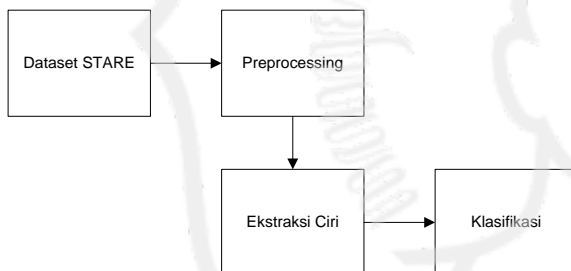
Studi literatur dilaksanakan dengan melakukan studi kepustakaan untuk memahami teori yang berasal dari buku maupun artikel dan jurnal yang bersumber dari internet. Studi kepustakaan dilakukan untuk mempelajari hal-hal yang berhubungan dengan penelitian secara umum, literatur tentang retinopati hipertensi, analisis fraktal, segmentasi citra digital untuk pengenalan pola dan ekstraksi ciri, serta pengklasifikasian menggunakan SVM.

3.2 Pengumpulan Data

Data citra retina yang digunakan dalam penelitian ini menggunakan dataset STARE (*Structured Analysis of the Retina*)[18]. Data yang diperoleh berupa citra retina yang sudah teridentifikasi sebagai retina sehat dan retinopati hipertensi.

3.3 Implementasi

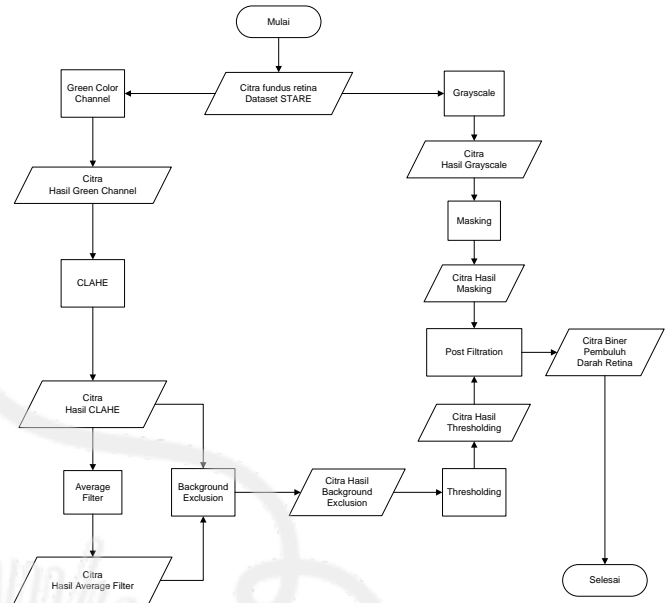
Tahap implementasi diawali *preprocessing* citra fundus retina. Pada tahap ini citra fundus retina akan dipisahkan antara pembuluh darah retina dan background dan diubah menjadi citra biner untuk kemudian dilakukan ekstraksi ciri. Ekstraksi ciri akan menghasilkan 2 parameter, yaitu dimensi fraktal dan *lacunarity*. Hasil ekstraksi ciri dari seluruh data kemudian dilakukan klasifikasi antara citra retina normal dan citra retinopati hipertensi.



Gambar 3.1 Diagram alir implementasi penelitian

3.3.1 Segmentasi

Pada tahapan ini, akan melakukan tahap *preprocessing* dan segmentasi sejumlah data citra retina sehat dan retinopati hipertensi (komposisinya sama). Citra hasil akuisisi kamera fundus berupa citra berwarna, sehingga terlebih dahulu perlu dilakukan proses skala keabuan untuk mendapatkan citra dengan aras keabuan. Skala keabuan suatu citra mempunyai 4 jenis yaitu skala keabuan biasa, kanal merah, kanal hijau dan kanal biru. Dari ke 4 jenis tersebut, citra kanal hijau memiliki refleksi cahaya yang paling baik sehingga dapat dihasilkan informasi yang signifikan tentang pembuluh darah dan struktur retina. Setelah proses green channel, maka dilakukan proses CLAHE (*Contrast Limited Adaptive Histogram Equalization*) untuk mendapatkan citra yang lebih baik kualitasnya. Proses berikutnya dilakukan *filtering* menggunakan average filter untuk menghilangkan derau. Proses berikutnya adalah *masking* untuk menghilangkan tepi citra retina. Kemudian langkah terakhir dilakukan proses *thresholding* untuk merubah kedalam citra biner.



