

TESIS

**IMPLEMENTASI SELEKSI FITUR MENGGUNAKAN EVOLUTIONARY
ALGORITHM PADA KLASIFIKASI RETINAL NERVE FIBER LAYER**



Disusun oleh:

Nama : Aam Shodiqul Munir
NIM : 20.51.1358
Konsentrasi : Business Intelligence

**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2023

TESIS

**IMPLEMENTASI SELEKSI FITUR MENGGUNAKAN EVOLUTIONARY
ALGORITHM PADA KLASIFIKASI RETINAL NERVE FIBER LAYER**

**IMPLEMENTATION OF FEATURE SELECTION USING
EVOLUTIONARY ALGORITHM ON RETINAL NERVE FIBER LAYER
CLASSIFICATION**

Diajukan untuk memenuhi salah satu syarat memperoleh derajat Magister



Disusun oleh:

Nama : Aam Shodiqul Munir
NIM : 20.51.1358
Konsentrasi : Business Intelligence

PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA

2023

HALAMAN PENGESAHAN

**IMPLEMENTASI SELEKSI FITUR MENGGUNAKAN EVOLUTIONARY
ALGORITHM PADA KLASIFIKASI RETINAL NERVE FIBER LAYER**

**IMPLEMENTATION OF FEATURE SELECTION USING EVOLUTIONARY
ALGORITHM ON RETINAL NERVE FIBER LAYER CLASSIFICATION**

Dipersiapkan dan Disusun oleh

Aam Shodiqul Munir

20.51.1358

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Kamis, 11 Mei 2023

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, 11 Mei 2023

Rektor

Prof. Dr. M. Suyanto, M.M.
NIK. 190302001

HALAMAN PERSETUJUAN

Implementasi Seleksi Fitur Menggunakan Evolutionary Algorithm pada Klasifikasi Retinal Nerve Fiber Layer

Implementation of Feature Selection Using Evolutionary Algorithm on Retinal Nerve
Fiber Layer Classification

Dipersiapkan dan Disusun oleh

Aam Shodiqul Munir

20.51.1358

Telah Drujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Kamis, 11 Mei 2023

Pembimbing Utama

Dr. Andi Sunyoto, M.Kom.
NIK. 190302052

Pembimbing Pendamping

Hanif Al Fatta, M.Kom.
NIK. 190302096

Anggota Tim Penguji

Dr. Arief Setyanto, S.SI, M.T.
NIK. 190302036

Hanafi, S.Kom., M.Eng., Ph.D.
NIK. 190302024

Dr. Andi Sunyoto, M.Kom.
NIK. 190302052

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, 11 Mei 2023
Direktur Program Pascasarjana

Dr. Kusrini, M.Kom.
NIK. 190302106

HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Aam Shodiqul Munir
NIM : 20.51.1358
Konsentrasi : Business Intelligence

Menyatakan bahwa Tesis dengan judul berikut:
Tuliskan Judul Tesis Bahasa Indonesia

Dosen Pembimbing Utama : Dr. Andi Sunyoto, M.Kom
Dosen Pembimbing Pendamping : Hanif Al Fatta, M.Kom.

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Tim Dosen Pembimbing
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMIKOM Yogyakarta
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi

Yogyakarta, 11 Mei 2023
Yang Menyatakan,



Aam Shodiqul Munir

HALAMAN PERSEMBAHAN

Alhamdulillahirabbil Alamin, Puji Syukur kehadiran Allah SWT atas berkat, rahmat dan karunia-Nya serta pertolongannya sehingga saya dapat menyelesaikan tesis ini dengan baik. Saya juga menyampaikan banyak terimakasih terhadap pihak-pihak yang telah memberikan banyak kontribusi baik secara langsung maupun tidak langsung dalam penelitian maupun dalam penyusunan naskah tesis. Tesis ini dipersembahkan kepada:

1. Bapak Mulyono, Ibu Tri windarsih selaku Orang tua dan Nizhom selaku adik yang telah memberikan semangat, doa dan logistik sehingga saya sebagai anak dan saudara kandung mampu menyelesaikan Tesis ini dengan baik.
2. Bapak Dr. Andi Sunyoto, M. Kom. selaku dosen pembimbing yang sudah membimbing saya hingga dapat menyelesaikan tesis ini dengan lancar, baik dan benar.
3. Bapak Hanif Al Fatta, M.Kom. selaku dosen pembimbing kedua yang sudah banyak membantu saya dalam menyelesaikan tesis ini.
4. Bapak dan Ibu Dosen yang telah memberikan ilmunya dari saya semester 1 sampai saat ini.
5. Semua pihak keluarga besar universitas AMIKOM Yogyakarta yang tidak bisa saya sebutkan satu persatu.

HALAMAN MOTTO

” Si Deus pro nobis, quis contra nos?”

Bila Tuhan bersama kita, siapa yang berani melawan kita?



KATA PENGANTAR

Alhamdulillahirabbil Alamin, Puji syukur kehadiran Allah SWT atas berkat, rahmat dan karuni-Nya serta pertolongannya sehingga saya dapat menyelesaikan tesis dengan judul “Implementasi seleksi fitur menggunakan evolutionary algorithm pada klasifikasi retinal nerve fiber layer” sebagai syarat untuk menyelesaikan Program Pascasarjana (S2) Universitas AMIKOM Yogyakarta. Dalam penyusunan tesis ini terdapat bantuan dan bimbingan dari berbagai pihak sehingga penulis bisa menyelesaikan tesis ini dengan lancar dan benar. Pada kesempatan ini saya mengucapkan banyak terimakasih kepada:

1. Bapak Prof. Dr. M. Suyanto, M.M. selaku Rektor Universitas AMIKOM yogyakarta.
2. Bapak Dr. Andi Sunyoto, M. Kom. dan Hanif Al Fatta, M.Kom. selaku dosen pembimbing yang dengan sabar membimbing dan memberi ilmu kepada saya.
3. Seluruh Bapak dan Ibu Dosen Program Pascasarjana Universitas AMIKOM Yogyakarta yang telah memberikan banyak ilmu sehingga dapat menjadi bekal dalam mengerjakan tesis ini.
4. Semua pihak keluarga besar Universitas AMIKOM Yogyakarta yang tidak bisa saya sebutkan satu per satu.
5. Keluarga besar saya tercinta, Orang tua , Saudara kandung yang telah mendoakan sehingga penulis tetap semangat untuk menyusun dan mengerjakan tesis ini

6. Serta Teman – teman penulis Abdul Rahman , Rizki Ananda, Dewi , Dinda, Isna dan Kawan – kawan seperjuangan di BPJS TK yang telah memberikan ide, logistik dan tamparan keras sehingga penulis tidak patah semangat dalam menyelesaikan tesis ini.

Penulis sadari bahwa naskah tesis ini masih jauh dari sempurna, Oleh sebab itu setiap kritik dan saran yang membangun sangat penulis harapkan. Akhir kata semoga tesis ini dapat bermanfaat bagi pembaca dan bagi diri penulis sendiri.

Yogyakarta, 11 Mei 2023

Penulis




DAFTAR ISI

HALAMAN JUDUL.....	ii
HALAMAN PENGESAHAN.....	iii
HALAMAN PERSETUJUAN.....	iv
HALAMAN PERNYATAAN KEASLIAN TESIS.....	v
HALAMAN PERSEMBAHAN.....	vi
HALAMAN MOTTO.....	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	x
DAFTAR TABEL.....	xiii
DAFTAR GAMBAR.....	xv
INTISARI.....	xvii
ABSTRACT.....	xviii
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah.....	1
1.2. Rumusan Masalah.....	4
1.3. Batasan Masalah.....	5
1.4. Tujuan Penelitian.....	5
1.5. Manfaat Penelitian.....	5
BAB II TINJAUAN PUSTAKA.....	7
2.1. Tinjauan Pustaka.....	7
2.2. Keaslian Penelitian.....	11

2.3. Landasan Teori.....	19
2.3.1 Retinal Nerve Fiber Layer	19
2.3.2 Ekstraksi Fitur GLCM	20
2.3.3 Seleksi Fitur	27
2.3.4. Seleksi fitur dengan Algoritma evolusi	29
2.3.5 Fungsi Fitness	32
2.3.6 Artificial Neural Network.....	33
BAB III METODE PENELITIAN.....	37
3.1. Jenis, Sifat, dan Pendekatan Penelitian.....	37
3.2. Metode Pengumpulan Data.....	37
3.3. Metode Analisis Data.....	37
3.4. Alur Penelitian	38
3.4.1. Citra Fundus.....	39
3.4.2. Mengubah ruang warna RGB ke ruang warna Grayscale.....	40
3.4.3 Ekstraksi Fitur menggunakan GLCM.....	41
3.4.4 Seleksi fitur menggunakan Algoritma evolusi.....	41
3.4.5 Klasifikasi	42
3.4.6 Evaluasi.....	42
BAB IV HASIL PENELITIAN DAN PEMBAHASAN	44
4.1. Pembentukan 12 Sub citra	44
4.2 . Mengubah citra RGB menjadi citra Grayscale.....	46

4.3 . Ekstraksi Ciri Tekstur menggunakan GLCM.....	47
4.4. Seleksi fitur menggunakan Algoritma Evolusi.....	50
4.5 Klasifikasi dan evaluasi.....	86
BAB V PENUTUP.....	93
5.1. Kesimpulan.....	93
5.2. Saran.....	94
DAFTAR PUSTAKA.....	96



DAFTAR TABEL

Tabel 2.1. Matriks literatur review dan posisi penelitian Implementasi Seleksi Fitur Menggunakan Evolutionary Algorithm pada Klasifikasi Retinal Nerve Fiber Layer.....	11
Tabel 4.1. Contoh hasil ekstraksi subcitra yang memiliki RNFL menggunakan GLCM.....	48
Tabel 4.2. Contoh hasil ekstraksi subcitra yang tidak memiliki RNFL menggunakan GLCM.....	49
Tabel 4.3. Hasil Seleksi fitur menggunakan Algoritma genetika.....	50
Tabel 4.4. Fitur – fitur yang terpilih pada proses seleksi fitur menggunakan Algoritma Genetika.....	52
Tabel 4.5. Fitur – fitur yang terpilih pada proses seleksi fitur menggunakan Algoritma PSO.....	53
Tabel 4.6. fitur – fitur yang terpilih pada proses seleksi fitur menggunakan Algoritma ABC.....	57
Tabel 4.7. Tabel Perbandingan Hasil Seleksi menggunakan Metode Algoritma Evolusi.....	60
Tabel 4.8. Sampel data individu 1.....	68
Tabel 4.9. Sampel data individu 2.....	69
Tabel 4.10. Sampel data individu 3.....	70
Tabel 4.11. Nilai akurasi dan jumlah fitur yang digunakan.....	71
Tabel 4.12. Nilai fitness pada setiap individu.....	72

Tabel 4.13. Nilai probabilitas dari setiap individu.....	72
Tabel 4.14. Nilai probabilitas komulatif dari setiap individu	73
Tabel 4.15. Hasil proses seleksi berdasarkan bilangan acak dan roulette wheel ..	74
Tabel 4.16. Penentuan individu untuk proses crossover	75
Tabel 4.17. Ilustrasi Penentuan titik crossover	76
Tabel 4.18. Hasil dari proses crossover	77
Tabel 4.19. Penentuan individu untuk proses crossover	78
Tabel 4.20. Penentuan titik mutase	79
Tabel 4.21. Hasil dari proses mutase	80
Tabel 4.22. data individu 1 setelah proses crossover dan mutase	81
Tabel 4.23. data individu 2 setelah proses crossover dan mutase	82
Tabel 4.24. Data individu 3 setelah proses crossover dan mutasi	83
Tabel 4.25. Nilai fitness dari individu baru	84
Tabel 4.26. Hasil percobaan skenario pertama (tanpa seleksi)	86
Tabel 4.27. Hasil percobaan skenario kedua (dengan seleksi fitur)	87
Tabel 4.28. Hasil percobaan skenario kedua berdasarkan jumlah fitur yang tersisa	88
Tabel 4.29. Perbandingan waktu komputasi percobaan skenario satu dan dua ..	90
Tabel 4.30. Perbandingan hasil penelitian dengan penelitian sebelumnya.....	91

DAFTAR GAMBAR

Gambar 2.1. Ilustrasi Citra fundus yang telah mengalami segmentasi ONH	19
Gambar 2. 2 Ilustrasi sudut θ pada GLCM	20
Gambar 2.3. Ilustrasi Artificial Neural Network	36
Gambar 3.1. Bagan Alur Penelitian	38
Gambar 3.2. Contoh Citra OCT	39
Gambar 3.3. Ilustrasi Pembagian Citra Fundus menjadi 12 buah Sub Sektor	40
Gambar 4.1. Ilustrasi template pemotong	44
Gambar 4.2. Ilustrasi template yang telah dirotasi untuk digunakan sebagai template pemotong	45
Gambar 4.3. Contoh subcitra yang memiliki RNFL	46
Gambar 4.4. Contoh subcitra yang tidak memiliki RNFL	46
Gambar 4.5. Contoh perubahan sub citra ruang warna RGB ke ruang warna Grayscale.	47
Gambar 4.6. Gambaran umum proses seleksi fitur menggunakan Algoritma Genetika	51
Gambar 4.7. Ilustrasi pembagian sektor Temporal , Nasal, Superior dan Inferior 61	
Gambar 4.8. Ilustrasi sebaran RNFL pada data sektor nasal	62
Gambar 4.9. Ilustrasi sebaran RNFL pada data sektor Temporal	62
Gambar 4.10. Ilustrasi sebaran RNFL pada data sektor Inferior	63
Gambar 4.11. Ilustrasi sebaran RNFL pada data sektor Superior	63

Gambar 4.12. Ilustrasi sebaran RNFL pada data nasal dan temporal arah diagonal	64
Gambar 4.13. Bagan perbandingan waktu komputasi ekstraksi fitur	85
Gambar 4.14. Bagan perbandingan Hasil Klasifikasi pada berdasarkan jumlah fitur yang tersisa	88
Gambar 4.15. Bagan perbandingan waktu komputasi klasifikasi dengan seleksi fitur dan tanpa seleksi fitur	90
Gambar 4.16. Bagan Perbandingan hasil penelitian dengan penelitian sebelumnya	92



INTISARI

Retina Nerve Fiber Layer (RNFL) adalah suatu bagian dari retina yang terletak di luar Optic Nerve Head (ONH), yang dapat diamati pada citra fundus retina. Citra fundus retina dibagi menjadi empat sektor, yaitu inferior (I), superior (S), nasal (N), dan temporal (T). Kerusakan pada RNFL dapat menyebabkan penyakit Glaukoma. Evaluasi terhadap struktur optic nerve head (ONH) dan retinal nerve head sangat penting untuk diagnosis penyakit dan penanganan penyakit selanjutnya. Klasifikasi RNFL masih menggunakan pengamatan manual oleh dokter mata yang mana tidak bisa dilakukan secara cepat jika melakukan pendeteksian secara masif. Persoalan – persoalan yang membutuhkan keterlibatan dan solusi dari machine learning sangat meningkat. Peningkatan tersebut dibarengi dengan kemunculan data yang memiliki dimensi dan ukuran yang besar. fitur seleksi menghapus data yang tidak relevan, berlebihan, dan noise sehingga menghindari penurunan performa pada suatu machine learning.

Berdasarkan hal tersebut penelitian ini memiliki tujuan untuk mengembangkan penelitian sebelumnya menggunakan algoritma evolusi sebagai metode seleksi fitur karena penelitian sebelumnya menggunakan metode seleksi fitur tradisional CFS. Metode seleksi fitur berbasis filter cenderung menghasilkan hasil klasifikasi yang lebih rendah dibandingkan dengan metode seleksi fitur berbasis wrapper dan embedded. Penelitian ini menggunakan GLCM untuk ekstraksi fitur sebanyak 84 fitur dan algoritma evolusi sebagai metode seleksi fitur.

Berdasarkan percobaan yang telah dilakukan tingkat akurasi terbaik didapatkan oleh algoritma genetika dengan akurasi, specificity dan sensitivity masing-masing sebesar 97,35%, 97,60% dan 97,19%. subset fitur terbaik adalah Autocorrelation 45o, Sum of Squares: Variances 90o dan Sum Variances 135 o. Terjadi penyederhanaan dari 84 fitur menjadi 3 fitur. Rata – rata dari 5 buah percobaan yang dilakukan tersebut mendapatkan tingkat akurasi rata-rata 96,78 % , rata-rata nilai specificity sebesar 97,40 % dan rata-rata nilai sensitivity sebesar 95,87 %. Dari hasil percobaan dua buah skenario diatas rata – rata peningkatan akurasi naik 1,93 % , rata – rata specificity naik 1,93% dan rata-rata sensitivity naik 1,95 % dibandingkan hasil klasifikasi yang tidak menggunakan seleksi fitur.

