

IMPLEMENTASI METODE SELEKSI FITUR MENGGUNAKAN *ARTIFICIAL BEE COLONY* PADA KLASIFIKASI RETINAL NERVE FIBER LAYER

Aam Shodiqu Munir^{1*}, Andi Sunyoto², Hanif Al fatta³.

^{1,2,3} Universitas Amikom Yogyakarta

e-mail: aamshodiqumunir@gmail.com*

Abstrak: Damage to Retinal Nerve Fiber Layer can Cause Glaucoma. Glaucoma is an inflammation of the optic eye which is characterized by progressive deterioration of Optic Nerve Head and field of view. Problems that require a classification solution are hindered by the large data dimensions. Artificial Bee Colony is one of the evolution algorithms widely used for feature selection and optimization. Gray level Coocurrence matrix is used as a feature extraction method, the Artificial bee colony method is used as a feature selection and Support Vector Machine used as Classification. The proposed method using Artificial Bee Colony gets improved Accuracy compared to method without using Artificial Bee Colony. The results obtained by the proposed method were 95% for accuracy, 95.9% for specificity and 93.7% for sensitivity where methods that did not use Artificial Bee Colony obtained an accuracy of 93.8%, Specificity sebesar 90.3% and Sensitivity of 92.6%.

Keyword : RNFL, GLCM, Artificial Bee Colony, Feature Selction, Classification

Abstract: Kerusakan pada RNFL dapat menyebabkan penyakit Glaukoma. Glaukoma adalah peradangan pada optik mata yang ditandai dengan kemunduran progresif dari ONH dan luas pandangan mata. Permasalahan yang membutuhkan solusi dari klasifikasi terhalang oleh dimensi data yang begitu besar. Algoritma Bee Colony adalah salah satu algoritma evolusi yang banyak digunakan untuk seleksi fitur dan optimasi. Metode Gray level Coocurrence matrix digunakan sebagai metode ekstraksi fitur, Metode Artificial bee colony digunakan sebagai seleksi fitur dan pengklasifikasian menggunakan metode Supprot Vector Machine. Metode yang diusulkan memiliki peningkatan akurasi, specificity dan Sensitivity dibandingkan dengan tidak menggunakan seleksi fitur. Hasil yang didapatkan oleh metode yang diusulkan sebesar 95 % untuk akurasi, 95,9% untuk specificity dan 93,7 % untuk sensitivity dimana metode yang tidak menggunakan Artificial Bee Colony mendapatkan akurasi sebesar 93,8 %, Specificity sebesar 90,3 % dan Sensitivity sebesar 92,6 %.

Kata Kunci : RNFL, GLCM, Artificial Bee Colony, Fitur Seleksi, Klasifikasi

Copyright (c) 2023 The Authors. This is an open access article under the CC BY-SA 4.0 license (<https://creativecommons.org/licenses/by-sa/4.0/>)

PENDAHULUAN

Retina Nerve Fiber Layer (RNFL) adalah bagian dari retina yang terletak di luar Optic Nerve Head (ONH), yang dapat diamati pada citra fundus retina. 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). Perbedaan retina pada mata normal dan

pada mata yg memiliki penyakit glaucoma terletak pada tekstur RNFL. Struktur mata normal akan terdapat banyak tekstur seperti goresan-goresan di sekeliling Optic Nerve Head sedangkan pada mata penderita glaukoma tekstur tersebut cenderung tipis.

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.

Pada penelitian yang dilakukan sebelumnya (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). Penelitian tersebut juga menggunakan metode Correlation based Feature Selection (CFS) sebagai metode seleksi fitur.

Seleksi fitur adalah suatu teknik preprocessing data yang banyak digunakan dalam data mining. Pada dasarnya seleksi fitur digunakan untuk mereduksi data dengan menghilangkan atribut yang signifikan dan berlebihan dari kumpulan data. Selain itu, teknik ini meningkatkan pemahaman pola dari data, memperbaiki visualisasi data agar menjadi lebih baik, mengurangi waktu training dari machine learning dan meningkatkan kinerja suatu sistem prediksi (Jain & Singh, 2018).