Gambar 3.2. Diagram alir segmentasi citra

3.3.2 Ekstraksi Ciri

Pada tahapan ini citra hasil keluaran pada tahap *preprocessing* kemudian dilakukan analisis fraktal. Analisis ini untuk mendapatkan dimensi fraktal dengan menggunakan metode *box counting* dan metode *gliding box* untuk mendapatkan *lacunarity*.

3.3.3 Klasifikasi

Tahapan klasifikasi menggunakan algoritma *Support Vector Machine* (SVM). Keluaran tahap analisis fraktal berupa dimensi fraktal dan *lacunarity* dari sejumlah citra (yang terdiri dari kelompok citra retina sehat dan retinopati hipertensi digunakan sebagai *input* SVM).

3.3.4 Pengujian

Metode yang dilakukan untuk pengujian adalah *k-fold cross validation* dengan nilai $k = 5$. Pada metode ini data dibagi menjadi k bagian secara acak, kemudian dilakukan k kali eksperimen di mana masing-masing eksperimen menggunakan bagian data ke k sebagai data *testing* dan memanfaatkan bagian lainnya sebagai data *training*.

Tabel 3.1 Pembagian data *training* dan *testing*

$k = 1$	$k = 2$	$k = 3$	$k = 4$	$k = 5$
Data1	Data11	Data 21	Data31	Data41
Data2	Data12	Data22	Data32	Data42
...
Data10	Data20	Data30	Data40	Data50

Eksperimen 1 : data saat $k = 1$ digunakan sebagai data *testing* dan data saat $k = 2,3,4,5$ digunakan sebagai data *training*.

Eksperimen 2 : data saat $k = 2$ digunakan sebagai data *testing* dan data saat $k = 1,3,4,5$ digunakan sebagai data *training*.

Eksperimen 3 : data saat $k = 3$ s digunakan sebagai data *testing* dan data saat $k = 1,2,4,5$ digunakan sebagai data *training*.

Eksperimen 4 : data saat $k = 4$ digunakan sebagai data *testing* dan data saat $k = 1,2,3,5$ digunakan sebagai data *training*.

Eksperimen 5 : data saat $k = 5$ digunakan sebagai data *testing* dan data saat $k = 1,2,3,4$ digunakan sebagai data *training*.

3.4 Analisis Hasil

Analisis yang dilakukan dengan menggunakan perhitungan Confusion Matrix untuk menentukan 4 parameter yaitu precision, specificity, sensitivity dan accuracy [19] dari hasil pengujian yang telah dilakukan.

$$\text{Precision} = \frac{TP}{TP+FP} \times 100\%$$

$$\text{Sensitivity / Recall} = \frac{TP}{TP+FN} \times 100\%$$

$$\text{Specificity} = \frac{TN}{TN+FP} \times 100\%$$

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \times 100\%$$

dimana,

TP adalah citra retina retinopati diprediksi retinopati.

TN adalah citra retina sehat diprediksi retina sehat.

FP adalah citra retina sehat diprediksi retinopati.


FN adalah citra retina retinopati diprediksi retina sehat.

4. HASIL DAN PEMBAHASAN


4.1 Segmentasi Citra Fundus Retina

Segmentasi citra retina yang dilakukan pada penelitian ini melalui beberapa tahapan seperti yang telah dijelaskan pada bagian metodologi. Segmentasi citra dilakukan pada citra berukuran 700x605 piksel sebanyak 50 citra yang terbagi atas 25 citra retina terdiagnosa retinopati hipertensi dan 25 citra retina normal. Tujuan dari proses segmentasi adalah untuk memisahkan pembuluh darah retina dengan objek lainnya sehingga didapatkan citra biner dengan background berwarna hitam dan pembuluh darah retina berwarna putih.