Kata kunci: RNFL, Algoritma Evolusi, Algoritma genetika, klasifikasi, GLCM

ABSTRACT

The Retina Nerve Fiber Layer (RNFL) is a part of the retina located outside the Optic Nerve Head (ONH), which can be observed fundus image. The fundus image is divided into four local sectors, namely inferior (I), superior (S), nasal (N), and temporal (T). Damage to RNFL can lead to glaucoma. Evaluation of the structure of the optic nerve head (ONH) and retinal nerve head is very important for the diagnosis of the disease and subsequent treatment of the disease. The classification of RNFL still uses manual observation by an ophthalmologist which cannot be done quickly if it performs massive detection. The problems that require the involvement and solutions of machine learning are increasing. The increase is accompanied by the emergence of data that has large dimensions and sizes. The selection feature removes irrelevant, redundant data, and noise, avoiding performance degradation in machine learning.

Based on background above, this study aims to develop previous research using evolutionary algorithms as a feature selection method. Filter-based feature selection methods tend to produce lower classification results compared to wrapper-based and embedded feature selection methods. This study used GLCM to extract 84 features and evolution algorithms as feature selection methods.

Based on experiments that have been carried out, the best level of accuracy is obtained by genetic algorithms with accuracy, specificity and sensitivity of 97.35%, 97.60% and 97.19% respectively using ANN as classifier method. The best feature subsets are Autocorrelation 45o, Sum of Squares: Variances 90o and Sum Variances 135o. The average of the 5 experiments obtained an average accuracy rate of 96.78%, an average specificity value of 97.40% and an average sensitivity value of 95.87%. From the experimental results of the two scenarios above, the average increase in accuracy rose 1.93%, the average specificity increased by 1.93% and the average sensitivity increased by 1.95% compared to the results of classifications that did not use feature selection.

Keyword: RNFL, Evolutionary Algorithm, Genetic Algorithm, Classification, GLCM

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Retina Nerve Fiber Layer (RNFL) adalah suatu bagian dari retina yang terletak di luar Optic Nerve Head (ONH), yang dapat diamati pada citra fundus retina. Secara visual, ONH adalah area bulat yang terang atau sedikit oval, dan RNFL adalah area dengan tekstur khas yang tampak seperti goresan-goresan dengan warna keputihan. Pada mata normal, tekstur RNFL terlihat jelas dan penyebarannya secara merata di semua sektor, sedangkan pada pasien glaukoma, struktur RNFL cenderung hilang, yang mengindikasikan kecacatan RNFL (Septiarini et al., 2018)

Pengamatan RNFL dilakukan dengan menggunakan citra fundus. Citra fundus retina dibagi menjadi empat sektor, yaitu inferior (I), superior (S), nasal (N), dan temporal (T). Sektor inferior dan superior masing-masing berada di bagian atas dan bawah. Pada mata kanan, sektor nasal dan temporal berada pada sisi kanan dan kiri, dan begitu pula sebaliknya untuk mata kiri. Yang paling tebal dan paling jelas terlihat bagian dari struktur RNFL terletak di sektor inferior dan superior (Chakrabarty et al., 2016)

Kerusakan pada RNFL dapat menyebabkan penyakit Glaukoma. Glaukoma adalah peradangan pada optik mata yang ditandai dengan kemunduran progresif dari ONH dan luas pandangan mata. Glaukoma bukanlah penyakit tunggal melainkan sekelompok kelainan klinis yang beragam. Jika pada tahap awal

penyakit ini tidak terdeteksi maka dapat menyebabkan kebutaan permanen. Evaluasi terhadap struktur optic nerve head (ONH) dan retinal nerve head sangat penting untuk diagnosis penyakit dan penanganan penyakit selanjutnya (Wyawahare & Patil, 2015)

Perbedaan citra fundus retina pada mata normal dan pada mata yg memiliki penyakit glaukoma terletak pada tekstur RNFL. Struktur mata normal akan terdapat banyak tekstur seperti goresan-goresan di sekeliling ONH sedangkan pada mata penderita glaukoma tekstur tersebut cenderung tipis (Wyawahare & Patil, 2015). Klasifikasi RNFL masih menggunakan pengamatan manual oleh dokter mata yang mana tidak bisa dilakukan secara cepat jika melakukan pendeteksian secara masif.

Terdapat beberapa penelitian yang pernah dilakukan mengenai pendeteksian dan klasifikasi dari retinal nerve fiber layer diantaranya adalah penelitian yang dilakukan (Prageeth et al., 2011) dengan hasil akurasi mencapai 91,5 % kemudian pada penelitian (Odstrcilik et al., 2015) menyebutkan bahwa penggunaan ekstraksi ciri tekstur Gaussian markov random field (GMRF) dan Local Binary pattern dapat digunakan untuk deteksi dan evaluasi penipisan RNFL. Penelitian yang dilakukan oleh (Odstrcilik et al., 2012) menggunakan fitur – fitur yang didapat dari Markov random field dari menghasilkan nilai akurasi sebesar 91 %. Penelitian yang dilakukan (Muramatsu et al., 2010) menggunakan gabor filter dan ANN menghasilkan nilai akurasi sebesar 91 %. (Gómez-Valverde et al., 2019) menggunakan Convolutional Neural Networks (CNN) untuk identifikasi gambar retina glaukoma. Tingkat deteksi Glaukoma menggunakan metode yang diusulkan pada penelitian tersebut ditingkatkan dengan menghitung fitur saraf internal untuk

proses klasifikasi. (Parashar & Agrawal, 2020) menggunakan Flexible Analytic Wavelet Transform yang kemudian diseleksi menggunakan metode seleksi fitur ReliefF. Pada penelitian tersebut juga menggunakan metode klasifikasi biner dan Cross-Validation untuk memverifikasi keefektifan metode deteksi yang diusulkan.

Pada penelitian yang dilakukan (Septiarini et al., 2018) klasifikasi Retinal Nerve Fiber Layer menghasilkan akurasi klasifikasi yang sangat baik yaitu 94,52 % menggunakan data sebanyak 160 sub Images (80 data sub-images berlabel Ada dan 80 data sub-images berlabel tidak). Fitur – fitur yang digunakan adalah fitur yang didapat dari metode GLCM (energy, contrast, correlation, homogeneity, entropy, autocorrelation, dissimilarity, cluster shade, cluster prominence, dan maximum probability).

Persoalan – persoalan yang membutuhkan keterlibatan dan solusi dari machine learning sangat meningkat. Peningkatan tersebut dibarengi dengan kemunculan data yang memiliki dimensi dan ukuran yang besar. Menurut (Chen et al., 2020) kita tidak membutuhkan semua fitur untuk dilatih dalam proses machine learning dan Model yang dibuat dapat ditingkatkan dengan menggunakan fitur – fitur yang berhubungan dan non redundant. Menurut (Prayogo et al., 2021) fitur seleksi menghapus data yang tidak relevan, berlebihan, dan noise sehingga menghindari penurunan performa pada suatu machine learning.

Berdasarkan hal tersebut penelitian ini memiliki tujuan untuk mengembangkan penelitian sebelumnya (Septiarini et al., 2018) menggunakan algoritma evolusi sebagai metode seleksi fitur karena penelitian sebelumnya menggunakan metode seleksi fitur tradisional CFS. Menurut (Pudjihartono et al.,

2022; Saeys et al., 2007) metode seleksi fitur berbasis filter memiliki keterbatasan karena mengabaikan hubungan antara fitur dan metode klasifikasi yang digunakan, sehingga metode seleksi fitur berbasis filter cenderung menghasilkan hasil klasifikasi yang lebih rendah dibandingkan dengan metode seleksi fitur berbasis wrapper dan embedded. Beberapa penelitian yang dilakukan oleh (Abd Alkreem & Karim, 2021; Eleya, 2019; Nakisa et al., 2018; Tan et al., 2020) menyimpulkan bahwa algoritma evolusi mampu menghasilkan fitur-fitur yang relevan sehingga dapat meningkatkan tingkat akurasi.

Pada penelitian ini Algoritma evolusi digunakan sebagai metode seleksi fitur pada klasifikasi Retinal Nerve Fiber Layer (RNFL). Penelitian ini juga menggunakan metode ANN sebagai metode klasifikasi pada Retinal Nerve Fiber Layer (RNFL).

1.2. Rumusan Masalah

Dari beberapa penjelasan yang telah dibahas, pada Penelitian ini memiliki beberapa rumusan masalah, antara lain :

- a. Apakah penggunaan algoritma evolusi sebagai seleksi fitur dapat meningkatkan akurasi dari klasifikasi retinal nerve fiber layer?
- b. Algoritma evolusi apa yang menunjukkan akurasi paling tinggi ?
- a. Subset Fitur apa saja yang terbaik setelah diterapkannya seleksi fitur menggunakan Algoritma Evolusi?

1.3. Batasan Masalah

Penelitian ini memiliki beberapa Batasan masalah untuk memfokuskan permasalahan. Batasan masalah tersebut antara lain :

- a. Data yang didapat berasal dari pasien yang tidak menderita rabun jauh dan katarak.
- b. Format data citra yang digunakan adalah .JPEG
- c. Dataset menggunakan data penelitian (Septiarini et al., 2018) sebanyak 44 buah citra fundus.
- d. Dataset yang digunakan memiliki dua kelas yaitu data citra subsector citra fundus yang terdapat RNFL dan data citra subsector yang tidak terdapat RNFL.
- e. Data yang digunakan adalah data citra fundus yang telah mengalami segmentasi *Optic Nerve Head*.

1.4. Tujuan Penelitian

Bagian ini memuat penjelasan secara spesifik:


- a. Solusi yang ditawarkan untuk menangani permasalahan yang dihadapi
- b. Hal-hal yang ingin dicapai melalui kegiatan penelitian yang akan dilakukan

1.5. Manfaat Penelitian

Berdasarkan rumusan masalah yang telah dibahas, dapat disimpulkan beberapa tujuan penelitian, antara lain :

- a. Mengetahui peningkatan akurasi sebelum dan sesudah mengimplementasikan Algoritma evolusi sebagai metode seleksi fitur.

- b. Mengetahui algoritma evolusi terbaik sebagai metode seleksi fitur pada klasifikasi Retinal Nerve Fiber Layer.
- a. Mengetahui fitur – fitur relevan yang dapat meningkatkan performa dari klasifikasi *Retinal Nerve Fiber Layer*.



BAB II

TINJAUAN PUSTAKA

2.1. Tinjauan Pustaka

Beberapa penelitian terdahulu yang digunakan sebagai rujukan klasifikasi retinal nerve fiber layer pada penelitian ini, antara lain :

Pada penelitian ini (Muramatsu et al., 2010) menggunakan 162 buah data. Bagian pembuluh darah dari data tersebut kemudian dihilangkan. Setelah itu, data tersebut ditransformasikan sehingga bagian cekung dari RNFL menjadi lurus yang kemudian diklasifikasikan menggunakan Linear Discriminant Analysis dan ANN. Penelitian tersebut mendapatkan nilai sensitivity sebesar 91 %.

Penelitian (Ajesh et al., 2021) menggunakan Multi feature Analysis sebagai metode ekstraksi fitur dan Deep Believe Neural Network sebagai metode klasifikasi. Penelitian ini menghasilkan akurasi sebesar 95 %.

Pada penelitian (Odstrcilik et al., 2014) menggunakan metode ekstraksi fitur Gaussian markov random field dan local binary pattern. Penelitian mendapatkan korelasi yang tinggi antara hasil evaluasi dari metode yang diusulkan dengan hasil evaluasi dari optical coherence tomography.

Penelitian ini (Prageeth et al., 2011) menggunakan metode quantitative pixel pada evaluasi retinal nerve fiber layer pada pendeteksian awal penyakit glaukoma. Metode yang diusulkan tersebut mendapatkan tingkat akurasi rata – rata sebesar 93,5 %.

Penelitian yang dilakukan oleh (Wyawahare & Patil, 2015) menggunakan ekstraksi ciri tekstur GLCM yang kemudian di optimalkan menggunakan metode Analysis of Variance (ANOVA) dan diklasifikasikan menggunakan metode Radial Basis. Penelitian ini mendapatkan hasil akurasi yang tinggi.

Penelitian yang dilakukan oleh (Parashar & Agrawal, 2020) menggunakan Flexible Analytic Wavelet Transform (FAWT) yang kemudian diseleksi dengan menggunakan metode ReliefF. Penelitian ini metode klasifikasi biner dan Cross Validation sebagai metode verifikasi hasil klasifikasi. Penelitian ini mendapatkan hasil akurasi 93,40 %.

Penelitian ini (Gómez-Valverde et al., 2019) menggunakan metode CNN dan transfer learning sebagai metode klasifikasi pada lebih dari 2300 data . Penelitian ini mendapatkan skor AUC sebesar 0,94 %.

Pada penelitian yang dilakukan (Septiarini et al., 2018) klasifikasi Retinal Nerve Fiber Layer menghasilkan akurasi klasifikasi yang sangat baik yaitu 94,52 % menggunakan data sebanyak 160 sub Images (80 data sub-images berlabel Ada dan 80 data sub-images berlabel tidak) . Fitur – fitur yang digunakan adalah fitur yang didapat dari metode GLCM.

Beberapa literatur juga digunakan sebagai rujukan Algoritma evolusi, antara lain :

Penelitian menggunakan algoritma evolusi seperti Differential evolution, Ant Colony Optimization dan Genetic Algorithm bertujuan untuk meminimalkan fitur yang digunakan sehingga dapat menambah akurasi dan waktu pemrosesan.

Pengurangan jumlah fitur tersebut meningkatkan akurasi dan waktu pemrosesan dari sistem tersebut rata-rata sebesar 11 % (Nakisa et al., 2018) .

Penelitian menggunakan algoritma evolusi Artificial Bee Colony untuk klasifikasi buah mendapatkan rata – rata precision, recall dan akurasi masing – masing sebesar 98%, 96% dan 96% dengan data sebanyak 360 buah data dan jumlah kelas sebanyak 5 kelas buah. Pada penelitian ini menggunakan fitur – fitur yang didapatkan dari algoritma ekstraksi tekstur Gray level Coocurrence matrix (GLCM) dan Harris corner detector (Abd Alkreem & Karim, 2021) .

Penelitian ini menggunakan algoritma Particle swarm optimization pada bidang face recognition. Eksperimen dalam penelitian ini menggunakan dua buah database wajah yang banyak diketahui yaitu ORL dan PUT face database. Performa dari pendekatan Particle swarm optimization menunjukkan peningkatan dalam parameter akurasi, spesifikasi dan sensitivity dibandingkan dengan pendekatan seleksi fitur PCA (Eleya, 2019) .

Penelitian ini mengusulkan pendekatan seleksi fitur menggunakan algoritma evolusi Particle Swarm Optimization dan algoritma filtering Signal to Noise Ratio (SNR). Dalam penelitian ini beberapa metode klasifikasi digunakan seperti Support vector machine (SVM), K nearest neighbour (KNN), Probabilistic neural network (PNN) dan menghasilkan akurasi sebesar 100% pada metode klasifikasi KNN (Sahu & Mishra, 2012).

Pada penelitian ini (Keles & Kılıç, 2018) menggunakan algoritma evolusi Artificial Bee Colony dalam melakukan seleksi fitur pada data Self Care Activities dataset based on ICF-CY (SCADI). Data tersebut memiliki 206 buah fitur dari 70

orang anak dengan disabilitas motorik dan fisik. Seleksi fitur menggunakan Artificial Bee Colony dibandingkan dengan metode seleksi fitur tradisional menggunakan Gain ratio, Info gain dan Chi Squared. Hasil akurasi yang dicapai metode Artificial Bee Colony sebesar 88,5% dibandingkan dengan akurasi metode seleksi fitur tradisional sebesar 84 % .

Pada penelitian ini (Barani & Mina Mirhosseini, 2018), pendekatan berbasis Support Vector Machine dan Artificial Bee Colony digunakan untuk klasifikasi biner. Pada penelitian ini digunakan kombinasi antara versi continuous dan binary pada algoritma Artificial Bee Colony untuk mengoptimasi kernel parameter secara terus menerus dan menghapus fitur – fitur yang tidak relevan pada data. Gabungan metode tersebut menunjukkan peningkatan akurasi sebesar 97%.

Berdasarkan pembahasan beberapa literatur diatas, metode seleksi fitur menggunakan algoritma evolusi memiliki akurasi klasifikasi lebih baik jika dibandingkan dengan algoritma seleksi fitur tradisional. Berdasarkan hal tersebut, dalam penelitian ini akan digunakan algoritma evolusi untuk menyeleksi fitur-fitur GLCM yang digunakan pada penelitian sebelumnya (Septiarini et al., 2018) ditambah dengan fitur – fitur GLCM yang belum digunakan seperti Difference Variance, Difference Entropy, inverse difference, information measure of correlation 1, information measure of correlation 2, sum averages, sum entropy, sum of squares : variances, sum variances, inverse difference normalized, inverse difference normalized didasari pada penelitian (Öztürk & Akdemir, 2018) sehingga fitur GLCM yang akan digunakan berjumlah 21 buah fitur..