Pada Penelitian yang dilakukan oleh (Singh & Malik, 2022) menggunakan dua buah metode seleksi fitur yaitu Relief dan Neighborhood Component Analysis (NCA) dan metode klasifikasi Support Vector Machine pada klasifikasi buah jeruk kino/Kinnow. Metode seleksi fitur tersebut mengurangi 54% fitur dan meningkatkan hasil akurasi dari 90,84% menjadi 94,67 %.

Algoritma evolusi adalah suatu komputasi atau algoritma yang menggunakan mekanisme yang terinspirasi oleh alam dan pemecahan 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 (Sekhar & Sujatha, 2020).

Pada penelitian yang dilakukan oleh (Aly et al., 2019) menggunakan beberapa metode optimisasi sebagai metode seleksi fitur antara lain Particle Swarm, Ant Colony dan Bee Colony pada kasus prediksi dan diagnosis tumor otak. Hasilnya, metode-metode tersebut menghasilkan akurasi mulai dari 88,9% sampai dengan 98,8 %.

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

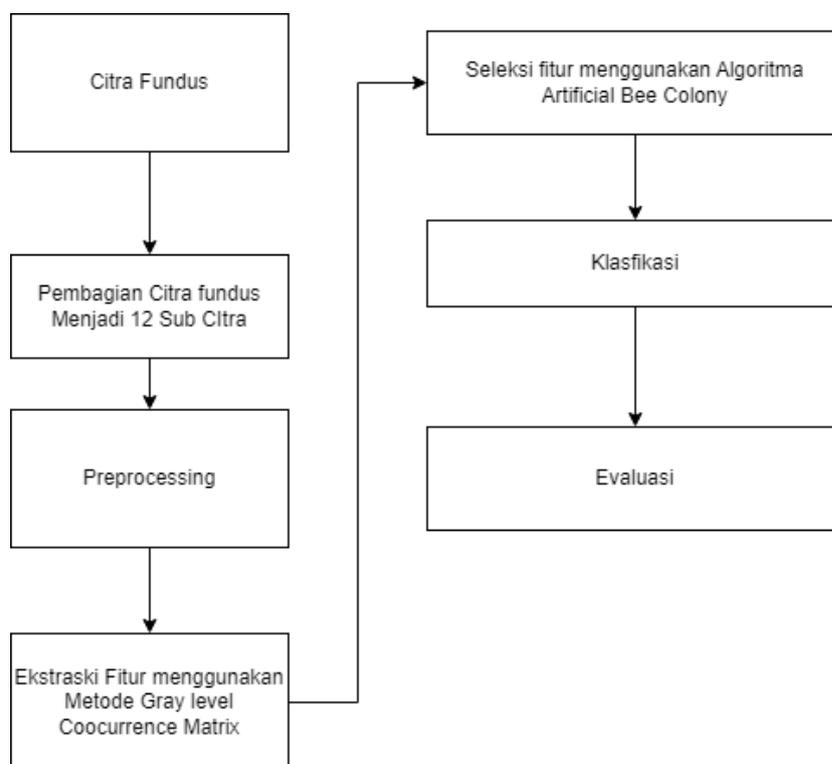
Penelitian (Kaya Keles & Kilic, 2018) menggunakan pendekatan seleksi fitur menggunakan Algoritma Bee Colony pada dataset SCADI (Self Care Daily Activities). Pada dataset SCADI yang tidak mengalami seleksi fitur mendapatkan akurasi dan F-Score masing – masing 84,2 % dan 0,812. Pada dataset yang mengalami seleksi fitur dengan metode Information Gain, Gain Ratio dan Chi-Squared tidak mengalami peningkatan akurasi dan F-score meningkat menjadi 0,822. Pada dataset yang menggunakan metode Artificial bee colony mendapatkan peningkatan akurasi menjadi 88,5 % dan F-Score sebesar 0,871.

Pada penelitian sebelumnya yang dilakukan oleh (Septiarini et al., 2018) hanya menggunakan CFS sebagai metode seleksi fitur dan menggunakan 10 buah fitur yang didapat dari ekstraksi fitur Gray level Coocurrence Matrix. Berdasarkan hal tersebut, pada penelitian ini akan menggunakan Artificial Bee Colony sebagai metode Seleksi Fitur dan menggunakan 21 buah fitur dari metode GLCM untuk mengklasifikasikan Retinal Nerve Fiber Layer.