Di bawah ini merupakan contoh hasil *preprocessing* dan segmentasi citra untuk masing-masing citra retinopati hipertensi dan citra retina normal :



Gambar 4.1 Citra Hasil Segmentasi untuk Citra Retinopati Hipertensi



Gambar 4.2. Citra Hasil Segmentasi untuk Citra Retina Normal

Keterangan gambar :

- (a) Citra asli dari dataset STARE
- (b) Citra kanal hijau
- (c) Citra setelah dilakukan perbaikan contrast CLAHE
- (d) Citra setelah dilakukan filtering *average*
- (e) Citra setelah dilakukan pembersihan *background*
- (f) Citra setelah dilakukan *thresholding*
- (g) Citra *mask*
- (h) Citra hasil akhir

Pengujian hasil segmentasi dilakukan dengan membandingkan menggunakan 20 citra hasil segmentasi yang dilakukan secara manua. Dari hasil pengujian didapatkan nilai akurasi 0.9482, TPR 0.7195, dan FPR 0.0328

4.2 Ekstraksi Ciri



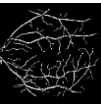
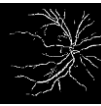
Setelah citra dilakukan preprocessing dan segmentasi untuk mendapatkan citra pembuluh darah retina, kemudian dilakukan analisis fraktal untuk mendapatkan nilai dimensi fraktal dan lacunarity dari masing-masing citra. Nilai dimensi fraktal didapatkan dari perhitungan menggunakan metode *Box Counting*. Sedangkan nilai *lacunarity* didapatkan dari perhitungan menggunakan metode *Gliding Box*. Ukuran box yang digunakan untuk perhitungan lacunarity adalah $2^1, 2^2, 2^3, 2^4, 2^5, 2^6, 2^7, 2^8$, dan 2^9 . Berikut ini ditampilkan beberapa hasil dari analisis fraktal untuk citra retina retinopati hipertensi:

Tabel 4.3 Sampel Hasil Analisis Fraktal untuk Citra Retinopati Hipertensi

	Citra				
	fd	1.5827	1.6349	1.6516	1.5304
L a c u n a r i t y	2^1	6.4665	4.9875	4.5008	8.8571
	2^2	4.9351	3.8732	3.5149	7.0244
	2^3	3.0335	2.4143	2.2353	4.6053
	2^4	1.4666	1.1185	1.0581	2.3548
	2^5	0.6649	0.5466	0.5116	1.1536
	2^6	0.2826	0.2635	0.2583	0.5806
	2^7	0.1009	0.0911	0.1105	0.2470
	2^8	0.0088	0.0161	0.0316	0.0479
	2^9	0.0015	0.0007	0.0022	0.0063

Berikut ini ditampilkan beberapa hasil dari analisis fraktal untuk citra retina normal:

Tabel 4.4 Sampel Hasil Analisis Fraktal untuk Citra Retina Normal

Citra					
fd		1.4484	1.5247	1.5082	1.4302
L a c u n a r i t y	2 ¹	11.034	9.0509	8.1649	10.1949
	2 ²	9.0095	6.7333	6.4779	8.5226
	2 ³	6.1535	4.0804	4.2654	5.9469
	2 ⁴	3.3759	2.0762	2.1751	3.2241
	2 ⁵	1.7863	1.0300	0.9792	1.5624
	2 ⁶	1.0063	0.5104	0.4217	0.7874
	2 ⁷	0.4901	0.2186	0.1394	0.3915
	2 ⁸	0.1643	0.0966	0.0131	0.1581
	2 ⁹	0.0013	0.0069	0.0011	0.0044

Di bawah ini ditampilkan nilai rata-rata dimensi fraktal dan lacunarity untuk citra retina normal dan retinopati hipertensi.