2.2. Keaslian Penelitian

Tabel 2.1. Matriks literatur review dan posisi penelitian
Implementasi Seleksi Fitur Menggunakan Evolutionary Algorithm pada Klasifikasi Retinal Nerve Fiber Layer

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Sarat atau Kelemahan	Perbandingan
1	Automated Detection of Retinal Nerve Fiber Layer by Texture-Based Analysis for Glaucoma Evaluation	Anindita Septiariini, , Agus Harjoko, , Reza Pulungan, , Retno Ekantini, Healthcare Informatics Research, 2018.	Mendeteksi ada dan tidaknya Retinal Nerve Fiber Layer pada citra fundus menggunakan Ekstraksi Fitur Tekstur Gray Level Co-Occurrence dan seleksi Fitur CFS.	Kesimpulan dari penelitian ini menunjukkan bahwa metode yang digunakan menghasilkan hasil yang baik yang ditunjukkan oleh akurasi sebesar 94,52 %.	Penelitian ini memiliki potensi pengembangan menggunakan metode seleksi fitur yang lain sehingga dapat meningkatkan akurasi yang didapatkan.	Pada jurnal ini digunakan proses seleksi fitur CFS dan menghasilkan 2 buah fitur dari 10 buah fitur GLCM yang digunakan sedangkan pada penelitian yang akan dilakukan akan menggunakan metode – metode Evolutionary Algorithm dan menggunakan 21 fitur dari metode GLCM.

Tabel 2.1. Lanjutan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
2	Thickness related textural properties Color of retinal nerve fiber layer in fundus images	Jan Odstrejlik., Radim Kolar, Ralf-Peter Tornow, Jiri Jan, Attila Budai, Markus Mayer, Martina Vodakov, Robert Laemmer, Martin Lamos, Zdenek Kuna, Jiri Gazarek,	Membandingkan korelasi antara hasil evaluasi menggunakan Gaussian Random Markov Field dan Local Binary Pattern dengan Hasil Evaluasi dari OCT	Kesimpulan dari penelitian ini adalah hasil evaluasi antara metode yang diusulkan dengan hasil evaluasi OCT memiliki korelasi yang besar dengan kata lain bahwa hasil evaluasi dari metode yang diusulkan dapat	Penelitian ini hanya menyebutkan hasil korelasi tanpa menyebutkan hasil evaluasinya. Penelitian ini juga membandingkan evaluasi menggunakan citra fundus yang utuh.	Pada jurnal ini data yang digunakan untuk evaluasi menggunakan data fundus utuh sedangkan pada penelitian yang akan dilakukan menggunakan data fundus yang dibagi menjadi 12 sub sector sesuai dengan evaluasi RNFL pada OCT

Tabel 2.1. Lanjutan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
		Tomas Kubena, Pavel Cernosek, Marina Ronzhina. Computerized Medical Imaging and Graphics, 2014		dijadikan tolak ukur evaluasi RNFL		
3	Automatic glaucoma classification using color fundus images based on	Juan J.Gómez-Valverde, Alfonso antón Gian lucafatti	Menggunakan pendekatan klasifikasi menggunakan CNN	Penggunaan metode yang diusulkan pada jurnal ini menghasilkan	Penelitian ini memiliki potensi untuk dikembangkan dengan menambahkan data dan	Pada jurnal ini menggunakan pendekatan deep learning pada klasifikasi RNFL sedangkan pada penelitian

Tabel 2.1. Lanjutan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	convolutional neural networks and transfer learning	Bart liefers Alejandra hervanz Andrés santos clara I.Sánchez Maria J.Ledesma-Carbayo Biomedical Optics Express,2019	dan Transfer learning untuk mendeteksi glaukoma pada citra fundus	nilai AUC sebesar 0,94.	menggunakan Architectural yang lain.	yang akan dilakukan menggunakan pendekatan metode klasifikasi tradisional
4	Automated classification of	Agrawal, Dhceraj Kumar	Menggunakan metode fitur	Penggunaan metode FAWT dan relief	Penelitian ini juga membandingkan	Pada jurnal ini menggunakan FAWT sebagai metode

Tabel 2.1. Lanjutan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	glaucoma stages using flexible analytic wavelet transform from retinal fundus images	Agrawal, Dhceeraj Kumar IEEE Sensors Journal,2020	FAWT dan seleksi fitur Relief F untuk mendeteksi penyakit glaukoma pada citra fundus.	menghasilkan akurasi sebesar 93,40 %	evaluasi menggunakan citra fundus yang utuh.	ekstraksi fitur dan metode seleksi fitur berbasis filter yaitu relief. Sedangkan pada penelitian yang akan dilakukan menggunakan metode GLCM sebagai metode ekstraksi fitur dan algoritma evolusi sebagai metode seleksi fitur
5	Analysis of retinal nerve fiber layer via	Odstrcilik, Jan Kolar, Radim	Menggunakan metode Markov	Penelitian ini menyimpulkan bahwa	Penelitian ini memiliki potensi pengembangan	Penelitian ini menggunakan Markov random field

Tabel 2.1. Lanjutan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	Markov random fields in color fundus images	Jan, Jiri Jan, Jiri Gazarek, Jiri Kuna, Zdenek Vodakova, Martina International Conference on Systems, Signals and Image Processing, 2012	random field sebagai fitur dan menggunakan metode seleksi fitur Maximum relevance Minimum Redundancy (MRMR) dan GMM sebagai metode klasifikasi dan	metode yang digunakan memiliki korelasi yang baik terhadap evaluasi dari OCT	dengan menggunakan algoritma klasifikasi lainnya dan metode ekstraksi fitur yang lain, Penelitian ini juga membandingkan evaluasi menggunakan citra fundus yang utuh.	sebagai fitur yang kemudian diseleksi menggunakan metode MRMR sedangkan pada penelitian yang akan dilakukan menggunakan metode GLCM sebagai fitur dan Algoritma evolusi sebagai metode seleksi fitur. jurnal ini menilai korelasi hasil evaluasi antara hasil

Tabel 2.1. Lanjutan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			membandingkan hasil evaluasinya dengan evaluasi OCT			evaluasi metode yang diusulkan dengan evaluasi OCT sedangkan penelitian yang akan dilakukan menjadikan OCT sebagai rujukan dalam pembuatan subsektor pada citra fundus
6	Detection of retinal nerve fiber layer defects on retinal fundus images for	Muramatsu, Chisako Hayashi, Yoshimori Sawada, Akira	Menggunakan 162 data fundus yang kemudian diklasifikasikan	Penelitian ini mendapatkan hasil specificity sebesar 91 %	Penelitian ini memiliki potensi pengembangan dengan menggunakan metode ekstraksi fitur	Penelitian ini menggunakan gabor filter, LDA dan ANN sebagai metode yang digunakan dalam penelitian


Tabel 2.1. Lanjutan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	early diagnosis of glaucoma	Hatanaka, Yuji Hara, Takeshi Yamamoto, Tetsuya Fujita, Hiroshi Journal of Biomedical Optics,2010	menggunakan metode LDA dan ANN. Data fundus yang digunakan juga ditingkatkan menggunakan Gabor Filter		yang lain sebagai pembanding dari metode yang diusulkan. Penelitian ini juga membandingkan evaluasi menggunakan citra fundus yang utuh.	sedangkan penelitian yang akan dilakukan menggunakan GLCM , Algoritma evolusi sebagai metode seleksi fitur dan ANN sebagai metode klasifikasi

2.3. Landasan Teori

2.3.1 Retinal Nerve Fiber Layer

Dataset yang digunakan adalah dataset citra fundus yang telah mengalami segmentasi Optic nerve head dengan menggunakan metode yang telah diusulkan pada penelitian (Septiarini et al., 2017). Dataset yang digunakan pada penelitian ini juga digunakan pada penelitian (Septiarini et al., 2018). Retina Nerve Fiber Layer (RNFL) adalah bagian dari retina yang terletak di luar Optic Nerve Head (ONH), yang dapat diamati pada citra fundus retina. Secara visual, ONH adalah area bulat yang terang atau sedikit oval, dan RNFL adalah area dengan tekstur khas yang tampak seperti goresan-goresan dengan warna keputihan. Pada mata normal, tekstur RNFL terlihat jelas dan penyebarannya secara merata di semua sektor, sedangkan pada pasien glaukoma, struktur RNFL cenderung hilang, yang mengindikasikan cacat RNFL. Ilustrasi citra sesudah dilakukan segmentasi Optic nerve head dapat dilihat pada gambar 2.1.




Gambar 2.1. Ilustrasi Citra fundus yang telah mengalami segmentasi ONH

2.3.2 Ekstraksi Fitur GLCM

Ekstraksi fitur menjelaskan bentuk yang relevan informasi yang terkandung dalam suatu pola sehingga tugas mengklasifikasikan pola menjadi mudah oleh formal (Kumar & Bhatia, 2014) .

Gray Level Co-occurrence Matrix (GLCM) adalah teknik untuk memperoleh teksturcitra dengan menggunakan perhitungan pada orde kedua. Pengukuran tekstur pada orde pertama menggunakan perhitungan statistika didasarkan pada nilai pixel citra asli semata, seperti varians, dan tidak memperhatikan hubungan ketetangaan pixel. Pada orde kedua, hubungan antarpasangan dua pixel citra asli diperhitungkan . *Gray level co-occurrence matrix (GLCM)* merupakan matrik yang menggambarkan frekuensi munculnya pasangan piksel pada jarak d dan orientasi arah dengan sudut θ dalam citra yang digunakan untuk menghitung fitur-fitur glcm. Ilustrasi sudut θ pada glcm dapat dilihat pada gambar 2.2.



Gambar 2. 2 Ilustrasi sudut θ pada GLCM

Sebagai ilustrasi, ketetangaan piksel dapat dipilih ke arah timur (kanan). Salah satu cara untuk merepresentasikan hubungan ini yaitu berupa

(1,0), yang menyatakan hubungan dua piksel yang berjajar horizontal dengan piksel bernilai 1 diikuti dengan piksel bernilai 0.

Menurut penelitian (Haralick et al., 1973) fitur yang dapat dihitung pada GLCM adalah *Contrast, Correlation, Difference entropy, Difference variance, Energy, Inverse Difference Moment, Information measure of correlation 1, Information measure of correlation 2, Sum average, Sum entropy, Sum of squares: Variance, Sum variance*. Berdasarkan penelitian (Soh & Tsatsoulis, 1999) terdapat penambahan perhitungan fitur yaitu *Autocorrelation, Cluster Prominence, Cluster Shade, Dissimilarity, Entropy, Maximum probability, Homogeneity*. Kemudian untuk menambah akurasi dalam klasifikasi citra ditambahkan fitur *Inverse Difference Moment Normalized, Inverse Difference Normalized* (Clausi, 2002). Sehingga terdapat total 21 fitur yang terdapat dalam metode ekstraksi ciri tekstur GLCM.

1. *Contrast*

$$\sum (i-j)^2 P(i,j)$$

Dimana :

i dan j : koordinat pada matriks kookurensi.

$P(i,j)$: nilai koordinat pada matriks kookurensi.

2. *Correlation*

$$\sum \frac{(i - \mu_i)(j - \mu_j)P(i, j)}{\sigma_i \sigma_j}$$

Dimana :

i dan j : koordinat pada matriks kookurensi

$P(i, j)$: nilai koordinat pada matriks kookurensi

μ_i : nilai rata-rata pada elemen matrik i

$$\mu_i = \sum_i \sum_j i p(i, j)$$

μ_j : nilai rata-rata pada elemen matriks j

$$\mu_j = \sum_i \sum_j j p(i, j)$$

σ_i : standar deviasi pada elemen matriks i

$$\sigma_i = \sqrt{\sum_i \sum_j (i - \mu_i)^2 p(i, j)}$$

σ_j : standar deviasi pada elemen matriks j

$$\sigma_j = \sqrt{\sum_i \sum_j (j - \mu_j)^2 p(i, j)}$$

3. *Difference Entrophy*

$$\sum_{i=0}^{N-1} i^2 p_{i \rightarrow i}(i) \log \{ p_{i \rightarrow i}(i) \}$$

Dimana :

N : jumlah dari intensitas keabuan

$$P_x(i) \quad :$$

$$P_x(i) = \sum_{j=0}^{i-1} P(i, j)$$

$$P_y(i) \quad :$$

$$\sum_{j=0}^{N-1} P(i, j)$$

$$P_{x+y}(k) \quad :$$

$$\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P(i, j), \quad i+j=k$$

$$k = 0, 1, \dots, 2(N-1)$$

$$P_{x-y}(k) \quad :$$

$$\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P(i, j), \quad |i-j|=k$$

$$k = 0, 1, \dots, (N-1)$$

4. Difference Variance

$$\sum_{i=0}^{N-1} i^2 p_{x-y}(i)$$

5. Energy

$$\sum_i \sum_j p(i, j)^2$$

6. Inverse Difference Moment

$$\sum_i \sum_j \frac{1}{1+|i-j|^2} P(i, j)$$

7. Information of Measures Correlation 1

$$\frac{HXY - HXY1}{\max\{HX, HY\}}$$

Dimana :

HX : entropi dari $P_x(i)$

HY : entropi dari $P_y(i)$

HXY :

$$-\sum_i \sum_j p(i, j) \log(p(i, j))$$

HXY1 :

$$-\sum_i \sum_j p(i, j) \log\{p_x(i)p_y(j)\}$$

HXY2 :

$$-\sum_i \sum_j p_x(i)p_y(j) \log\{p_x(i)p_y(j)\}$$

8. Information of measures Correlation 2

$$(1 - \exp[-2(HXY2 - HXY)])^{\frac{1}{2}}$$

9. *Sum averages*

$$\sum_{i=2}^{2N} ip_{x,y}(i)$$

10. *Sum Entrophy*

$$-\sum_{i=2}^{2N} p_{x,y}(i) \log\{p_{x,y}(i)\}$$

11. *Sum squares of variances*

$$\sum_i \sum_j (i - \mu)^2 p(i, j)$$

Dimana:

μ : mean dari $p(i, j)$

12. *Sum variances*

$$\sum_{i=2}^{2N} \left(i - \left(\sum_{i=2}^{2N} ip_{x,y}(i) \right) \right)^2 p_{x,y}(i)$$

13. *Auto Correlation*

$$\sum_i \sum_j (ij) p(i, j)$$

14. *Cluster Shade*

$$\sum_i \sum_j (i + j - \mu_x - \mu_y)^2 p(i, j)$$

Dimana :

$$\mu_x \quad :$$

$$\sum_{i=0}^{N-1} iP_x(i)$$

$$\mu_y \quad :$$

$$\sum_{j=0}^{N-1} jP_y(j)$$

15. *Cluster prominence*

$$\sum_i \sum_j (i + j - \mu_x - \mu_y)^k p(i, j)$$

16. *Dissimilarity*

$$\sum_i \sum_j |i - j| \cdot p(i, j)$$

17. *Entropy*

$$-\sum_i \sum_j p(i, j) \log(p(i, j))$$

18. *Homogeneity*

$$\sum_{i,j} \frac{p(i, j)}{1 + |i - j|}$$

19. *Maximum Probability*

$$\text{MAX}_{i,j} p(i, j)$$

20. *Inverse difference moment normalized*

$$\sum_{j=1}^N \sum_{i=1}^N \frac{p(i, j)}{1 + (i - j)^2 / N^2}$$

21. *Inverse difference normalized (homogeneity normalized)*

$$\sum_{j=1}^N \sum_{i=1}^N \frac{p(i, j)}{1 + |i - j|^2 / N^2}$$

2.3.3 Seleksi Fitur

Seleksi fitur adalah proses mengidentifikasi subset fitur yang relevan dari serangkaian fitur yang lebih besar untuk digunakan dalam model. Tujuan seleksi fitur adalah untuk meningkatkan kinerja dari suatu model dengan mengurangi dimensi data dan menghapus fitur yang tidak relevan dan berlebihan. Ada dua jenis seleksi fitur, antara lain adalah seleksi fitur menggunakan metode filter dan seleksi fitur menggunakan metode wrapper (Firdaus et al., 2020).

1. Metode Filter

Metode filter mengevaluasi fitur secara independent dengan menghitung nilai imbal balik, nilai korelasi, nilai F-value yang kemudian fitur terbaik akan dipilih berdasarkan nilai ambang batas atau ranking yang telah ditentukan. Dalam pendekatan seleksi fitur berbasis filter, fitur-fitur dipilih menggunakan suatu Langkah preprocessing. Kelemahan utama dari pendekatan seleksi fitur berbasis filter adalah bahwa metode tersebut sepenuhnya mengabaikan pengaruh suatu subset fitur yang telah terpilih terhadap kinerja algoritma klasifikasi (Pudjihartono et al., 2022).

2. Metode Wrapper

Metode wrapper menggunakan kinerja dari suatu model sebagai kriteria untuk mengevaluasi pentingnya fitur. Model dilatih dengan subset fitur yang berbeda dan subset yang menghasilkan kinerja terbaik kemudian dipilih. Dalam pendekatan seleksi fitur berbasis wrapper, algoritma pemilihan subset fitur berfungsi sebagai pembungkus (wrapper) di sekitar algoritma klasifikasi. Algoritma pemilihan subset fitur melakukan pencarian subset yang baik dengan menggunakan algoritma klasifikasi itu sendiri sebagai bagian dari fungsi evaluasi subset fitur. Ide di balik pendekatan seleksi fitur berbasis wrapper ini adalah algoritma klasifikasi digunakan sebagai black box. Algoritma klasifikasi dijalankan pada dataset, yang biasanya dibagi menjadi data latih internal, dengan berbagai subset fitur yang didapatkan dari proses seleksi. Subset fitur yang memiliki nilai evaluasi tertinggi dipilih sebagai set akhir yang akan dijalankan oleh algoritma klasifikasi. (Pudjihartono et al., 2022)

3. Metode Embedded

Dalam pendekatan tersemat, algoritma klasifikasi menggabungkan atau menggunakan pemilihan fitur secara langsung. Metode Klasifikasi disesuaikan pengaturan internalnya dan memilih bobot/kepentingan yang tepat untuk setiap fitur guna menghasilkan akurasi klasifikasi terbaik selama fase training. Sebagai hasilnya, dengan metode tersemat, pencarian subset fitur yang ideal dan pembangunan model digabungkan dalam satu fase.