METODE

Pada penelitian ini dilakukan proses klasifikasi Retinal Nerve Fiber Layer menggunakan Gray Level Coocurrence Matriks sebagai metode ekstraksi fitur dan Algoritma Artificial Bee Colony sebagai Metode Seleksi fitur. Data yang akan digunakan

dalam penelitian ini adalah data yang digunakan pada penelitian (Septiarini et al., 2018). Jumlah data citra fundus yang digunakan dalam penelitian ini yaitu 44 buah data. Setiap Data citra tersebut kemudian dibagi menjadi 12 buah subcitra berdasarkan pembagian penilaian citra OCT sehingga jumlah data yang digunakan berjumlah 528 subcitra. Beberapa tahapan utama yang akan dilakukan pada penelitian ini antara lain Pembagian citra menjadi sub citra, Esktraksi fitur, Seleksi fitur, Klasifikasi dan Evaluasi Metodologi yang diusulkan untuk digunakan pada penelitian ini dapat dilihat pada gambar 1 dan setiap tahapan – tahapan pada metode yang diusulkan akan dijelaskan pada setiap subbagian bab.



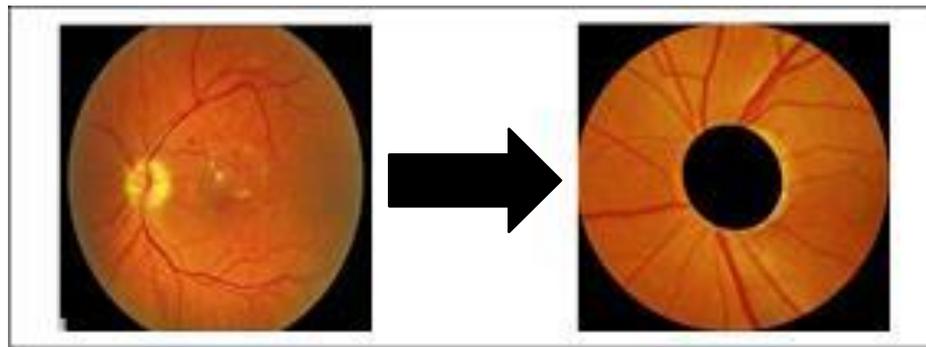
Gambar 1. Alur Proses Penelitian

Penyusunan Dataset

Dataset yang digunakan dalam penelitian ini adalah dataset yang digunakan pada penelitian yang dilakukan oleh (Septiarini et al., 2018) yang berjumlah 44 buah.. Akurasi dari semua citra fundus diverifikasi oleh seorang dokter mata. Setiap label dari citra fundus tersebut ditentukan dengan menganalisa 12 subsektor yang berbeda. Subsektor tersebut berdasarkan citra Optical Coherence Tomography dengan referensi searah jarum jam

Pembagian citra menjadi subcitra

Pada tahapan pembagian citra menjadi subcitra, dilakukan segmentasi Optic nerve head (ONH) pada citra fundus menggunakan metode segmentasi yang diterapkan pada penelitian pada penelitian (Septiarini et al., 2017) Ilustrasi segmentasi ONH dapat dilihat pada gambar 2.



Gambar 2. Ilustrasi segmentasi ONH

Setelah dilakukan segmentasi ONH, citra tersebut kemudian akan dilakukan pembagian menjadi 12 sub citra. Pembagian tersebut didasari dari citra OCT berdasarkan angka jam.

Preprocessing

Tahapan preprocessing dilakukan dengan cara mengubah citra berwarna menjadi citra grayscale. Hal ini dilakukan karena metode ekstraksi fitur tekstur GLCM mengharuskan citra yang diolah adalah citra grayscale atau citra yang memiliki 1 layer warna.

Ekstraksi fitur GLCM

Setelah semua subcitra mengalami proses preprocessing, maka dilakukan tahap ekstraksi fitur GLCM. Gray Level Co-occurrence Matrix (GLCM) adalah teknik untuk memperoleh tekstur citra dengan menggunakan perhitungan pada orde kedua (Öztürk & Akdemir, 2018). 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 (Zulpe & Pawar, 2012). Fitur GLCM yang akan digunakan berjumlah 21 fitur dan 4 buah sudut yaitu 0, 45, 90 dan 135 derajat. Fitur – fitur yang digunakan antara lain (Clausi, 2002; Haralick et al., 1993; Soh & Tsatsoulis, 1999) : Contrast, Correlation, Difference entropy, Difference variance, Energy, Inverse Difference Moment, Information measure of

correlation 1, Informaiton measure of correlation 2, Sum average, Sum entropy, Sum of squares: Variance, Sum variance, Autocorrelation, Cluster Prominence, Cluster Shade, Dissimilarity, Entropy, Maximum probability, Homogeneity, Inverse Difference Moment Normalized dan Inverse Difference Normalized.