Tabel 4.5 Nilai Rata-rata Dimensi Fraktal dan Lacunarity

		Retina Normal	Retinopati Hipertensi
FD		1.48784	1.552076
L a c u n a r i t y	2 ¹	9.731643	7.878516
	2 ²	7.72954	6.141145
	2 ³	5.105688	3.949537
	2 ⁴	2.72909	2.021429
	2 ⁵	1.390628	1.008944
	2 ⁶	0.725257	0.517033
	2 ⁷	0.33696	0.219349
	2 ⁸	0.110541	0.055314
	2 ⁹	0.003749	0.002738

4.3 Klasifikasi dan Analisis Hasil

Dari hasil analisis fraktal yang berupa dimensi fraktal dan lacunarity tersebut, kemudian dilakukan klasifikasi hasil menggunakan SVM. Proses pelatihan (training) dan pengujian (testing) dilakukan menggunakan metode *k-fold cross validation* dengan nilai $k = 5$. Di bawah ini ditampilkan hasil pengujian dengan menggunakan 3 kernel yang berbeda :

Tabel 4.7 Hasil Pengujian menggunakan Kernel Linear

Ciri	TP	FP	TN	FN	Acc	Prec	Sensi	Spesi	AUC
fd	19	9	16	6	0.7	0.68	0.76	0.64	0.7
fd_lac1	19	9	16	6	0.7	0.68	0.76	0.64	0.72
fd_lac2	18	9	16	7	0.68	0.67	0.72	0.64	0.72
fd_lac3	18	8	17	7	0.7	0.69	0.72	0.68	0.72

fd_lac4	18	8	17	7	0.7	0.69	0.72	0.68	0.68
fd_lac5	19	9	16	6	0.7	0.68	0.76	0.64	0.7
fd_lac6	19	10	15	6	0.68	0.66	0.76	0.6	0.7
fd_lac7	19	10	15	6	0.68	0.66	0.76	0.6	0.72
fd_lac8	19	10	15	6	0.68	0.66	0.76	0.6	0.7
fd_lac9	19	9	16	6	0.7	0.68	0.76	0.64	0.72
all	17	10	15	8	0.64	0.63	0.68	0.6	0.7

Tabel 4.8 Hasil Pengujian menggunakan Kernel Polynomial

Ciri	TP	FP	TN	FN	Acc	Prec	Sensi	Spesi	AUC
fd	17	9	16	8	0.66	0.65	0.68	0.64	0.72
fd_lac1	15	1	24	10	0.78	0.94	0.6	0.96	0.74
fd_lac2	14	0	25	11	0.78	1	0.56	1	0.76
fd_lac3	16	3	22	9	0.76	0.84	0.64	0.88	0.74
fd_lac4	16	6	19	9	0.7	0.73	0.64	0.76	0.62
fd_lac5	18	5	20	7	0.76	0.78	0.72	0.8	0.7
fd_lac6	18	7	18	7	0.72	0.72	0.72	0.72	0.7
fd_lac7	20	6	19	5	0.78	0.77	0.8	0.76	0.76
fd_lac8	16	11	14	9	0.6	0.59	0.64	0.56	0.64
fd_lac9	18	8	17	7	0.7	0.69	0.72	0.68	0.72
all	15	10	15	10	0.6	0.6	0.6	0.6	0.66