Dengan mengurangi jumlah fitur yang digunakan dalam suatu model, seleksi fitur dapat membantu mengurangi overfitting dan meningkatkan kemampuan klasifikasi dari suatu model.

2.3.4. Seleksi fitur dengan Algoritma evolusi

Komputasi dengan menggunakan algoritma evolusi yang menggunakan mekanisme yang terinspirasi oleh alam dan memecahkan masalah melalui proses yang meniru perilaku organisme-organisme hidup. Pada saat ini Algoritma Evolusi banyak digunakan pada bidang seleksi fitur. Algoritma tersebut meliputi Algoritma genetika, *Differential Evolution*, *Swarm Intelligence* digunakan pada berbagai macam tipe dataset yang berbeda. Algoritma tersebut memperoleh hasil optimisasi yang tinggi dan meningkatkan akurasi (Rathna Sekhar & Sujatha, 2020).

Beberapa penelitian yang menggunakan algoritma evolusi sebagai seleksi fitur antara lain, klasifikasi emosi berdasarkan electroencephalogram (EEG) menggunakan algoritma evolusi *Ant Colony Optimization*, *Simulated Annealing*, *Differential Evolution*, dan *Particle Swarm Optimization* sebagai algoritma seleksi fitur (Nakisa et al., 2018). Klasifikasi *motor imagery brain computer imagery* berbasis *Electroencephalogram* (EEG) (Tan et al., 2020). Klasifikasi pada buah menggunakan *Artificial Bee Colony* sebagai seleksi fitur (Abd Alkreem & Karim, 2021). Beberapa penelitian diatas menggunakan beberapa algoritma evolusi untuk mereduksi fitur – fitur yang tidak relevan pada data – data

yang dihasilkan. Kemudian pada penelitian (Eleya, 2019) Performa klasifikasi yang menggunakan *Particle Swarm Optimization* memberikan hasil yang lebih baik daripada algoritma lain seperti *Principal Component Analysis*.

Menurut (Yazdani & Meybodi, 2014) Kelebihan dari Algoritma *Artificial Bee Colony* adalah simplisitas dan fleksibilitas dengan tingkat ketepatan dan keakuratan yang tinggi. Menurut (Jong-Bae Park & Kwang Y. Lee, 2006) Kelebihan utama dari Algoritma *Particle Swarm Optimization* adalah Konsep algoritma yang ringkas, Kemudahan untuk diimplementasikan, Kemudahan untuk mengontrol parameter - parameternya, dan efisiensi dalam hal komputasi saat dibandingkan dengan metode – metode optimasi lainnya.

Algoritma evolusi adalah suatu algoritma yang merupakan subset dari komputasi evolusi (*evolutionary computation, EC*) yang merupakan bentuk generik dari algoritma optimasi meta-heuristic berbasis populasi. Sifat fleksibel dan perilaku kuat yang diwarisi dari *Evolutionary Computation*, algoritma ini menjadi sarana metode pemecahan masalah yang efisien untuk masalah optimalisasi yang banyak digunakan. Algoritma ini juga dapat digunakan dengan baik dalam banyak aplikasi dengan kompleksitas tinggi (Pradnya A.Vikhar, 2016). Penggunaan GA sebagai pendekatan meta-heuristik untuk masalah optimasi sudah digunakan secara luas. Pendekatan ini terinspirasi dari proses evolusi biologis, seperti *Selection*, *Cross over*, dan *mutation*. Langkah-langkah dasar GA melibatkan

pembuatan populasi awal, pemilihan kromosom induk, melakukan persilangan dan mutasi untuk menghasilkan kromosom anak (child), dan mengganti kromosom yang memiliki nilai fitness yang rendah dengan yang nilai fitness yang tinggi atau sebaliknya.

Awalnya, GA menghasilkan populasi acak dari sejumlah kromosom, masing-masing dengan Panjang kromosom tetap. Gen dalam setiap kromosom diisi dengan nilai acak, berfungsi sebagai populasi awal. Dari populasi ini, beberapa kromosom dipilih sebagai induk dan mengalami persilangan dan mutasi untuk menghasilkan kromosom anak. Kesesuaian kromosom ini kemudian dievaluasi menggunakan fitness function. Jika kromosom anak memiliki nilai fitness yang lebih baik daripada beberapa kromosom dalam populasi, kromosom tersebut akan menggantikan kromosom dengan nilai fitness yang lebih rendah.

Fitness function mengevaluasi kualitas solusi yang diwakili oleh representasi genetik. Proses ini mengarah pada generasi kromosom berikutnya, yang mengalami proses *Selection*, *Crossover*, dan *Mutation* yang sama. Setelah beberapa generasi, GA menyatu dengan solusi yang mendekati optimal. Dalam seleksi fitur, versi biner GA digunakan, di mana setiap kromosom direpresentasikan sebagai angka '0' dan '1'. Angka '0' menandakan fitur yang tidak digunakan, sedangkan '1' menunjukkan fitur yang digunakan (Khan et al., 2022).

2.3.5 Fungsi Fitness

Fungsi fitness (*Fitness function*) adalah suatu fungsi objektif yang dikembangkan untuk suatu masalah dengan memuat seluruh parameter untuk menemukan solusi yang diinginkan. Pada proses seleksi fitur, fungsi fitness digunakan untuk menilai kelayakan dari suatu subset fitur. Pada penentuan fungsi fitness, digunakan dua buah kriteria yaitu akurasi dari klasifikasi dan jumlah dari fitur yang terpilih dimana individu yang memiliki jumlah fitur sedikit dan akurasi klasifikasi yang tinggi memiliki nilai fitness yang tinggi (Zhuo et al., 2008). Formula dari fungsi fitness tersebut dapat di deskripsikan :

$$fitness = \alpha * accuracy + \beta \left(\frac{x}{y} \right)$$

Dimana :

- α = bobot dari akurasi
- β = bobot dari fitur
- x = jumlah fitur terpilih
- y = jumlah seluruh fitur

Secara umum, bobot dapat diatur dalam rentang 75% sampai 100% tergantung dari kebutuhan. Pada penelitian ini nilai bobot α diatur pada nilai 90% dan bobot β diatur pada nilai 10%. Nilai bobot tersebut dapat diartikan

bahwa nilai fitness bergantung kepada tinggi nya nilai akurasi kemudian dari banyaknya fitur yang terpilih.

2.3.6 Artificial Neural Network

Artificial Neural Network adalah salah satu metode klasifikasi yang terinspirasi dari cara kerja sistem saraf biologis, khususnya sel-sel otak manusia dalam memproses informasi. Prinsip dasar ANN adalah sejumlah parameter sebagai input (layer input) diproses secara tertentu di hidden layer, kemudian diproses kembali di lapisan output untuk menghasilkan output.

Jaringan saraf tiruan pertama kali dikembangkan pada tahun 1958 oleh Frank Rosenblatt untuk menjelaskan cara kerja dari otak manusia memproses data visual dan belajar mengenali objek. Jaringan saraf tiruan dirancang untuk mengimitasi Tindakan – Tindakan yang dapat dilakukan oleh otak manusia. Hasil yang didapatkan dari sistem yang dibuat tersebut mampu melakukan pembelajaran mesin serta melakukan pengenalan pola. Hal ini menghasilkan suatu sistem neuron yang saling terhubung, yang kemudian mampu menghitung nilai-nilai dari input yang diberikan. (Dave, 2019)

Pada dasarnya, Artificial neural network memiliki suatu mekanisme tersendiri untuk mereduksi fitur yaitu dengan menggunakan metode regularization. Metode regularization digunakan untuk menghilangkan resiko overfitting dimana ANN menggunakan seluruh data secara maksimal

untuk mempelajari seluruh data yang diberikan termasuk data yang bersifat noise. Data noise yang dimaksud adalah data yang tidak mewakili keseluruhan data yang sebenarnya melainkan data yang ada karena hasil kebetulan random. Oleh karena itu, metode regularization digunakan untuk mencegah model ANN yang terlalu kompleks, guna menghindari masalah overfitting. Beberapa metode regularization antara lain adalah : L1 regularization, L2 regularization, elastic net regularization dan lain – lain (Dave, 2019)

Pada dasarnya metode regularization dan seleksi fitur memiliki tujuan yang sama yaitu meringkaskan fitur – fitur yang akan digunakan sebagai input pada ANN. Perbedaan antara metode regularization dan metode seleksi fitur lainnya adalah metode regularization bekerja pada proses ANN sehingga membutuhkan proses komputasi yang lebih pada ANN sedangkan proses seleksi fitur dilakukan sebelum proses ANN sehingga proses ANN menjadi lebih simple karena fitur yang digunakan pada proses input adalah fitur yang terseleksi pada proses seleksi fitur sebelumnya.

Artificial neural network dibagi menjadi tiga lapisan proses yaitu Input layer (lapisan input), Hidden Layer (lapisan tersembunyi) dan Output Layer (lapisan keluaran).(Anita & Albarda, 2020)

1. Input Layer

Fungsi layer input adalah menerima informasi dari dataset untuk setiap observasi yang dilakukan. Ada node-node yang membantu dalam


mendapatkan input. Jumlah node input sering kali sesuai dengan jumlah properti dataset. Node input pada layer input bersifat pasif, yang berarti mereka hanya mengulang nilai-nilai input dan mentransfernya ke berbagai output tanpa mengubah atau mengubah data tersebut.

2. Hidden Layer

Tujuan dari layer tersembunyi adalah melakukan transformasi pada nilai-nilai input jaringan. Sebagai input, hidden layer dapat terhubung dengan input layer atau hidden layer yang lainnya. Perhitungan yang dilakukan pada hidden layer melalui *weighted connection*. *Weight* / bobot adalah sekumpulan angka yang telah ditentukan sebelumnya dikalikan dengan nilai-nilai yang masuk ke hidden layer.

3. Output layer

Layer yang paling akhir pada struktur artificial neural network adalah output layer. Layer ini mengeluarkan suatu output prediksi berdasarkan dari input layer dan hidden layer. Pada suatu kasus klasifikasi yang menggunakan artificial neural network terdapat satu node yang ada pada output layer, yang mana node tersebut memberikan hasil dari klasifikasi suatu kasus tersebut.



Gambar 2.3. Ilustrasi Artificial Neural Network

BAB III

METODE PENELITIAN

3.1. Jenis, Sifat, dan Pendekatan Penelitian

Penelitian yang dilakukan menggunakan pendekatan kuantitatif. Penelitian ini termasuk kedalam jenis penelitian eksperimen. Penelitian eksperimen adalah metode yang dapat menguji hipotesis mengenai hubungan sebab akibat.

3.2. Metode Pengumpulan Data

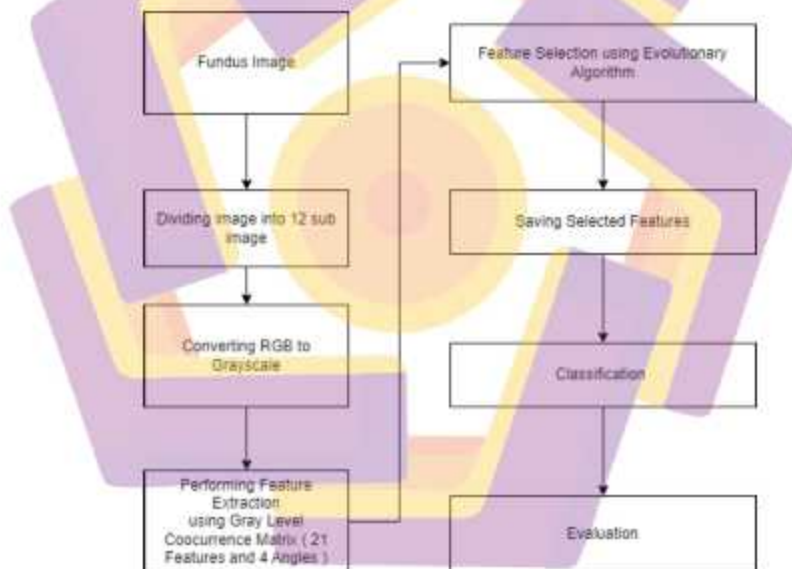
Data yang digunakan dalam penelitian ini adalah data primer. Data yang digunakan berukuran sebesar 4288×2848 pixels dan berukuran 2240×1488 pixels. Data tersebut digunakan pada penelitian (Septiarini et al., 2018)

3.3. Metode Analisis Data

Metode analisis yang digunakan dalam penelitian ini adalah analisis statistika uji regresi. Analisis dengan uji regresi ini dilakukan untuk mengetahui pengaruh antar variabel dependen dan independen. Pada penelitian ini uji regresi dilakukan untuk mengetahui hubungan antara jumlah fitur dengan akurasi yang dihasilkan dan waktu komputasi. Jumlah fitur digunakan sebagai variabel independen dan hasil akurasi digunakan sebagai variabel dependen.

3.4. Alur Penelitian

Pada penelitian ini, terdapat beberapa proses yang akan dilakukan seperti, Pembagian citra menjadi 12 citra sub sektor, kemudian perubahan ruang warna RGB menjadi ruang warna *Grayscale* kemudian ekstraksi fitur menggunakan metode *Gray Level Coocurrence Matrix* sebanyak 21 Fitur dan 4 buah sudut ekstraksi, Seleksi fitur menggunakan algoritma evolusi dan kemudian dilakukan proses klasifikasi dan evaluasi. Alur penelitian dapat dilihat pada gambar 3.1.




Gambar 3.1. Bagan Alur Penelitian.

3.4.1. Citra Fundus

Citra yang digunakan berjumlah 20 buah citra fundus yang telah mengalami segmentasi ONH menggunakan metode yang diusulkan oleh (Septiarini et al., 2017) dan masing – masing akan dibagi menjadi 12 sub sektor pada setiap gambar berdasarkan pembagian pada citra OCT. kemudian citra subsektor tersebut yang akan digunakan sebagai citra yang akan mengalami proses ekstraksi fitur, seleksi fitur dan klasifikasi. Contoh citra OCT dan ilustrasi pembagian citra fundus menjadi 12 subsektor dapat dilihat pada gambar 3.2 dan 3.3.



Gambar 3.2. Contoh Citra OCT



Gambar 3.3. Ilustrasi Pembagian Citra Fundus menjadi 12 buah Sub Sektor

3.4.2. Mengubah ruang warna RGB ke ruang warna Grayscale

Proses Preprocessing dilakukan untuk mengubah citra berwarna menjadi citra grayscale. Hal ini dilakukan karena metode ekstraksi fitur GLCM menggunakan ruang warna dua dimensi yaitu Grayscale. Citra berwarna terdiri dari 3 layer matrik yaitu R layer, G layer dan B layer. Sehingga untuk melakukan proses - proses selanjutnya tetap diperhatikan tiga layer di atas. Bila setiap proses perhitungan dilakukan menggunakan tiga layer, berarti dilakukan tiga perhitungan yang sama. Sehingga konsep itu

diubah dengan mengubah 3 layer di atas menjadi 1 layer matrik grayscale dan hasilnya adalah citra grayscale (Prayogo et al., 2021) .Persamaan yang digunakan untuk mengubah citra berwarna menjadi citra grayscale dapat dilihat pada persamaan dibawah :

$$\frac{R + G + B}{3}$$

Dimana :

R layer adalah nilai dari value piksel red

G layer adalah nilai dari value piksel green

B layer adalah nilai dari value piksel blue

3.4.3 Ekstraksi Fitur menggunakan GLCM

Setelah semua citra subsektor dirubah ruang warnanya menjadi Grayscale maka proses selanjutnya adalah proses ekstraksi fitur GLCM. Fitur yang akan diekstraksi adalah sebanyak 21 Fitur dan 4 buah sudut yaitu 0, 45, 90 dan 135 derajat sehingga total dari seluruh fitur yang akan diekstraksi adalah sebanyak 84 buah fitur. fitur – fitur tersebut dapat dilihat pada subbab 2.3.2 bagian esktraksi fitur GLCM.

3.4.4 Seleksi fitur menggunakan Algoritma evolusi

Seleksi fitur yang digunakan pada penelitian ini menggunakan Algoritma evolusi. 84 fitur yang telah didapatkan pada proses ekstraksi fitur akan diseleksi untuk menemukan fitur – fitur yang paling relevan untuk

mengklasifikasikan Retinal nerve fiber layer. Algoritma yang digunakan adalah algoritma Algoritma genetika dan sebagai algoritma pembanding digunakan algoritma particle swarm optimization dan Artificial bee colony.

3.4.5 Klasifikasi

Pada tahapan klasifikasi citra, kelas yang akan digunakan ada 2 kelas yaitu ada dan tidak ada. Metode klasifikasi ini menggunakan nilai-nilai hasil ekstraksi ciri sebagai masukan. Metode klasifikasi yang digunakan adalah Artificial neural network dimana jumlah epoch yang digunakan adalah 100 epoch.