Seleksi fitur

Pada tahapan ini digunakan seleksi fitur menggunakan Algoritma Artificial Bee Colony. Metode Aritificial Bee Colony (ABC) adalah suatu algoritma optimasi metaheuristic yang terinspirasi dari perilaku cerdas koloni lebah madu. Metode ini sering dipakai untuk menemukan solusi optimal dari perilaku lebah madu dalam mencari dan mengeksplorasi makanan. Metode ini terdiri dari tiga macam lebah madu yaitu Employed bees (Lebah Pekerja), Onlooker bees (Lebah Penjaga) , dan Scout bees (Lebah Pemandu) (Keles & Kılıç, 2018) .

Pada algoritma artificial bee colony, lebah penjaga memilih submer makanan berdasarkan nilai probabilitas yang terdapat pada sumber makanan tersebut. Persamaan Langkah tersebut dapat dilihat pada persamaan 3.1 berikut.

$$P_i = \frac{fit_j}{\sum_{n=1}^{SN} fit_n} \dots\dots\dots(1)$$

Dimana SN adalah jumlah sumber makanan yang sama dengan jumlah lebah pekerja dan fit_i adalah nilai fitness yang digunakan. Untuk menentukan posisi dari sumber makanan yang telah tersimpan digunakan persamaan 3.2 berikut.

$$v_{ij} = z_{ij} + \varphi_{ij}(z_{ij} - z_{kj}) \dots\dots\dots(2)$$

Pada sumber makanan yang isinya telah habis kemudian diganti dengan sumber makanan baru oleh lebah pemandu. Langkah tersebut disimulasikan dengan memproduksi posisi secara random kemudian mengganti posisi yang telah ditinggalkan dengan posisi random tersebut. Pada algoritma artificial bee colony, Ketika suatu posisi sumber makanan tidak dapat ditingkatkan setelah melalui beberapa perputaran atau *cycle* , maka posisi tersebut dapat dinyatakan sebagai posisi yang ditinggalkan. Jumlah cycle tersebut adalah parameter yang sangat penting pada algoritma Artificial bee colony.

Lebah Pemandu kemudian mencari suatu sumber baru untuk digunakan. Persamaan yang digunakan dapat dilihat pada persamaan 3.3 berikut :

$$z_j^i = z_{min}^j + rand(0,1)(z_{max}^j - z_{min}^j) \dots\dots\dots(3)$$

. Setelah setiap kandidat sumber posisi makanan v_{ij} diproduksi dan kemudian dievaluasi, kinerja dari posisi tersebut dibandingkan dengan posisi yang lama. Jika sumber makanan baru memiliki nektar yang sama atau lebih baik dari sumber yang lama, maka dilakukan penggantian sumber makanan. Jika tidak, sumber yang lama tetap disimpan. Dengan kata lain, mekanisme seleksi greedy digunakan sebagai operasi seleksi antara sumber makanan yang lama dan sumber makanan yang baru. (Karaboga & Ozturk, 2011)

Klasifikasi

Pada tahapan Klasifikasi, data yang telah mengalami proses seleksi fitur kemudian diklasifikasi menggunakan metode Support Vector Machine. Support Vector Machine adalah suatu metode yang dapat memprediksi untuk kasus klasifikasi maupun kasus regresi. Support Vector Machine memiliki prinsip linier dimana data dipisahkan secara linier. Metode ini pun dapat diformulasikan untuk data yang tidak bersifat linear dengan menggunakan fungsi – fungsi kernel dan parameter (Monika Parapat & Tanzil Furqon, 2018).

Evaluasi

Dalam tahap pengujian , tolak ukur untuk menilai klasifikasi sebagai klasifikasi yang baik menggunakan akurasi, specificity dan sensitifity. 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 Sensitifity adalah kemampuan sistem klasifikasi untuk mengetahui citra fundus yang tidak memiliki RNFL. Persamaan nilai Akurasi, Specificity dan sensitifity terdapat pada persamaan 3.1 sampai 3.3.