Tabel 4.9 Hasil Pengujian menggunakan Kernel Radial

Ciri	TP	FP	TN	FN	Acc	Prec	Sensi	Spesi	AUC
fd	16	8	17	9	0.66	0.67	0.64	0.68	0.7
fd_lac1	14	3	22	11	0.72	0.82	0.56	0.88	0.72
fd_lac2	14	5	20	11	0.68	0.74	0.56	0.8	0.7
fd_lac3	15	4	21	10	0.72	0.79	0.6	0.84	0.68
fd_lac4	16	6	19	9	0.7	0.73	0.64	0.76	0.66
fd_lac5	17	8	17	8	0.68	0.68	0.68	0.68	0.7
fd_lac6	18	8	17	7	0.7	0.69	0.72	0.68	0.74
fd_lac7	18	7	18	7	0.72	0.72	0.72	0.72	0.76
fd_lac8	15	8	17	10	0.64	0.65	0.6	0.68	0.72
fd_lac9	18	9	16	7	0.68	0.67	0.72	0.64	0.7
all	14	1	24	11	0.76	0.93	0.56	0.96	0.72

Keterangan Tabel 4.7, 4.8, dan 4.9

fd = dimensi fraktal

fd_lac1 = dimensi fraktal dan lacunarity dengan ukuran box 2¹

fd_lac2 = dimensi fraktal dan lacunarity dengan ukuran box 2²

fd_lac3 = dimensi fraktal dan lacunarity dengan ukuran box 2³

fd_lac4 = dimensi fraktal dan lacunarity dengan ukuran box 2⁴

fd_lac5 = dimensi fraktal dan lacunarity dengan ukuran box 2⁵

fd_lac6 = dimensi fraktal dan lacunarity dengan ukuran box 2⁶

fd_lac7 = dimensi fraktal dan lacunarity dengan ukuran box 2⁷

fd_lac8 = dimensi fraktal dan lacunarity dengan ukuran box 2⁸

fd_lac9 = dimensi fraktal dan lacunarity dengan ukuran box 2⁹

Acc = Accuracy

Prec = Precision

Sensi = *Sensitivity*

Spesi = *Specificity*


AUC = *Area Under Curve*

Nilai maximal AUC adalah 1 yang menunjukkan sebagai *classifier* sempurna. Semakin tinggi nilai AUC mengindikasikan semakin baik pula kinerja *classifier*.

4.4 Pembahasan

4.4.1 Segmentasi

Untuk menguji hasil segmentasi, dilakukan pengujian menggunakan 20 citra hasil segmentasi secara manual. Pengujian dilakukan dengan membandingkan citra hasil segmentasi penelitian ini dengan citra hasil segmentasi secara manual untuk mendapatkan akurasi, TPR, dan FPR.



Gambar 4.2 Perbandingan hasil segmentasi

Gambar 4.2 menunjukkan salah satu contoh hasil segmentasi. Gambar 4.2 (a) merupakan hasil segmentasi yang dilakukan pada penelitian ini sedangkan Gambar 4.2 (b) merupakan hasil segmentasi secara manual oleh peneliti Adam Hoover. Hasil pengujian untuk 20 citra didapatkan *accuracy* sebesar 0.9482, TPR sebesar 0.7195, dan FPR sebesar 0.0328.. Perbandingan hasil pengujian segmentasi pembuluh darah retina seperti ditunjukkan pada Tabel 4.7

Tabel 4.1 Perbandingan Hasil Pengujian Segmentasi Pembuluh Darah Citra Retina dari Dataset STARE

Metode	Akurasi	TPR	FPR
Human Observer	0.9354	0.8949	0.0610
Matched filter [20]	0.9384	0.6134	0.0245
Hoover [21]	0.9267	0.6751	0.0433
Staal [22]	0.9516	0.6970	0.0190
Soares [23]	0.9480	0.7165	0.0252
Mendonca [24]	0.9440	0.6996	0.0270
Martinez-Perez [25]	0.9410	0.7506	0.0431
MF-FDOG [26]	0.9484	0.7177	0.0247
Metode yang diusulkan	0.9482	0.7195	0.0328

Akurasi merupakan proporsi pembuluh darah dan *background* yang terdeteksi benar sebagai pembuluh darah dan *background*. TPR (*True Positive Rate*) merupakan proporsi pembuluh darah yang terdeteksi benar sebagai pembuluh darah. Sedangkan FPR (*False Positive Rate*) adalah proporsi *background* yang salah diklasifikasikan sebagai pembuluh darah.