3.4.6 Evaluasi

Dalam proses validasi dan pengujian menggunakan metode *K-Fold Cross Validation*. Menurut (Rohani et al., 2018) *K-Fold Cross Validation* adalah salah satu dari jenis pengujian *Cross Validation* yang berfungsi untuk menilai kinerja proses sebuah metode algoritma dengan membagi sampel data secara acak dan mengelompokkan data tersebut sebanyak nilai K pada K-fold. Kemudian salah satu kelompok k-fold tersebut akan dijadikan sebagai data uji sedangkan sisa kelompok yang lain akan dijadikan sebagai data latih.

Confusion matrix merupakan salah satu metode yang dapat digunakan untuk mengukur kinerja suatu metode klasifikasi. Pada pengukuran kinerja menggunakan *confusion matrix*, terdapat 4 (empat) istilah sebagai representasi hasil proses klasifikasi. Keempat istilah tersebut adalah *True*

Positive (TP), *True Negative* (TN), *False Positive* (FP) dan *False Negative* (FN).

Nilai *True Negative* (TN) merupakan jumlah data negatif yang terdeteksi dengan benar, sedangkan *False Positive* (FP) merupakan data negatif namun terdeteksi sebagai data positif. Sementara itu, *True Positive* (TP) merupakan data positif yang terdeteksi benar. *False Negative* (FN) merupakan kebalikan dari *True Positive*, sehingga data positif, namun terdeteksi sebagai data negatif.

Dalam tahap pengujian, tolak ukur untuk menilai klasifikasi sebagai klasifikasi yang baik menggunakan akurasi, *specificity* dan *sensitivity*. Akurasi adalah kemampuan sistem klasifikasi untuk membedakan citra fundus yang memiliki RNFL dan yang tidak memiliki RNFL. *Specificity* adalah kemampuan sistem klasifikasi untuk mengetahui citra fundus yang memiliki RNFL dan *Sensitivity* adalah kemampuan sistem klasifikasi untuk mengetahui citra fundus yang tidak memiliki RNFL. Akurasi, *specificity* dan *sensitivity* dapat dideskripsikan sebagai berikut (Septiarini et al., 2018) :

$$\text{Akurasi} = \frac{\text{True Positive} + \text{True Negative}}{\text{True Positive} + \text{True Negative} + \text{False Positive} + \text{False Negative}}$$

$$\text{Specificity} = \frac{\text{True Positif}}{\text{True Positive} + \text{False Negative}}$$

$$\text{Sensitivity} = \frac{\text{True Positif}}{\text{True Negative} + \text{False Positive}}$$

BAB IV

HASIL PENELITIAN DAN PEMBAHASAN


4.1. Pembentukan 12 Sub citra

Sebelum dilakukan proses pemotongan citra menjadi 12 sub citra dilakukan segmentasi ONH. Segmentasi tersebut dilakukan untuk menghapus bagian ONH menggunakan metode – metode yang telah dilakukan pada penelitian (Septiarini et al., 2017, 2018). Proses pemotongan citra menjadi 12 bagian kemudian dilakukan dengan menggunakan template yang telah disiapkan terlebih dahulu. Ilustrasi template tersebut dapat dilihat pada gambar 4.1.



Gambar 4.1. Ilustrasi template pemotong

Kemudian template tersebut dilakukan rotasi 90,180 dan 270 derajat untuk digunakan sebagai template pemotong citra fundus menjadi 12 sub citra. Ilustrasi rotasi dari template tersebut dapat dilihat pada gambar 6. Setelah didapatkan 12 template tersebut tahap selanjutnya adalah melakukan pemotongan citra fundus berdasarkan template tersebut. Hasil dari pemotongan tersebut dapat dilihat pada gambar 4.2.



Gambar 4.2. Ilustrasi template yang telah dirotasi untuk digunakan sebagai template pemotong

Proses pemotongan citra fundus menjadi 12 sub citra dilakukan pada seluruh data citra fundus yang akan digunakan sehingga jumlah 44 citra fundus tersebut akan menjadi 528 sub citra yang akan digunakan untuk proses klasifikasi. Contoh subcitra yang memiliki RNFL dan subcitra yang tidak memiliki RNFL dapat dilihat pada gambar 4.3 dan 4.4.




Gambar 4.3. Contoh subcitra yang memiliki RNFL.



Gambar 4.4. Contoh subcitra yang tidak memiliki RNFL.

4.2 . Mengubah citra RGB menjadi citra Grayscale

Setelah dilakukan proses pemotongan citra fundus menjadi 12 sub citra, dilakukan proses pengubahan ruang warna RGB menjadi ruang warna Grayscale . Hal ini dilakukan karena metode GLCM hanya bekerja pada ruang warna 1 layer . Contoh hasil perubahan ruang warna RGB menjadi ruang warna Grayscale dapat dilihat pada gambar 4.5.



Gambar 4.5. Contoh perubahan sub citra ruang warna RGB ke ruang warna Grayscale.

4.3 . Ekstraksi Ciri Tekstur menggunakan GLCM.

Setelah semua data subcitra mengalami perubahan ruang warna menjadi grayscale, maka Langkah selanjutnya adalah proses ekstraksi fitur menggunakan GLCM. Jumlah fitur yang akan digunakan adalah 21 fitur dan 4 arah sehingga total fitur berjumlah 84 fitur seperti yang dijelaskan pada subbab 2.3.2. Hasil ekstraksi tersebut kemudian disimpan menjadi sebuah matriks pada aplikasi matlab. Hasil ekstraksi fitur subcitra yang terdapat RNFL dan ekstraksi fitur subcitra yang tidak terdapat RNFL dapat dilihat pada tabel 4.1 dan 4.2.

Tabel 4.1. Contoh hasil ekstraksi subcitra yang memiliki RNFL menggunakan GLCM

Nama Fitur	0	45	90	135
Autocorrelation	1.65225	1.649119	1.654174	1.654934
Cluster Prominence	40.13039	39.35819	40.5583	40.24725
Cluster Shade	7.059653	6.973278	7.103883	7.086247
Contrast	0.029561	0.039837	0.025713	0.028207
Correlation	0.93893	0.944899	0.964275	0.960921
Difference entropy	0.094487	0.115349	0.086146	0.09234
Difference variance	0.020249	0.026231	0.017982	0.019579
Dissimilarity	0.029151	0.039149	0.02539	0.027824
Energy	0.885756	0.884497	0.886141	0.885339
Entropy	0.335302	0.345961	0.330902	0.334607
Inverse difference moment	0.991057	0.988649	0.991989	0.991293
Information measure of correlation1	-0.80771	-0.77271	-0.82536	-0.81299
Information measure of correlation2	0.60424	0.594265	0.608826	0.60636
Homogeneity	0.990769	0.988199	0.991753	0.991028
Normalized inverse difference moment	0.99957	0.999422	0.999625	0.99959
Normalized inverse difference	-0.997844	0.997223	0.99808	0.997911
Maximum probability	0.940679	0.940059	0.940864	0.940555
Sum average	2.286614	2.287476	2.286614	2.287476
Sum entropy	0.318089	0.323726	0.315682	0.318085
Sum of squares variances	0.359879	0.3609	0.359879	0.3609
Sum variances	1.409957	1.403764	1.413804	1.415394

Tabel 4.2. Contoh hasil ekstraksi subcitra yang tidak memiliki RNFL menggunakan GLCM

Nama Fitur	0	45	90	135
Autocorrelation	1.604916	1.607587	1.606476	1.60041
Cluster Prominence	40.89495	41.05096	41.05504	39.7633
Cluster Shade	6.87805	6.908487	6.902824	6.75717
Contrast	0.025591	0.023966	0.022469	0.03832
Correlation	0.961815	0.964342	0.966472	0.942984
Difference entropy	0.08174	0.075928	0.0793	0.110931
Difference variance	0.017079	0.015676	0.016102	0.025052
Dissimilarity	0.025299	0.02372	0.02221	0.037692
Energy	0.887981	0.887674	0.888407	0.886662
Entropy	0.341124	0.33884	0.338779	0.357567
Inverse difference moment	0.992265	0.992928	0.992548	0.988746
Information measure of correlation1	-0.81912	-0.82983	-0.82723	-0.76516
Information measure of correlation2	0.614019	0.617719	0.616388	0.59831
Homogeneity	0.992513	0.993146	0.992742	0.989212
Normalized inverse difference moment	0.999631	0.999657	0.999673	0.999445
Normalized inverse difference	0.998187	0.998339	0.998274	0.997351
Maximum probability	0.941991	0.941807	0.942216	0.94135
Sum average	2.265059	2.265857	2.265059	2.265857
Sum entropy	0.324797	0.324207	0.32367	0.331788
Sum of squares variances	0.335088	0.336043	0.335088	0.336043
Sum variances	1.314761	1.320207	1.317882	1.305853

4.4. Seleksi fitur menggunakan Algoritma Evolusi

Algoritma yang digunakan dalam seleksi fitur adalah salah satu dari metode dari banyak metode Algoritma Evolusi yaitu algoritma genetika. Total fitur yang akan di seleksi sebanyak 84 buah fitur yang didapatkan dari proses ekstraksi fitur, Seleksi fitur tersebut menggunakan fitness-function yang telah dijelaskan pada subbab 2.3.5.

Seleksi fitur bertujuan untuk mengurangi waktu komputasi, biaya serta ruang penyimpanan karena semakin besar jumlah fitur yang digunakan akan membutuhkan waktu komputasi yang lebih lama, biaya yang lebih mahal dan ruang penyimpanan yang lebih besar. Proses seleksi fitur dilakukan dengan 5 kali percobaan. Hasil proses seleksi fitur tersebut dapat dilihat pada tabel 4.3.

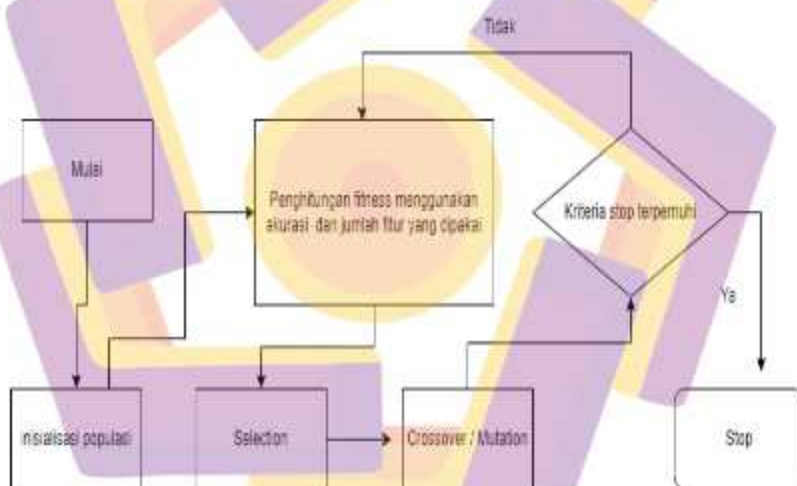
Algoritma Genetika mampu untuk mencari fitur – fitur yang dapat meningkatkan akurasi dengan subset fitur yang lebih sedikit dibandingkan metode evolusi lainnya. Kemampuan tersebut didapat dengan memperbanyak jumlah generasi dan populasi yang digunakan. Gambaran umum Langkah – Langkah seleksi fitur menggunakan algoritma genetika dapat dilihat pada gambar 4.6.

Tabel 4.3. Hasil Seleksi fitur menggunakan Algoritma genetika

No.	Nomor Fitur yang tersisa setelah seleksi							
1	3	47	49	50	59	68	69	77
2	2	79	84					

Tabel 4.3. Lanjutan

No.	Nomor Fitur yang tersisa setelah seleksi						
3	2	30	39	75	82		
4	3	7	11	18	40	43	69
5	10	30	46	60			



Gambar 4.6. Gambaran umum proses seleksi fitur menggunakan Algoritma Genetika

Penentuan jumlah generasi dan iterasi yang besar dapat meningkatkan jumlah probabilitas subset fitur yang menghasilkan nilai optimal dari suatu klasifikasi dengan proses crossover dan mutasi yang dilakukan dengan algoritma genetika.

Namun, penentuan parameter generasi dan iterasi yang besar dapat memperbesar waktu yang diperlukan untuk melakukan proses seleksi fitur sehingga resource dan waktu yang digunakan menjadi lebih besar. Perbandingan hasil seleksi fitur Algoritma genetika dengan algoritma evolusi lainnya (Particle Swarm Optimization dan Artificial Bee Colony) menggunakan jumlah parameter generasi sebanyak 50 dan populasi sebanyak 1000 dapat dilihat pada tabel 4.4.

Tabel 4.4. Fitur – fitur yang terpilih pada proses seleksi fitur menggunakan Algoritma Genetika

No.	Nomor Fitur	Nama fitur	Akurasi
Ke - 1	3	Auto Correlation	90 derajat
	47	Information measure of Correlation	90 derajat
	49	Information measure of correlation 2	0 derajat
	50	Information measure of correlation 2	45 derajat
	59	Inverse Difference Moment	90 derajat
	68	Maximum Probability	135 derajat
	69	Sum Average	0 derajat
	77	Sum of Squares : Variances	0 derajat
Ke - 2	2	Auto Correlation	45 derajat
	79	Sum of Squares : Variances	90 derajat
	84	Sum Variances	135 derajat
Ke - 3	2	Auto Correlation	45 derajat
	30	Difference Variance	45 derajat
	39	Entropy	90 derajat
	75	Sum Entropy	90 derajat
	82	Sum Variances	45 derajat
			96.57%
			97.35%
			96.97%

Tabel 4.4. Lanjutan

No.	Nomor Fitur	Nama fitur	Akurasi	
Ke - 4	3	Auto Correlation	90 derajat	97,16%
	7	Cluster Prominence	90 derajat	
	11	Contrast	90 derajat	
	18	Correlation	45 derajat	
	40	Entrophy	135 derajat	
	43	Homogeneity	90 derajat	
	69	Sum Average	0 derajat	
Ke - 5	10	Contrast	45 derajat	95,84%
	30	Difference Variance	45 derajat	
	46	Information measure of Correlation	45 derajat	
	60	Inverse Difference Moment	135 derajat	

Tabel 4.5. Fitur – fitur yang terpilih pada proses seleksi fitur menggunakan Algoritma PSO

No.	Nomor Fitur	Nama Fitur	Akurasi	
Ke -1	2	Auto Correlation	45 derajat	96,03%
	6	Cluster Prominence	45 derajat	
	7	Cluster Prominence	90 derajat	
	10	Contrast	45 derajat	
	18	Correlation	45 derajat	
	23	Difference Entrophy	90 derajat	
	26	Dissimilarity	45 derajat	
	31	Difference Variance	90 derajat	
	39	Entrophy	90 derajat	
	52	Infromation measure of correlation 2	135 derajat	
	58	Inverse Difference Moment	45 derajat	

Tabel 4.5. Lanjutan

No.	Nomor Fitur	Nama Fitur	Akurasi
	75	Sum Entrophy	90 derajat
	77	Sum of Squares : Variances	0 derajat
	80	Sum of Squares : Variances	135 derajat
	81	Sum Variances	0 derajat
Ke – 2	8	Cluster Prominence	135 derajat
	12	Contrast	135 derajat
	13	Cluster shade	0 derajat
	18	Correlation	45 derajat
	20	Correlation	135 derajat
	23	Difference Entrophy	90 derajat
	40	Entrophy	135 derajat
	47	Information measure of Correlation	90 derajat
	48	Information measure of Correlation	135 derajat
	57	Inverse Difference Moment	0 derajat
	58	Inverse Difference Moment	45 derajat
	66	Maximum Probability	45 derajat
	79	Sum of Squares : Variances	90 derajat
	84	Sum Variances	135 derajat
Ke – 3	8	Cluster Prominence	135 derajat
	9	Contrast	0 derajat
	10	Contrast	45 derajat
	12	Contrast	135 derajat
	13	Cluster shade	0 derajat
	14	Cluster shade	45 derajat
	19	Correlation	90 derajat
	33	Energy	0 derajat
	36	Energy	135 derajat
	38	Entrophy	45 derajat
	43	Homogeneity	90 derajat
			96.02%
			95.45%

Tabel 4.5. Lanjutan

No.	Nomor Fitur	Nama Fitur	Akurasi
	44	Homogeneity	135 derajat
	49	Infomation measure of correlation 2	0 derajat
	50	Infomation measure of correlation 2	45 derajat
	51	Infomation measure of correlation 2	90 derajat
	52	Infomation measure of correlation 2	135 derajat
	53	Inverse Difference	0 derajat
	59	Inverse Difference Moment	90 derajat
	65	Maximum Probability	0 derajat
	66	Maximum Probability	45 derajat
	77	Sum of Squares : Variances	0 derajat
	79	Sum of Squares : Variances	90 derajat
	82	Sum Variances	45 derajat
	7	Cluster Prominence	90 derajat
	8	Cluster Prominence	135 derajat
	10	Contrast	45 derajat
	13	Cluster shade	0 derajat
	20	Correlation	135 derajat
	23	Difference Entrophy	90 derajat
	27	Dissimilarity	90 derajat
	30	Difference Variance	45 derajat
Ke –	39	Entrophy	90 derajat
4	42	Homogeneity	45 derajat
	49	Infomation measure of correlation 2	0 derajat
	53	Inverse Difference	0 derajat
	56	Inverse Difference	135 derajat
	58	Inverse Difference Moment	45 derajat
	64	Inverse Difference Normalized	135 derajat
	65	Maximum Probability	0 derajat
	71	Sum Average	90 derajat
	75	Sum Entrophy	90 derajat
			95.46%