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots(4)$$

$$Specificity = \frac{TN}{TN+FP} \dots\dots\dots(5)$$

$$Sensitifity = \frac{TP}{TP+FN} \dots\dots\dots(6)$$

Dimana :

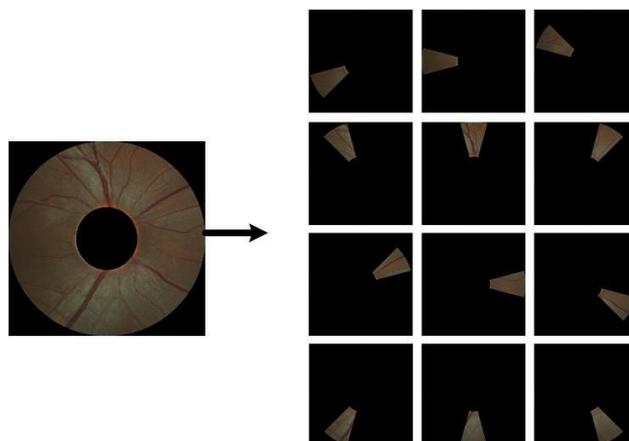
- TP = True Positive
- TN = True Negative
- FP = False Positive
- FN = False Negative

HASIL DAN PEMBAHASAN

Pada penelitian ini digunakan data berjumlah 44 buah data yang juga digunakan pada penelitian sebelumnya (Septiarini et al., 2017), data tersebut kemudian dibagi menjadi 12 buah subcitra dikarenakan pelabelan ada atau tidaknya RNFL berdasarkan subcitra.

Pembagian citra menjadi subcitra

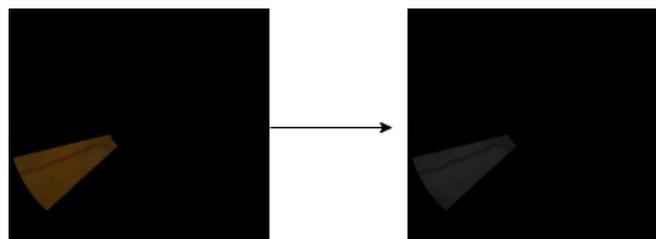
Pada proses pembagian citra menjadi subcitra, Citra OCT digunakan sebagai rujukan. Pembagian dilakukan disetiap 30 derajat perputaran, sehingga setiap data fundus yang digunakan dalam penelitian memiliki 12 subcitra sehingga dari 44 data citra fundus akan didapatkan data sebesar 528 buah data subcitra. Subcitra tersebut yang kemudian akan diekstraksi dan di klasifikasi. Ilustrasi pembagian citra menjadi subcitra dapat dilihat pada gambar 4.



Gambar 3. Ilustrasi pembagian citra menjadi subcitra

Preprocessing

Setelah dilakukan pembagian subcitra, masing-masing subcitra mengalami proses preprocessing. Proses preprocessing dilakukan karena metode GLCM menggunakan citra yang memiliki ruang warna grayscale. Ilustrasi dari proses preprocessing dapat dilihat pada gambar 5.



Gambar 4. Ilustrasi tahapan preprocessing

Ekstraksi Fitur GLCM

Setelah semua data subcitra mengalami proses preprocessing maka dilakukan proses selanjutnya yaitu proses ekstraksi ciri tekstur. Proses ekstraksi ciri tekstur menggunakan metode Gray matrix co occurrence (GLCM) menggunakan 21 fitur dan 4 arah maka total fitur yang akan digunakan berjumlah 84 buah.

Seleksi Fitur Menggunakan Algoritma Artificial Bee Colony.