4.4.2 Ekstraksi Ciri

Setelah citra biner pembuluh darah retina didapatkan dari tahap segmentasi, kemudian dilanjutkan tahapan berikutnya yaitu

ekstraksi ciri. Tahapan ini bertujuan untuk mendapatkan ciri berupa dimensi fraktal dan *lacunarity*. Jika dilihat dari rata-rata nilai dimensi fraktal antara retina normal dan retinopati hipertensi, dimensi fraktal untuk retinopati hipertensi lebih tinggi dibandingkan retina normal. Berbanding terbalik dengan nilai *lacunarity*, retinopati hipertensi memiliki rata-rata nilai *lacunarity* yang lebih rendah dibandingkan retina normal, seperti ditunjukkan pada table 4.5

Untuk melihat apakah ada perbedaan yang signifikan antara tiap nilai ciri (dimensi fraktal dan *lacunarity*) pada retina normal dan retinopati hipertensi yang didapatkan, maka dilakukan uji t-test. Uji T-test dilakukan dengan menggunakan nilai *alpha* 0.05 atau dengan tingkat konfidensi sebesar 95%. Artinya adalah, jika pada t-Test didapatkan hasil *P-value* < 0.05 maka ciri tersebut memiliki perbedaan yang signifikan diantara tiap nilai ciri untuk retina normal dan retinopati hipertensi. Hasil t-Test yang telah dilakukan ditampilkan seperti pada tabel 4.6.

Table 4.6 Hasil t-Test

Ciri	P-value
FD	0.000069
<i>Lacunarity</i> 2 ¹	0.002126
<i>Lacunarity</i> 2 ²	0.001350
<i>Lacunarity</i> 2 ³	0.000959
<i>Lacunarity</i> 2 ⁴	0.000739
<i>Lacunarity</i> 2 ⁵	0.001761
<i>Lacunarity</i> 2 ⁶	0.008010
<i>Lacunarity</i> 2 ⁷	0.015628
<i>Lacunarity</i> 2 ⁸	0.007708
<i>Lacunarity</i> 2 ⁹	0.172182

Dari tabel di atas, ciri FD (dimensi fraktal) memiliki P-value yang paling rendah diantara ciri-ciri yang lain yaitu sebesar 0.000069 < 0.05 yang berarti ciri FD memiliki perbedaan yang signifikan untuk retina normal dan retinopati hipertensi. Sedangkan pada ciri *Lacunarity* 2⁹ memiliki P-value sebesar 0.172182 > 0.05 yang berarti ciri *Lacunarity* 2⁹ tidak memiliki perbedaan yang signifikan untuk retina normal dan retinopati hipertensi.

4.4.3 Klasifikasi dan Pengujian

Setelah semua ciri didapatkan dari analisis fraktal, tahapan berikutnya adalah klasifikasi menggunakan algoritma SVM. Pengujian hasil klasifikasi menggunakan metode *k-fold cross validation* dengan *k* = 5 seperti dijelaskan pada metodologi. Hasil pengujian ditampilkan seperti pada Tabel 4.7 untuk kernel Linear, Tabel 4.8 untuk kernel Polynomial, dan Tabel 4.9 untuk kernel Radial. *Accuracy* terbaik didapatkan kernel Polynomial dengan menggunakan ciri *fd_lac2* dan *fd_lac7* yaitu sama-sama memiliki *accuracy* 0.78. Pada ciri *fd_lac2* memiliki *sensitivity* 0.56 dan *specificity* 1. Dengan kata lain, apabila menggunakan ciri ini, hasil yang didapatkan akan jauh lebih baik saat mendeteksi retina normal dibandingkan retinopati hipertensi. Sedangkan pada ciri *fd_lac7* memiliki *sensitivity* 0.8 dan *specificity* 0.76 dengan selisih yang sangat kecil, apabila menggunakan ciri ini maka hasil yang didapatkan akan sedikit lebih baik saat mendeteksi retinopati hipertensi dibandingkan retina normal. Nilai AUC terbaik juga didapatkan pada ciri *fd_lac2* dan *fd_lac7* yaitu 0.76. Nilai maximal AUC adalah 1 yang menunjukkan sebagai *classifier* sempurna. Semakin tinggi nilai AUC mengindikasikan semakin baik pula kinerja *classifier*.