Tabel 4.5. Lanjutan

No.	Nomor Fitur	Nama Fitur	Akurasi
	78	Sum of Squares : Variances	45 derajat
	80	Sum of Squares : Variances	135 derajat
Ke- 5	9	Contrast	0 derajat
	21	Difference Entrophy	0 derajat
	22	Difference Entrophy	45 derajat
	23	Difference Entrophy	90 derajat
	24	Difference Entrophy	135 derajat
	25	Dissimilarity	0 derajat
	32	Difference Variance	135 derajat
	35	Energy	90 derajat
	51	Infromation measure of correlation 2	90 derajat
	54	Inverse Difference	45 derajat
	55	Inverse Difference	90 derajat
	57	Inverse Difference Moment	0 derajat
	59	Inverse Difference Moment	90 derajat
	61	Inverse Difference Normalized	0 derajat
	62	Inverse Difference Normalized	45 derajat
	63	Inverse Difference Normalized	90 derajat
65	Maximum Probability	0 derajat	
66	Maximum Probability	45 derajat	
69	Sum Average	0 derajat	
77	Sum of Squares : Variances	0 derajat	
			95.26%

Tabel 4.6. fitur – fitur yang terpilih pada proses seleksi fitur menggunakan Algoritma ABC

No.	Nomor Fitur	Nama Fitur	Akurasi
Ke -1	1	Auto Correlation	0 derajat
	4	Auto Correlation	135 derajat
	10	Contrast	45 derajat
	25	Dissimilarity	0 derajat
	36	Energy	135 derajat
	37	Entrophy	0 derajat
	41	Homogeneity	0 derajat
	68	Maximum Probability	135 derajat
	72	Sum Average	135 derajat
	78	Sum of Squares : Variances	45 derajat
Ke - 2	14	Cluster shade	45 derajat
	17	Correlation	0 derajat
	18	Correlation	45 derajat
	27	Dissimilarity	90 derajat
	48	Information measure of Correlation	135 derajat
	49	Infromation measure of correlation 2	0 derajat
	58	Inverse Difference Moment	45 derajat
	63	Inverse Difference Normalized	90 derajat
	64	Inverse Difference Normalized	135 derajat
	67	Maximum Probability	90 derajat
	72	Sum Average	135 derajat
	76	Sum Entrophy	135 derajat
	77	Sum of Squares : Variances	0 derajat
83	Sum Variances	90 derajat	
			96.96%
			96.02%

Tabel 4.6. Lanjutan

No.	Nomor Fitur	Nama Fitur	Akurasi
Ke – 3	3	Auto Correlation	90 derajat
	12	Contrast	135 derajat
	15	Cluster shade	90 derajat
	22	Difference Entrophy	45 derajat
	33	Energy	0 derajat
	41	Homogeneity	0 derajat
	51	Infromation measure of correlation 2	90 derajat
	54	Inverse Difference	45 derajat
	55	Inverse Difference	90 derajat
	56	Inverse Difference	135 derajat
	60	Inverse Difference Moment	135 derajat
	61	Inverse Difference Normalized	0 derajat
	82	Sum Variances	45 derajat
84	Sum Variances	135 derajat	
			95.83%
Ke – 4	14	Cluster shade	45 derajat
	16	Cluster shade	135 derajat
	17	Correlation	0 derajat
	18	Correlation	45 derajat
	20	Correlation	135 derajat
	25	Dissimilarity	0 derajat
	26	Dissimilarity	45 derajat
	34	Energy	45 derajat
	35	Energy	90 derajat
	51	Infromation measure of correlation 2	90 derajat
	59	Inverse Difference Moment	90 derajat
	61	Inverse Difference Normalized	0 derajat
	62	Inverse Difference Normalized	45 derajat
			95.83%

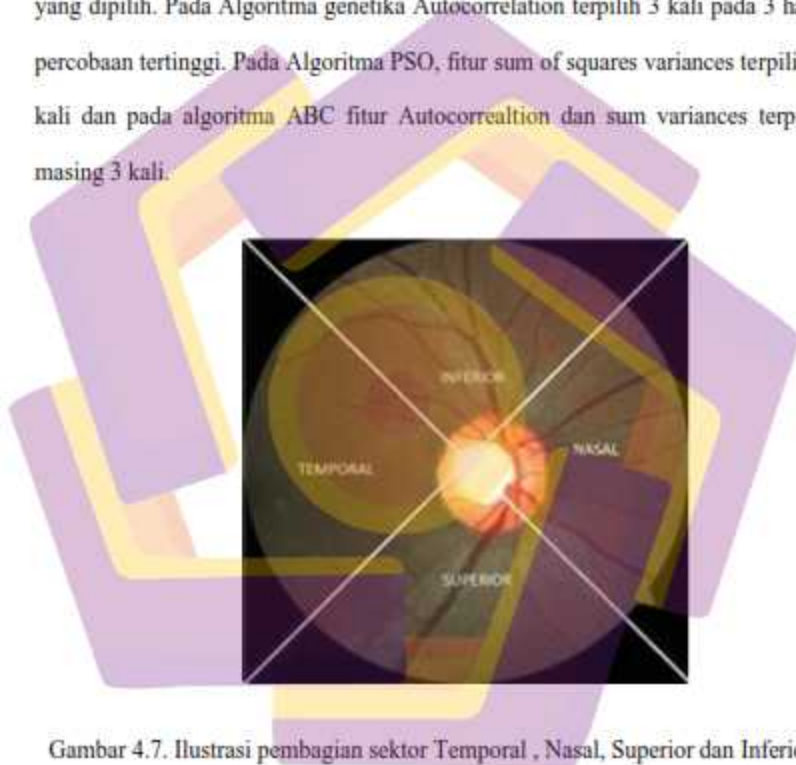
Tabel 4.6. Lanjutan

No.	Nomor Fitur	Nama Fitur	Akurasi
	67	Maximum Probability	90 derajat
	78	Sum of Squares : Variances	45 derajat
	83	Sum Variances	90 derajat
	84	Sum Variances	135 derajat
Ke-5	1	Auto Correlation	0 derajat
	4	Auto Correlation	135 derajat
	19	Correlation	90 derajat
	25	Dissimilarity	0 derajat
	29	Difference Variance	0 derajat
	34	Energy	45 derajat
	39	Entrophy	90 derajat
	57	Inverse Difference Moment	0 derajat
	59	Inverse Difference Moment	90 derajat
	72	Sum Average	135 derajat
	73	Sum Entrophy	0 derajat
	76	Sum Entrophy	135 derajat
	83	Sum Variances	90 derajat
			95.45%

Tabel 4.7. Tabel Perbandingan Hasil Seleksi menggunakan Metode Algoritma Evolusi

Percobaan	Algoritma Genetika		Particle Swarm Optimization		Artificial Bee Colony	
	Hasil Seleksi	Akurasi	Hasil Seleksi	Akurasi	Hasil Seleksi	Akurasi
Ke - 1	3,47,49,50,59 68,69,77	96.57%	2,6,7,10, 18,23,26,31, 39,52,58,75, 77,80,81	96.03%	1,4,10,25, 36,37,41,68, 72,78	96.96%
Ke - 2	2,70,84	97.25%	8,12,13,18, 20,23,40,47, 48,57,58,66, 79,84	96.02%	14,17,18,27, 48,49,58,63, 64,67,72,76, 77,83	96.02%
Ke - 3	2,30,39,75,82	96.97%	8,9,10,12, 13,14,19,33, 36,38,43,44, 49,50,51,52, 53,59,65,66, 77,79,82	95.45%	3,12,15,22, 33,41,51,54, 55,56,60,61, 82,84	95.83%
Ke - 4	3,7,11,18, 40,43,69	97.16%	7,8,10,13, 20,23,27,30, 39,42,49,53, 56,58,64,65, 71,75,78,80	95.46%	14,16,17,18, 20,25,26,34, 35,51,59,61, 62,67,78,83, 84	95.83%
Ke - 5	10,30,46,60	95.84%	9,21,22,23, 24,25,32,35, 51,54,55,57, 59,61,62,63, 65,66,69,77	95.26%	1,4,19,25,29, 34,39,57,59, 72,73,76,83	95.45%
Rata - rata fitur	5 fitur		13 fitur		14 fitur	

Pada tabel 4.1 sampai 4.2 dapat dilihat bahwa ada beberapa fitur yang selalu terpilih dari setiap percobaan yang dilakukan yaitu Autocorrelation, Sum Variance dan Sum of square : Variances. Pada 3 percobaan yang menghasilkan nilai evaluasi tertinggi dari setiap algoritma evaluasi, tiga buah fitur tersebut mendominasi dari setiap fitur yang dipilih. Pada Algoritma genetika Autocorrelation terpilih 3 kali pada 3 hasil percobaan tertinggi. Pada Algoritma PSO, fitur sum of squares variances terpilih 5 kali dan pada algoritma ABC fitur Autocorrealtion dan sum variances terpilih masing 3 kali.



Gambar 4.7. Ilustrasi pembagian sektor Temporal , Nasal, Superior dan Inferior

Komputasi ekstraksi fitur GLCM bekerja berdasarkan intensitas ketetanggaan pixel yang sama. Pada citra fundus bagian superior dan inferior memiliki kecenderungan untuk memiliki RNFL sedangkan pada bagian nasal dan

temporal dan nasal cenderung tidak memiliki RNFL seperti yang dapat dilihat pada gambar 4.7.

Pada subcitra yang berasal dari section nasal dan temporal (Bagian kiri dan kanan dari citar fundus), arah dari sebaran RNFL adalah horizontal atau mendekati horizontal sehingga komputasi GLCM pada sudut 0 derajat (sudut horizontal) memiliki variasi gradasi warna pixel yang rendah seperti yang terlihat pada gambar 4.8 dan 4.9.




Gambar 4.8. Ilustrasi sebaran RNFL pada data sektor nasal




Gambar 4.9. Ilustrasi sebaran RNFL pada data sektor Temporal

Sedangkan pada subcitra yang berasal dari section inferior dan superior (bagian atas dan bawah) arah dari sebaran RNFL adalah vertical atau mendekati vertical sehingga komputasi GLCM pada sudut 45 derajat, 90 derajat dan 135 derajat memiliki variasi gradasi warna yang tinggi seperti yang terlihat pada gambar 4.10 dan gambar 4.11.



Gambar 4.10. Ilustrasi sebaran RNFL pada data sektor Inferior



Gambar 4.11. Ilustrasi sebaran RNFL pada data sektor Superior

Pada subcitra yang termasuk dari bagian nasal dan temporal tetapi memiliki arah yang diagonal, memiliki gradasi warna campuran dimana pada beberapa subcitra tidak memiliki RNFL dan beberapa subcitra memiliki RNFL dengan sebaran 45 derajat dan 135 derajat sehingga komputasi GLCM pada sudut 45 derajat dan 135 derajat memiliki variasi gradasi warna yang tinggi. Ilustrasi sebaran RNFL pada citra sektor nasal dan temporal diagonal dapat dilihat pada gambar 4.12.



Gambar 4.12. Ilustrasi sebaran RNFL pada data nasal dan temporal arah diagonal

Berdasarkan hal tersebut dapat disimpulkan bahwa Komputasi GLCM yang dapat menentukan adanya RNFL pada suatu subsector terdapat pada arah sudut 45 derajat, 90 derajat dan 135 derajat dikarenakan sebaran RNFL dominan terdapat pada sudut – sudut tersebut.

Berdasarkan tabel 4.4, dibandingkan dengan Algoritma evolusi lain, Algoritma genetika mampu mengurangi fitur hingga rata – rata 94 % dari fitur awal sedangkan Particle Swarm Optimization mengurangi 88 % dan Artificial Bee Colony mengurangi 87 % dari fitur awal . Hasil klasifikasi yang dihasilkan dari seleksi fitur Algoritma genetika juga lebih tinggi daripada algoritma PSO dan ABC

Yaitu rata – rata 96,78 % untuk Algoritma genetika dengan berbagai jumlah dan variasi fitur, 95.65% untuk Algoritma PSO dan 96.02% untuk ABC. Berdasarkan hasil percobaan yang telah dilakukan, Algoritma genetika mampu mendapatkan akurasi yang lebih tinggi dengan fitur yang lebih sedikit dibandingkan PSO dan ABC.

Berikut ini adalah pseudocode Algoritma Genetika yang digunakan pada penelitian ini untuk mendapatkan pasangan fitur terbaik.



```

START
  Pembentukan random populasi
  Mendefinisikan fungsi fitness
  Inisialisasi nilai crossover, dan mutasi
  For i=1 to banyaknya generasi
    For j = 1 to n
      Seleksi
      Crossover
      Mutasi
    End for
  Gabung semua kromosom
  Pilih n kromosom terbaik (populasi baru)
  End for
STOP
  
```

Berikut ini adalah pseudocode dari fitness function algoritma genetika yang digunakan pada penelitian ini untuk menentukan nilai fitness dari suatu kromosom atau individu pada perhitungan ini.

```

START
  If sum (subset biner == 1) = 0
    Fitness value = 0
  Else
    Akurasi = svm(subset biner == 1 , label)
    x = (subset biner == 0)
    y = (length(subset biner))
    w1 = 0,8
    w2 = 0,2
    fitness value = w1 * akurasi + w2 * (x / y)
  END

```

Berikut ini adalah contoh Langkah - langkah perhitungan Algoritma Genetika dengan menggunakan asumsi sampel data yang ada pada penelitian ini. Parameter-parameter yang digunakan yaitu:

Nilai Mutasi = 0.01

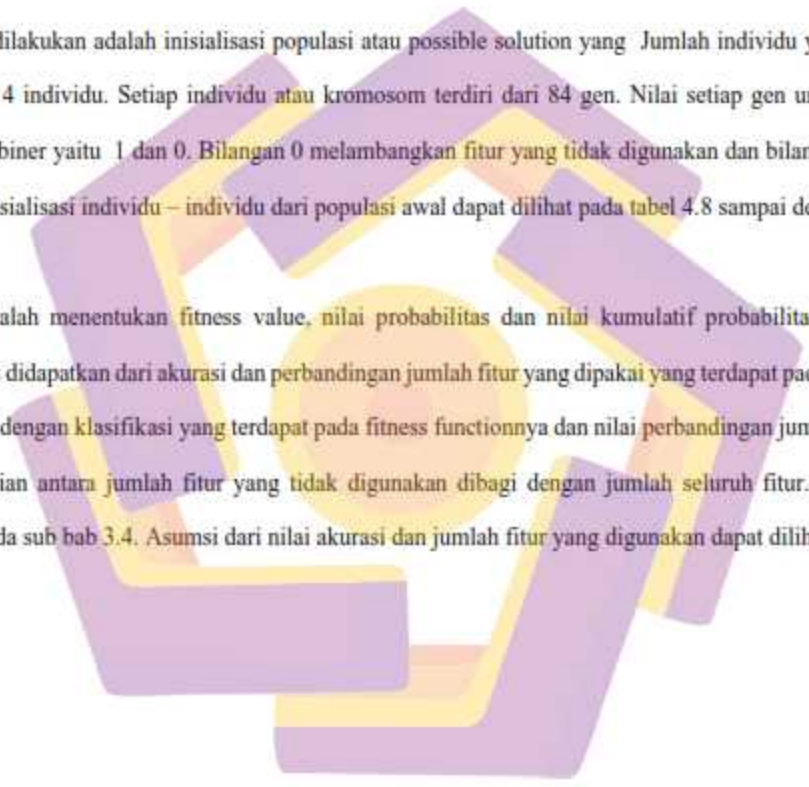
Nilai Crossover = 0.8

Jumlah Populasi Awal = 3

Maksimum Generasi = 1

Seleksi = Roulette Wheels Selections

Nilai mutasi = 0,01

- 
- Langkah Pertama yang dilakukan adalah inisialisasi populasi atau possible solution yang Jumlah individu yang digunakan untuk populasi awal sebanyak 4 individu. Setiap individu atau kromosom terdiri dari 84 gen. Nilai setiap gen untuk populasi awal di inisialkan oleh bilangan biner yaitu 1 dan 0. Bilangan 0 melambangkan fitur yang tidak digunakan dan bilangan 1 melambangkan fitur yang digunakan. Inisialisasi individu – individu dari populasi awal dapat dilihat pada tabel 4.8 sampai dengan tabel 4.10.
 - Langkah selanjutnya adalah menentukan fitness value, nilai probabilitas dan nilai kumulatif probabilitas berdasarkan fitness functionnya. Nilai fitness didapatkan dari akurasi dan perbandingan jumlah fitur yang dipakai yang terdapat pada fitness functionnya. Nilai akurasi didapatkan dengan klasifikasi yang terdapat pada fitness functionnya dan nilai perbandingan jumlah fitur yang dipakai didapatkan dari pembagian antara jumlah fitur yang tidak digunakan dibagi dengan jumlah seluruh fitur. Formula dari fitness function dapat dilihat pada sub bab 3.4. Asumsi dari nilai akurasi dan jumlah fitur yang digunakan dapat dilihat pada tabel 4.11.