Setelah dilakukan proses ekstraksi fitur, fitur – fitur tersebut kemudian akan di seleksi menggunakan algoritma Artificial Bee Colony menggunakan parameter yaitu solusi yang memungkinkan berjumlah , 20 jumlah iterasi dan limit yang digunakan adalah 10 . Dari 84 buah fitur tersebut tersisa 32 fitur. Jumlah Solusi yang digunakan berjumlah 100 dan jumlah iterasi sebanyak 20 iterasi. Fitur yang tersisa antara lain : Auto Correlation 0⁰, Auto Correlation 45⁰ , Auto Correlation 90⁰, Contrast 135⁰ ,Correlation 90⁰ ,Difference Entrophy 0⁰, Difference Entrophy 45⁰ , Difference Entrophy 90⁰ ,Dissimilarity 0⁰, Dissimilarity 135⁰,Difference Variance 0⁰, Difference Variance 90⁰, Difference Variance 135⁰,Homogeneity 0⁰, Homogeneity 45⁰, Information of Measures Correlation 1 90⁰, Information of Measures Correlation 1 135⁰, Information of Measures Correlation 2 45⁰ , Information of Measures Correlation 2 135⁰, Inverse Difference 0⁰, Inverse Difference 90⁰, Inverse Difference Moment Normalized 0⁰ , Inverse Difference Moment Normalized 135⁰ , Inverse Difference Normalized 45⁰ , Inverse Difference Normalized 90⁰, Maximum Probability 90⁰, Maximum Probability 135⁰,Sum Average 90⁰, Sum Entrophy 0⁰ dan Sum Entrophy 135⁰.

Klasifikasi

Pada tahapan klasifikasi data – data dibagi menjadi menjadi dua buah data yaitu data training dan data testing. Pada penelitian ini 528 data subcitra terbagi menjadi 80% data training dan 20% data testing. Proses klasifikasi menggunakan metode Support vector machine

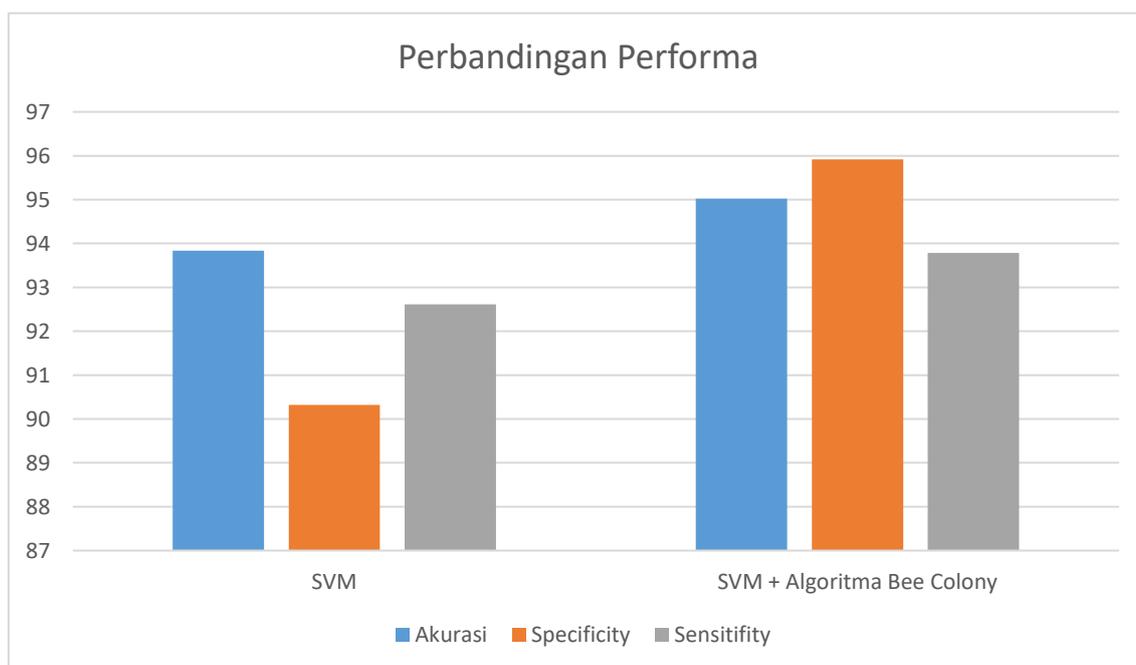
Evaluasi

Proses Evaluasi dilakukan dengan membandingkan hasil klasifikasi tanpa seleksi fitur dan hasil klasifikasi menggunakan seleksi fitur Algoritma Artificial Bee Colony. Berdasarkan hasil percobaan yang dilakukan dapat dilihat hasilnya pada tabel 1.