5. Kesimpulan dan Saran

5.1.1 Kesimpulan

Berdasarkan hasil penelitian, dapat diambil beberapa kesimpulan :

1. Segmentasi pembuluh darah citra retina telah berhasil dilakukan dan memiliki tingkat *accuracy* sebesar 0.9482 ketika dilakukan pengujian terhadap 20 citra retina yang telah dilakukan segmentasi secara manual.
2. Dari hasil ekstraksi ciri yang didapatkan, citra retina yg terdiagnosa retinopati hipertensi memiliki rata-rata dimensi fraktal yang lebih tinggi dibandingkan citra retina normal. Sedangkan untuk rata-rata lacunarity nya lebih rendah dibandingkan citra retina normal.
3. Analisis fraktal citra fundus retina dapat dipertimbangkan untuk digunakan sebagai langkah diagnosa awal untuk penyakit retinopati hipertensi. Hal ini ditunjang dari hasil pengujian penelitian didapatkan hasil *accuracy* 0.78, *precision* 0.77, *sensitfity* 0.8, *specificity* 0.76, dan AUC 0.76 menunjukkan bahwa kernel *polynomial* dengan menggunakan ciri dimensi fraktal dan *lacunarity* dengan ukuran box 2^7 memperoleh hasil yang paling baik dibandingkan dengan yang lain. Nilai AUC 0.76 menunjukkan bahwa deteksi retinopati hipertensi dengan pendekatan analisis fraktal memiliki kinerja yang cukup baik.

5.1.2 Saran

Saran yang dapat diberikan untuk penelitian ini yaitu adanya penambahan data citra fundus retina serta kemungkinan adanya penambahan ciri lain untuk proses pendeteksian retinopati hipertensi.