Tabel 4.8. Sampel data individu 1

Nomor fitur																											
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28
0	1	1	0	0	1	0	1	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
Nomor fitur																											
29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56
1	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	1	0	0
Nomor fitur																											
57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84
1	1	1	0	0	0	0	1	0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	1	1	0	0

Tabel 4.9. Sampel data individu 2

Nomor fitur																											
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28
1	1	0	0	0	1	1	1	1	1	0	1	0	0	0	1	1	0	0	0	0	0	0	0	0	1	0	0
Nomor fitur																											
29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Nomor fitur																											
57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84
1	0	1	0	0	0	0	1	0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0

Tabel 4.10. Sampel data individu 3

Nomor fitur																											
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28
1	1	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
Nomor fitur																											
29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56
1	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Nomor fitur																											
57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84
1	1	1	0	0	0	0	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1

Tabel 4.11. Nilai akurasi dan jumlah fitur yang digunakan

Individu	Jumlah Fitur yang tidak digunakan	Akurasi
Individu 1	61	92 %
Individu 2	67	90 %
Individu 3	45	91 %

Pada tabel 4.11 diatas, diasumsikan nilai akurasi dari individu 1 sebesar 92 % dan jumlah fitur yang tidak digunakan adalah 61 buah fitur maka nilai fitness dari individu 1 adalah 0,843 karena

$$\text{nilai fitness} = \alpha \cdot 0,92 + \beta \cdot \left(\frac{61}{84}\right)$$

Dimana di penelitian ini nilai bobot α adalah 0,8 dan nilai bobot β adalah 0,2 sehingga

$$\text{nilai fitness} = 0,8 \cdot 0,92 + 0,2 \cdot \left(\frac{61}{84}\right) = 0,881$$

Nilai fitness individu 2 dan 3 juga menggunakan cara yang sama sehingga nilai fitness individu tersebut dapat dilihat pada tabel 4.12.

Tabel 4.12. Nilai fitness pada setiap individu

Individu	Jumlah Fitur	Akurasi	Nilai Fitness
Individu 1	61	92%	0,881
Individu 2	67	90%	0,879
Individu 3	45	91%	0,835

Setelah mendapatkan nilai fitness atau fitness value, dilakukan pencarian nilai probabilitas. Nilai probabilitas ditentukan menggunakan rumus dibawah ini.

$$\text{Nilai probabilitas} = \frac{\text{nilai fitness}}{\sum \text{Nilai fitness}}$$

Sehingga nilai probabilitas dari individu 1 dapat dihitung menjadi

$$\text{Nilai probabilitas} = \frac{0,881}{2,597} = 0,339$$

Nilai probabilitas individu 2 dan 3 juga dihitung menggunakan cara yang sama, dapat dilihat pada tabel 4.13.

Tabel 4.13. Nilai probabilitas dari setiap individu

Individu	Nilai Fitness	Nilai Probabilitas
Individu 1	0,881	0,339
Individu 2	0,879	0,338
Individu 3	0,835	0,321

Setelah didapatkan nilai probabilitas, kemudian mencari nilai kumulatif probabilitas dengan menggunakan rumus dibawah ini

$$\text{Nilai Probabilitas Kumulatif}_i = \sum_{j=1}^i \text{Nilai Probabilitas}_j$$

Sehingga Nilai Probabilitas Kumulatif individu 1 adalah 0,339 dikarenakan individu 1 tidak memiliki individu sebelumnya untuk dijumlahkan, kemudian nilai nilai probabilitas kumulatif individu 2 adalah nilai probabilitas individu 1 + nilai individu probabilitas 2 dan nilai kumulatif individu 3 adalah nilai probabilitas individu 1 + nilai probabilitas individu 2 + nilai probabilitas individu 3. Hasil perhitungan nilai probabilitas kumulatif dapat dilihat pada tabel 4.14.

Tabel 4.14. Nilai probabilitas kumulatif dari setiap individu

Individu	Nilai Fitness	Nilai probabilitas	Nilai probabilitas kumulatif
Individu 1	0,881	0,339	0,339
Individu 2	0,879	0,338	0,677
Individu 3	0,835	0,321	1,00

- Langkah selanjutnya adalah melakukan seleksi. Pada Langkah seleksi digunakan metode roulette wheel selection. Metode roulette wheel selection dipilih karena proses seleksi tersebut menggunakan perhitungan berdasarkan

probabilitas dari suatu fitness value. Berdasarkan metode tersebut, suatu individu yang memiliki nilai fitness yang besar mendapatkan kesempatan untuk terpilih daripada individu yang memiliki nilai fitness yang kecil.

Metode roulette wheel menyeleksi individu dengan cara membangkitkan bilangan acak ($0 - 1$) pada suatu individu kemudian dibandingkan dengan nilai probabilitas individu tersebut. Sebagai contoh, individu 1 memiliki nilai probabilitas kumulatif 0,339 maka, ketika bilangan acak yang muncul $< 0,339$ maka individu 1 akan terpilih dari proses seleksi tersebut. Hasil dari seleksi dapat dilihat pada tabel 4.15.

Tabel 4.15. Hasil proses seleksi berdasarkan bilangan acak dan roulette wheel

Nama Individu	Nilai Kumulatif Probabilitas	Bilangan Acak	Individu yang terpilih
Individu 1	0,339	0,54	Individu 2
Individu 2	0,677	0,32	Individu 1
Individu 3	1,00	0,74	Individu 3

Setelah individu – individu hasil roulette wheel sudah diketahui maka individu lama sebelum seleksi kemudian digantikan dengan individu – individu baru hasil seleksi. Sebagai contoh, jika pada hasil seleksi pertama individu 2 terpilih berdasarkan roulette wheel maka individu 1 digantikan dengan individu 2 dan seterusnya.

- Langkah selanjutnya adalah proses crossover. Parameter nilai crossover yang digunakan pada contoh perhitungan ini adalah 0.8, maka individu yang dapat dijadikan induk dari crossover adalah individu yang memiliki nilai random < 0.8. Hasil penentuan induk crossover individu yang dapat dijadikan induk dapat dilihat pada Tabel 4.16.

Tabel 4.16. Penentuan individu untuk proses crossover

Nama Individu	Bilangan Acak	Individu terpilih
Individu 2	0,7	Individu 2
Individu 1	0,67	Individu 1
Individu 3	0,9	-

Berdasarkan tabel 4.16, individu yang dapat melakukan crossover adalah individu 2 dan individu 1. Setelah didapatkan induk crossover maka dilakukan pemilihan titik crossover. Pada perhitungan ini dilakukan single point crossover yang ditentukan secara acak. Pada perhitungan ini titik yang ditentukan adalah 46. Ilustrasi penentuan titik crossover dapat dilihat pada tabel 4.17 dan hasil dari proses crossover dapat dilihat pada tabel 4.18.

Tabel 4.17. Ilustrasi Penentuan titik crossover

I M B I V I D M 2	Normal Size																												
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	
	1	1	0	0	0	1	1	1	1	1	0	1	0	0	0	1	1	0	0	0	0	0	0	0	0	1	0	0	
	Normal Size																												
	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	
	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
	Normal Size																												
	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84	
	1	0	1	0	0	0	0	1	0	0	0	1	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	0	
	I M B I V I D M 1	Normal Size																											
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28
		0	1	1	0	0	1	0	1	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
Normal Size																													
29		30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	
1		0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	1	0	0
Normal Size																													
57		58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84	
1		1	1	0	0	0	0	1	0	0	0	1	0	0	0	1	0	0	0	0	0	1	0	0	1	1	1	0	0

Tabel 4.18. Hasil dari proses crossover

T h a b l 4 . 1 8 . H a s i l d a r i p r o s e s c r o s s o v e r	Generasi Awal																											
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28
	1	1	0	0	0	1	1	1	1	1	0	0	1	0	0	0	1	0	0	0	0	0	0	0	0	1	0	0
	Generasi Akhir																											
	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56
	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	1	0	0	
	Generasi Awal																											
	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84
	1	1	1	0	0	0	0	1	0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	1	1	0	0
	T h a b l 4 . 1 8 . H a s i l d a r i p r o s e s c r o s s o v e r	Generasi Awal																										
1		2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28
0		1	1	0	0	1	0	1	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
Generasi Akhir																												
29		30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56
1		0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Generasi Awal																												
57		58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84
1		0	1	0	0	0	0	1	0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0

- Seperti yang dapat dilihat pada tabel 4.17. Individu 1 dan individu 2 dipotong menjadi 2 sub individu yaitu bagian dari 1 sampai 45 dan 46 sampai 84. Untuk menghasilkan individu baru maka bagian yang telah dipotong tersebut disatukan sehingga membentuk individu baru seperti yang terlihat pada tabel 4.18.
- Langkah selanjutnya adalah mutasi. Jika bilangan acak yang dibangkitkan saat proses crossover berada dibawah dari nilai mutase yaitu 0,01 maka dilakukan proses mutasi. Ilustrasi pemanggilan bilangan acak pada proses mutasi dapat dilihat pada tabel 4.19.

Tabel 4.19. Penentuan individu untuk proses crossover

Nama Individu	Nilai Acak	Individu terpilih
Individu 1	0,84	
Individu 2	0,32	
Individu 3	0,009	Individu 3

Berdasarkan tabel 4.19, didapatkan individu 3 sebagai individu yang terpilih sebagai individu yang akan menjalani proses mutase. Setelah didapatkan individu untuk proses mutasi, dilakukan pemilihan point untuk diubah nilainya dari 0 menjadi 1 atau sebaliknya. Ilustrasi dari proses mutasi dapat dilihat pada tabel 4.20 dan hasil dari proses mutasi dapt dilihat pada tabel 4.21.

Tabel 4.20. Penentuan titik mutase

Nomor fitur																											
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28
1	1	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
Nomor fitur																											
29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56
1	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Nomor fitur																											
57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84
1	1	1	0	0	0	0	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1

Tabel 4.21. Hasil dari proses mutase

Nomor fitur																											
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28
1	1	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
Nomor fitur																											
29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56
1	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Nomor fitur																											
57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84
1	1	1	0	0	0	0	1	0	1	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1	1	1	1

- Langkah terakhir adalah membuat populasi baru berdasarkan proses crossover dan mutasi. Hasil subset biner pada Individu 1, individu 2 dan individu 3 hasil crossover dan mutasi terdapat pada tabel 4.22 sampai tabel 4.24. Setelah populasi dari individu – individu baru terbentuk, maka selanjutnya dilakukan proses pencarian fitness dari individu baru tersebut. Hasil Pencarian fitness pada populasi baru tersebut dapat dilihat pada tabel 4.25.

Tabel 4.22. data individu 1 setelah proses crossover dan mutase

Individu 1	Nomor fitur																											
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28
	0	1	1	0	0	1	0	1	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
	Nomor fitur																											
	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56
	1	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	Nomor fitur																											
	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84
	1	0	1	0	0	0	0	1	0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0

Tabel 4.23. data individu 2 setelah proses crossover dan mutase

Individu 2	Nomor fitur																												
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	
	1	1	0	0	0	1	1	1	1	1	0	1	0	0	0	1	1	0	0	0	0	0	0	0	0	1	0	0	
	Nomor fitur																												
	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	
	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	1	0	0	
	Nomor fitur																												
	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84	
	1	1	1	0	0	0	0	1	0	0	0	1	0	0	0	1	0	0	0	0	1	0	0	1	1	1	1	0	0

Tabel 4.24. Data individu 3 setelah proses crossover dan mutasi

Individu 3	Nomor fitur																											
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28
	1	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
	Nomor fitur																											
	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56
	1	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	Nomor fitur																											
	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84
	1	1	1	0	0	0	0	1	0	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1	1	1	1	1

Tabel 4.25. Nilai fitness dari individu baru

Individu	Jumlah Fitur	Akurasi	Nilai Fitness
Individu 1	16	92%	0,897
Individu 2	24	92,5%	0,882
Individu 3	38	91%	0,837

Berdasarkan data yang ada pada Tabel 4.25, nilai fitness terbesar ada pada individu 1 dengan nilai fitness terbesar dengan nilai 0,897, meningkat dari nilai fitness awal sebesar 0,881 sehingga subset fitur yang paling baik dari populasi baru tersebut adalah fitur dengan nomor urut ke – 2,3,6,8,10,12,26,29,31,35,57,59,64,68,72,77. Dari total 84 fitur yang digunakan, selama 1 generasi Algoritma Genetika mampu menyeleksi fitur tersebut menjadi 16 fitur. Fitur – fitur tersebut yang kemudian digunakan untuk subset fitur pada klasifikasi.

Algoritma genetika mampu mendapatkan hasil evaluasi maksimum dengan jumlah fitur yang lebih sedikit dikarenakan pada Algoritma genetika terdapat proses crossover dan mutasi. Proses Crossover dan mutasi mengakibatkan perubahan suatu kromosom / calon solusi sebanyak dua kali dimana perubahan itu memungkinkan Algoritma genetika mendapatkan kombinasi subset yang optimal secara lebih cepat.

Subset fitur yang didapatkan dari penggunaan Algoritma genetika juga membuat waktu yang digunakan untuk ekstraksi fitur pada data baru menjadi lebih cepat. Hal ini dikarenakan terjadi penyederhanaan pada algoritma ekstraksi fitur GLCM, dimana fitur yang dihitung berkurang dari 84 buah fitur menjadi 3 buah fitur. Fitur tersebut antara lain Auto Correlation 45 derajat, Sum of Squares : Variances 90 derajat dan Sum Variances 135 derajat.

Proses ekstraksi fitur pada satu buah data baru yang dilakukan tanpa seleksi fitur memakan waktu komputasi sebesar 0.040822 detik dimana proses ekstraksi fitur yang telah melalui penyederhanaan fitur memakan waktu komputasi sebesar 0.004670 detik atau 88 % lebih cepat.



Gambar 4.13. Bagan perbandingan waktu komputasi ekstraksi fitur

4.5 Klasifikasi dan evaluasi

Eksperimen yang akan dilakukan menggunakan algoritma ANN untuk klasifikasinya. Validasi proses klasifikasi menggunakan 10 K-fold cross validation. Pada tahapan klasifikasi juga dilakukan dengan 2 skenario. Skenario pertama dilakukan klasifikasi dengan menggunakan seluruh fitur tanpa dilakukan fitur seleksi terlebih dahulu, sedangkan pada skenario kedua klasifikasi dilakukan dengan menggunakan fitur-fitur hasil seleksi yang diperoleh dari tahapan seleksi fitur. Masing-masing skenario akan dilakukan sebanyak 5 kali percobaan. Hasil percobaan tersebut untuk skenario pertama dapat dilihat pada tabel 4.26.

Tabel 4.26. Hasil percobaan skenario pertama (tanpa seleksi)

No.	Akurasi	Speciflcity	Sensitivity	Jumlah fitur yang digunakan
1	94.52%	94.70%	94.20%	84 fitur
2	94.89%	96.17%	93.02%	84 fitur
3	94.51%	94.70%	94.20%	84 fitur
4	95.46%	95.91%	94.76%	84 fitur
5	94.88%	95.87%	93.43%	84 fitur

Hasil dari eksperimen yang telah dilakukan untuk skenario pertama pada data tanpa seleksi fitur dapat dilihat pada Tabel 4.26. Berdasarkan hasil yang ada pada Tabel 4.26, tingkat akurasi yang didapatkan dengan proses klasifikasi tanpa seleksi fitur memiliki tingkat akurasi tertinggi sebesar 95,46% , untuk specificity sebesar 96,17 % dan Sensitivity sebesar 94,76%. Rata – rata dari 5 buah percobaan tersebut mendapatkan tingkat akurasi rata-rata 94,85% , rata-rata nilai specificity sebesar 95,80% dan rata-rata nilai sensitivity sebesar 93,92%. Kemudian hasil percobaan skenario kedua berdasarkan fitur yang tersisa pada tabel 4.27.

Tabel 4.27. Hasil percobaan skenario kedua (dengan seleksi fitur)

No.	Akurasi	Specificity	Sensitivity	Jumlah fitur yang digunakan
1	96,57%	94,91%	97,76%	8 fitur
2	97,35%	97,60%	97,19%	3 fitur
3	96,97%	96,23%	97,47%	5 fitur
4	97,16%	96,24%	97,78%	7 fitur
5	95,84%	94,39%	96,82%	4 fitur

Tabel 4.28. Hasil percobaan skenario kedua berdasarkan jumlah fitur yang tersisa

No.	Nomor Fitur yang tersisa setelah seleksi	Akurasi	Specificity	Sensitivity
1	3,47,49,50,59,68,69,77	96.57%	94.91%	97.76%
2	2,79,84	97.35%	97.60%	97.19%
3	2,30,39,75,82	96.97%	96.23%	97.47%
4	3,7,11,18,40,43,69	97.16%	96.24%	97.78%
5	10,30,46,60	95.84%	94.39%	96.82%



Gambar 4.14. Bagan perbandingan Hasil Klasifikasi pada berdasarkan jumlah fitur yang tersisa

Berdasarkan hasil yang ada pada Tabel 4.27 dan 4.28, tingkat akurasi yang didapatkan dengan proses klasifikasi menggunakan Algoritma genetika sebagai seleksi fitur memiliki tingkat akurasi tertinggi sebesar 97,35% , untuk specificity sebesar 97,60 % dan Sensitivity sebesar 97,78 % . Rata – rata dari 5 buah percobaan tersebut mendapatkan tingkat akurasi rata-rata 96,78 % , rata-rata nilai specificity sebesar 97,40 % dan rata-rata nilai sensitivity sebesar 95,87 % . Dari hasil percobaan dua buah skenario diatas rata – rata peningkatan akurasi naik 1,93 % , rata – rata specificity naik 1,93% dan rata-rata sensitivity naik 1,95 % .

Seleksi fitur menggunakan algoritma genetika juga mereduksi fitur dari 84 buah fitur menjadi rata – rata fitur yang digunakan dibawah 10 fitur seperti yang dilihat pada tabel 4.25. Fitur yang paling sedikit yang dihasilkan setelah proses seleksi fitur dalam 5 kali percobaan adalah 3 buah fitur dan fitur yang terbanyak adalah 8 buah fitur dengan hasil evaluasi klasifikasi terbaik dihasilkan oleh penggunaan 3 buah fitur.

Penyederhanaan fitur yang dilakukan dengan seleksi fitur algoritma genetika juga mengurangi waktu komputasi pada proses klasifikasi. Hal ini dikarenakan input variable independent pada Artificial neural network berkurang menjadi 3 buah input. Sedangkan jika tidak disederhanakan menggunakan seleksi fitur, input yang digunakan berjumlah 84 buah input. Penyederhanaan tersebut mengurangi jumlah rata – rata waktu komputasi 13.64 detik dimana percobaan yang dilakukan tanpa penyederhanaan memakan waktu sebesar 18.744 detik. Terjadi peningkatan waktu klasifikasi rata – rata klasifikasi sebesar 5.144 detik. Perbandingan

waktu antara percobaan skenario satu (tanpa seleksi fitur) dengan skenario kedua (dengan seleksi fitur) dapat dilihat pada tabel 4.29.

Tabel 4.29. Perbandingan waktu komputasi percobaan skenario satu dan dua.

Percobaan ke -	Waktu komputasi	
	Menggunakan fitur yang telah disederhanakan oleh seleksi fitur	Menggunakan seluruh fitur
1	13.62	17,00
2	9.93	14.67
3	21.51	35.42
4	9.20	12.92
5	8.64	13.71
Rata - rata	13.64	18.744



Gambar 4.15. Bagan perbandingan waktu komputasi klasifikasi dengan seleksi fitur dan tanpa seleksi fitur

hasil yang diperoleh dalam penelitian ini lebih baik jika dibandingkan dengan penelitian sebelumnya (Septiarini et al., 2018). Pada penelitian sebelumnya (Septiarini et al., 2018) tingkat akurasi tertinggi yang dihasilkan sebesar 94,52 %, menggunakan algoritma seleksi fitur cfs. Sedangkan pada penelitian ini nilai akurasi tertinggi yang dihasilkan sebesar 97,35 %. Nilai specificity dan sensitivity yang dihasilkan juga lebih baik yaitu masing – masing sebesar 97,60 % dan 97,19 % dibandingkan dengan penelitian sebelumnya yaitu masing – masing sebesar 89,06 % dan 96,26 %. Hasil perbandingan penelitian yang dilakukan dengan penelitian sebelumnya dapat dilihat pada tabel 4.30.

Tabel 4.30. Perbandingan hasil penelitian dengan penelitian sebelumnya

	Penelitian Sebelumnya	Penelitian saat ini
Jumlah Fitur keseluruhan	40 Fitur	84 Fitur
Algoritma Seleksi fitur	CFS	Genetic Algorithm
Jumlah Fitur tersisa	- Auto Correlation 0° - Correlation 90°	- Auto Correlation 45° - Sum of Squares variances 90° - Sum of Variances 135°
Akurasi	94,52 %	97,35 %
Specificity	89,06 %	97,60 %
Sensitivity	96,26 %	97,19 %

Gambar 4.16. Bagan Perbandingan hasil penelitian dengan penelitian sebelumnya



BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan percobaan dan analisa yang telah dilakukan dapat disimpulkan bahwa:

1. Berdasarkan hasil pengujian pada penelitian ini, Penggunaan algoritma evolusi pada klasifikasi retinal nerve fiber layer sangat baik dalam menyeleksi fitur dan meningkatkan akurasi dari klasifikasi. Terjadi peningkatan akurasi dan specificity sebesar 1,93 % dan Sensitivity sebesar 1,95 % jika menggunakan fitur hasil seleksi algoritma evolusi.
2. Tingkat akurasi terbaik diperoleh oleh algoritma genetika dengan rata – rata fitur yang terpilih adalah 5 buah fitur. Algoritma Genetika mampu untuk mencari fitur – fitur yang dapat meningkatkan akurasi dengan subset fitur yang lebih sedikit dibandingkan metode evolusi lainnya .Kemampuan tersebut didapat dengan memperbanyak jumlah generasi dan populasi yang digunakan. Algoritma genetika juga memiliki proses crossover dan mutasi yang memungkinkan penemuan subset fitur yang memiliki nilai yang optimal menjadi lebih cepat dan efisien.
3. Subset fitur hasil dari seleksi menggunakan algoritma genetika yang memiliki karakteristik terbaik adalah urutan fitur ke 2, 79 dan 84. Urutan fitur tersebut yaitu Autocorrelation 45°, Sum of Squares: Variances 90° dan Sum Variances 135°. Sudut 45, 90 dan 135 derajat tidak terseleksi pada


proses seleksi fitur dikarenakan sebaran – sebaran RNFL pada subcitra dominan terjadi pada sudut – sudut tersebut. Penggunaan seleksi fitur juga dapat mempersingkat waktu komputasi yang di gunakan pada proses ekstraksi fitur dan proses klasifikasi. Waktu komputasi yang digunakan pada proses ekstraksi fitur yang menggunakan fitur hasil dari proses seleksi fitur mengalami peningkatan sebesar 1 menit 50 detik lebih cepat dibandingkan dengan proses esktraksi fitur yang menggunakan seluruh fitur. Proses Klasifikasi ANN yang mengalami penyederhanaan juga mengalami peningkatan kecepatan komputasi yaitu sebesar rata – rata 5 .104 detik dibandingkan klasifikasi yang meggunakan seluruh fitur.

4. Penelitian ini jauh lebih baik dari penelitian sebelumnya (Septiarini et al., 2018), karena pada penelitian ini tingkat akurasi, specificity dan sensitivity mengalami peningkatan dibandingkan tingkat akurasi specificity dan sensitivity pada penelitian sebelumnya. Penelitian ini juga menggunakan hasil ekstraksi fitur GLCM yang lebih banyak. Jika sebelumnya menggunakan 40 buah fitur, maka pada penelitian ini menggunakan 84 buah fitur, sehingga proses yang dihasilkan jauh lebih kompleks. Walaupun fitur yang dihasilkan setelah seleksi fitur pada penelitian ini lebih banyak yaitu 3 buah fitur dibandingkan dengan hasil seleksi fitur penelitian sebelumnya yang berjumlah 2 buah fitur.

5.2. Saran

Pada penelitian yang akan datang bisa meneliti perbandingan antara metode feature selection menggunakan feature selection (filter dan wrapper) dengan

metode seleksi fitur berbasis embedded menggunakan weight penalty atau weight regularization yang terdapat pada Artificial Neural Network.



DAFTAR PUSTAKA

- Abd Alkreem, M. H., & Karim, A. A. (2021). Feature Selection Using Artificial Bee Colony for Fruit Classification. *Journal of Physics: Conference Series*, 1818(1). <https://doi.org/10.1088/1742-6596/1818/1/012062>
- Ajesh, F., Ravi, R., & Rajakumar, G. (2021). Early diagnosis of glaucoma using multi-feature analysis and DBN based classification. *Journal of Ambient Intelligence and Humanized Computing*, 12(3), 4027–4036. <https://doi.org/10.1007/s12652-020-01771-z>
- Anita, S., & Albarda. (2020). Classification Cherry's Coffee using k-Nearest Neighbor (KNN) and Artificial Neural Network (ANN). *2020 International Conference on Information Technology Systems and Innovation, ICITSI 2020 - Proceedings*, 117–122. <https://doi.org/10.1109/ICITSI50517.2020.9264927>
- Barani, F., & Mina Mirhosseini. (2018). Classification of binary problems with SVM and a Mixed Artificial Bee Colony Algorithm. *3rd Conference on Swarm Intelligence and Evolutionary Computation*.
- Chakrabarty, L., Joshi, G. D., Chakravarty, A., Raman, G. V., Krishnadas, S. R., & Sivaswamy, J. (2016). Automated Detection of Glaucoma from Topographic Features of the Optic Nerve Head in Color Fundus Photographs. *Journal of Glaucoma*, 25(7), 590–597. <https://doi.org/10.1097/IJG.0000000000000354>
- Chen, R. C., Dewi, C., Huang, S. W., & Caraka, R. E. (2020). Selecting critical features for data classification based on machine learning methods. *Journal of Big Data*, 7(1). <https://doi.org/10.1186/s40537-020-00327-4>

- Clausi, D. A. (2002). *An analysis of co-occurrence texture statistics as a function of grey level quantization.*
- Dave, V. (2019). *COMPARATIVE ANALYSIS OF REGULARIZATION TECHNIQUES IN ARTIFICIAL NEURAL NETWORKS.*
<https://doi.org/10.1729/Journal.22756>
- Eleya, alaa. (2019). *Particle Swarm Optimization Based Feature Selection for Face Recognition.* International Conference on Digital Information Processing and Communications (ICDIPC).
- Firdaus, F. F., Nugroho, H. A., & Soesanti, I. (2020). A Review of Feature Selection and Classification Approaches for Heart Disease Prediction. In *IJITEE* (Vol. 4, Issue 3).
- Gómez-Valverde, J. J., Antón, A., Fatti, G., Liefers, B., Herranz, A., Santos, A., Sánchez, C. I., & Ledesma-Carbayo, M. J. (2019). Automatic glaucoma classification using color fundus images based on convolutional neural networks and transfer learning. *Biomedical Optics Express*, 10(2), 892.
<https://doi.org/10.1364/boe.10.000892>
- Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6), 610–621.
- Jong-Bae Park, & Kwang Y. Lee. (2006). *Application of Particle Swarm Optimization to Economic Dispatch Problem.*

- Keles, M. K., & Kılıç, Ü. (2018). Artificial Bee Colony Algorithm for Feature Selection on SCADI Dataset. *2018 3rd International Conference on Computer Science and Engineering (UBMK)*, 463–466.
- Khan, A. H., Sarkar, S. S., Mali, K., & Sarkar, R. (2022). A Genetic Algorithm Based Feature Selection Approach for Microstructural Image Classification. *Experimental Techniques*, *46*(2), 335–347. <https://doi.org/10.1007/s40799-021-00470-4>
- Kumar, G., & Bhatia, P. K. (2014). A detailed review of feature extraction in image processing systems. *International Conference on Advanced Computing and Communication Technologies, ACCT*, 5–12. <https://doi.org/10.1109/ACCT.2014.74>
- Muramatsu, C., Hayashi, Y., Sawada, A., Hatanaka, Y., Hara, T., Yamamoto, T., & Fujita, H. (2010). Detection of retinal nerve fiber layer defects on retinal fundus images for early diagnosis of glaucoma. *Journal of Biomedical Optics*, *15*(1), 016021. <https://doi.org/10.1117/1.3322388>
- Nakisa, B., Rastgoo, M. N., Tjondronegoro, D., & Chandran, V. (2018). Evolutionary computation algorithms for feature selection of EEG-based emotion recognition using mobile sensors. In *Expert Systems with Applications* (Vol. 93, pp. 143–155). Elsevier Ltd. <https://doi.org/10.1016/j.eswa.2017.09.062>
- Odstreilik, J., Kolar, R., Jan, J., Jan, J., Gazarek, J., Kuna, Z., & Vodakova, M. (2012). *Analysis of retinal nerve fiber layer via Markov random fields in color fundus images*. <http://www5.informatik.uni-erlangen.de/research/software/o>

- Odstreilík, J., Kolar, R., Tornow, R. P., Budai, A., Jan, J., Mackova, P., & Vodakova, M. (2015). Analysis of the retinal nerve fiber layer texture related to the thickness measured by optical coherence tomography. *Lecture Notes in Computational Vision and Biomechanics*, 19, 19–40. https://doi.org/10.1007/978-3-319-13407-9_2
- Odstreilík, J., Kolar, R., Tornow, R. P., Jan, J., Budai, A., Mayer, M., Vodakova, M., Laemmer, R., Lamos, M., Kuna, Z., Gazarek, J., Kubena, T., Cernosek, P., & Ronzhina, M. (2014). Thickness related textural properties of retinal nerve fiber layer in color fundus images. *Computerized Medical Imaging and Graphics*, 38(6), 508–516. <https://doi.org/10.1016/j.compmedimag.2014.05.005>
- Öztürk, Ş., & Akdemir, B. (2018). Application of Feature Extraction and Classification Methods for Histopathological Image using GLCM, LBP, LBGLCM, GLRLM and SFTA. *Procedia Computer Science*, 132, 40–46. <https://doi.org/10.1016/j.procs.2018.05.057>
- Parashar, D., & Agrawal, D. K. (2020). Automated classification of glaucoma stages using flexible analytic wavelet transform from retinal fundus images. *IEEE Sensors Journal*, 20(21), 12885–12894. <https://doi.org/10.1109/JSEN.2020.3001972>
- Pradnya A.Vikhar. (2016). *Evolutionary Algorithms: A Critical Review and its Future Prospects*. International Conference on Global Trends in Signal Processing, Information Computing and Communication.

- Prageeth, P. G., J. David., & A. S. Kumar. (2011). Early Detection of Retinal Nerve Fiber Layer Defects using Fundus Image Processing. *Recent Advances in Intelligent Computational Systems*.
- Prayogo, A., Gede, L., & Astawa, S. (2021). Analysis of the Effect of Feature Reduction on Accuracy and Computational Time in Mushroom Dataset Classification. *Jurnal Elektronik Ilmu Komputer Udayana*, 10.
- Pudjihartono, N., Fadason, T., Kempa-Liehr, A. W., & O'Sullivan, J. M. (2022). A Review of Feature Selection Methods for Machine Learning-Based Disease Risk Prediction. *Frontiers in Bioinformatics*, 2. <https://doi.org/10.3389/fbinf.2022.927312>
- Rathna Sekhar, P., & Sujatha, B. (2020). *A Literature Review on Feature Selection using Evolutionary Algorithms*. 2020 7th International Conference on Smart Structures and Systems (ICSSS). <https://doi.org/10.1109/ICSSS49621.2020.9202257>.
- Rohani, A., Taki, M., & Abdollahpour, M. (2018). A novel soft computing model (Gaussian process regression with K-fold cross validation) for daily and monthly solar radiation forecasting (Part: I). *Renewable Energy*, 115, 411–422. <https://doi.org/10.1016/j.renene.2017.08.061>
- Saeyns, Y., Inza, I., & Larrañaga, P. (2007). A review of feature selection techniques in bioinformatics. In *Bioinformatics* (Vol. 23, Issue 19, pp. 2507–2517). Oxford University Press. <https://doi.org/10.1093/bioinformatics/btm344>

- Sahu, B., & Mishra, D. (2012). A novel feature selection algorithm using particle swarm optimization for cancer microarray data. *Procedia Engineering*, 38, 27–31. <https://doi.org/10.1016/j.proeng.2012.06.005>
- Septiarini, A., Harjoko, A., Pulungan, R., & Ekantini, R. (2017). Optic disc and cup segmentation by automatic thresholding with morphological operation for glaucoma evaluation. *Signal, Image and Video Processing*, 11(5), 945–952. <https://doi.org/10.1007/s11760-016-1043-x>
- Septiarini, A., Harjoko, A., Pulungan, R., & Ekantini, R. (2018). Automated detection of retinal nerve fiber layer by texture-based analysis for glaucoma evaluation. *Healthcare Informatics Research*, 24(4), 335–345. <https://doi.org/10.4258/hir.2018.24.4.335>
- Soh, L.-K., & Tsatsoulis, C. (1999). Texture Analysis of SAR Sea Ice Imagery Using Gray Level Co-Occurrence Matrices. In *IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING* (Vol. 37, Issue 2).
- Tan, P., Wang, X., & Wang, Y. (2020). Dimensionality reduction in evolutionary algorithms-based feature selection for motor imagery brain-computer interface. *Swarm and Evolutionary Computation*, 52. <https://doi.org/10.1016/j.swevo.2019.100597>
- Wyawahare, M. V., & Patil, P. M. (2015). Feature selection and classification for automatic detection of retinal nerve fibre layer thinning in retinal fundus images. In *Int. J. Biomedical Engineering and Technology* (Vol. 19, Issue 3).
- Yazdani, D., & Meybodi, M. R. (2014). *A Novel Artificial Bee Colony Algorithm for Global Optimization*.

Zhuo, L., Zheng, J., Wang, F., Li, X., Ai, B., & Qian, J. (2008). *A GENETIC ALGORITHM BASED WRAPPER FEATURE SELECTION METHOD FOR CLASSIFICATION OF HYPERSPECTRAL IMAGES USING SUPPORT VECTOR MACHINE.*