6. DAFTAR PUSTAKA

- [1] Kementerian Kesehatan. 2014. Infodatin Hipertensi. Pusat Data dan Informasi Kementerian Kesehatan RI, Jakarta.
- [2] Kementerian Kesehatan. 2014. Laporan Hasil Riset Kesehatan Dasar, RISKESDAS Indonesia Tahun 2013. Depkes, Jakarta.
- [3] Setyowati, S. 2005. Faktor-faktor yang Berperan Terhadap Kejadian Retinopati Hipertensif Pada Pasien Hipertensi Esensial Non Diabetik. Pendidikan Dokter Spesialis Universitas Dinpponegoro, Semarang.
- [4] Kementerian Kesehatan. 2014. Infodatin Situasi Gangguan Penglihatan dan Kebutaan. Pusat Data dan Informasi Kementerian Kesehatan RI, Jakarta.
- [5] Sitompul, R. 2011. Retinopati Diabetik. J Indon Med Assoc, Volum: 61, Nomor: 8, Agustus 2011. Departemen Ilmu Kesehatan Mata, Fakultas Kedokteran Universitas Indonesia, Jakarta.
- [6] Wong TY, Mitchell P, 2004, Current Concept Hypertensive Retinopathy. The New England Journal of Medicine, 351:2310-2317. Available from : URL : <http://www.nejm.org/doi/pdf/10.1056/NEJMra032865>
- [7] Liew & et. 2011. Fractal Analysis of Retinal Microvasculature and Coronary Heart Disease Mortality. European Heart Journal 32:422-429
- [8] Mandelbrot BB. 1982. The Fractal Geometry of Nature. New York: W.H. Freeman and Company
- [9] Kesiman, Made Windu Antara. 2013. Segmentasi Area Teks Aksara Bali pada Citra Lontar Kuno Bali Berdasarkan Peta nilai Lacunarity. Jurusan Pendidikan Teknik Informatika Universitas Pendidikan Ganesha, Yogyakarta.
- [10] Gonzales, R.C., Woods, R.E. 2010. Digital Image Processing – Third Edition. New Jersey : Prentice Hall.
- [11] Kolar, R., Harabis, V., 2009. Automatic Rigid Registration and Analysis of Colour Fundus Image in Patient with Diabetic Retinopathy, IFMBE proceedings, vol 25/11, 251-24.
- [12] Munir, R. 2004. Pengolahan Citra Digital. Bandung : Informatika.
- [13] Marwan D. Saleh, C. Eswaran, Ahmed Mueen. 2011. An Automated Blood Vessel Segmentation Algorithm Using Histogram Equalization and Automatic Threshold Selection, Journal of Digital Imaging, ISSN: 0897-1889, Vol.24, No.4, August 2011, pp 564-572. Pusat Infrastruktur Komunikasi, Fakultas Teknologi Informasi, Universitas Multimedia, Jalan Multimedia, 63100, Cyberjaya, Selangor, Malaysia.
- [14] Peitgen HO, Jürgens H, Saupe D, Hosselbarth C, Maletsky E, et al. 1992. Fractal for Classroom Part 1: Introduction to Fractal and Chaos. New York: Springer-Verlag.
- [15] Backes AR, Bruno OM. 2008. A New Approach to Estimate Fractal Dimension of Texture Images. Heidelberg: Springer.
- [16] D.A.P.K.M. Utami. 2012. Segmentasi Citra Berdasarkan Tekstur Menggunakan Lacunarity dengan Metode Differential Box-Counting. Jurusan Pendidikan Teknik Informatika, Universitas Pendidikan Ganesha.
- [17] Cristianini, N., Shawe-Taylor, J., 2000. An introduction to support vector machines and other kernel-based learning methods. Cambridge university press.
- [18] <http://www.ces.clemson.edu/~ahoover/stare/>
- [19] Han, J. dan Kamber, M. 2006. Data Mining: Concepts and techniques (2nd Edition). Elsevier In
- [20] Chaudhuri, S., Chatterjee, S., Katz, N., Nelson, M., & Goldbaum, M. (1989). Detection of blood vessels in retinal images using two-dimensional matched filters. IEEE Transactions on medical imaging, 8(3), 263-269.
- [21] Hoover, A., Kouznetsova, V., & Goldbaum, M. (2000). Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response. Medical Imaging, IEEE Transactions on, 19(3), 203-210.
- [22] Staal, J., Abramoff, M. D., Niemeijer, M., Viergever, M., & Van Ginneken, B. (2004). Ridge-based vessel segmentation in color images of the retina. Medical Imaging, IEEE Transactions on, 23(4), 501-509.
- [23] Soares, J. V., Leandro, J. J., Cesar Jr, R. M., Jelinek, H. F., & Cree, M. J. (2006). Retinal vessel segmentation using the 2-D Gabor wavelet and supervised classification. Medical Imaging, IEEE Transactions on, 25(9), 1214-1222.
- [24] Mendonca, A. M., & Campilho, A. (2006). Segmentation of retinal blood vessels by combining the detection of centerlines and morphological reconstruction. Medical Imaging, IEEE Transactions on, 25(9), 1200-1213.
- [25] Martinez-Perez, M. E., Hughes, A. D., Thom, S. A., Bharath, A. A., & Parker, K. H. (2007). Segmentation of blood vessels from red-free and fluorescein retinal images. Medical image analysis, 11(1), 47-61.
- [26] Zhang, B., Zhang, L., Zhang, L., & Karray, F. (2010). Retinal vessel extraction by matched filter with first-order derivative of Gaussian. Computers in biology and medicine, 40(4), 438-4