Tabel 1. Perbandingan hasil klasifikasi tanpa seleksi dan menggunakan seleksi fitur

	Klasifikasi menggunakan sleuruh fitur	Klasifikasi menggunakan fitur yang telah di seleksi fitur menggunakan ABC
Akurasi	93.8389 %	95.0237%
Specificity	90.3226 %	95.9184 %
Sensitifity	92.6102 %	93.7853 %

Berdasarkan hasil evaluasi pada tabel 1, Proses klasifikasi menggunakan seleksi fitur *Artificial Bee Colony* mendapatkan akurasi sebesar 95 %, dibandingkan dengan akurasi yang didapatkan dari klasifikasi tanpa menggunakan proses seleksi fitur sebesar 93,8%. Nilai specificity dan sensitifity juga mendapatkan nilai masing – masing 95,9 % dan 93,7 %, lebih besar dari proses yang tidak menggunakan selski fitur yaitu masing – masing hanya sebesar 90,3 % dan 92,6 %.



Gambar 5. Grafik 1

Seleksi fitur yang telah diterapkan pada penelitian ini menggunakan algoritma Algoritma Bee Colony telah menunjukkan peningkatan akurasi saat proses kalsifikasi Retinal Nerve Fiber Layer dengan algoritma SVM. Algoritma SVM tanpa menggunakan seleksi fitur mencapai akurasi optimal 93,8 % sedangkan algoritma SVM yang dikombinasi dengan Algoritma Bee Colony untuk seleksi fitur berhasil mencapai akurasi yang lebih baik yaitu sebesar 95 %.

SIMPULAN

Berdasarkan penelitian di atas, dapat disimpulkan bahwa metode seleksi fitur menggunakan algoritma Artificial Bee Colony dapat meningkatkan hasil klasifikasi dari Retinal Nerve Fiber Later dibandingkan dengan tidak menggunakan seleksi fitur. Metode Seleksi fitur Artificial Bee Colony mendapatkan 32 fitur terbaik dari 84 fitur yang didapatkan dari ekstraksi fitur GLCM. Hasil klasifikasi menggunakan metode SVM yang dikombinasikan dengan Seleksi fitur menggunakan Artificial Bee Colony mendapatkan akurasi sebesar 95 % dibandingkan dengan klasifikasi menggunakan Metode SVM tanpa kombinasi Seleksi fitur yang hanya sebesar 93,8% . Metode - metode yang digunakan pada penelitian ini dapat digunakan juga untuk optimasi pada bidang lain seperti klasifikasi data dan citra, optimasi jadwal dan lain-lain. Untuk penelitian kedepannya, klasifikasi bisa menggunakan algoritma evolusi yang lain dan metode klasifikasi yang lain. Kesimpulan dari penelitian ini yaitu telah terjadi peningkatan akurasi algoritma Backpropagation yang cukup signifikan setelah dilakukan nya proses seleksi atribut dengan menggunakan algoritma ABC-kNN terhadap cleveland heart disease dataset.

DAFTAR RUJUKAN

- Aly, R. H. M., Rahouma, K. H., & Hamed, H. F. A. (2019). Brain Tumors Diagnosis and Prediction Based on Applying the Learning Metaheuristic Optimization Techniques of Particle Swarm, Ant Colony and Bee Colony. *Procedia Computer Science*, 163, 165–179. <https://doi.org/10.1016/j.procs.2019.12.098>
- Barani, F., & Mirhosseini, M. (2018). Classification of binary problems with SVM and a mixed artificial bee colony algorithm. *3rd Conference on Swarm Intelligence and Evolutionary Computation, CSIEC 2018*, 1–5. <https://doi.org/10.1109/CSIEC.2018.8405413>
- 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. *Canadian Journal of Remote Sensing*, 28(1), 45–62. <https://doi.org/10.5589/m02-004>
- Haralick, R., Shanmugam, K., & Its'Hak, D. (1993). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 610–621.
- Jain, D., & Singh, V. (2018). Feature selection and classification systems for chronic disease prediction: A review. *Egyptian Informatics Journal*, 19(3), 179–189. <https://doi.org/10.1016/j.eij.2018.03.002>
- Karaboga, D., & Ozturk, C. (2011). A novel clustering approach: Artificial Bee Colony (ABC) algorithm. *Applied Soft Computing Journal*, 11(1), 652–657. <https://doi.org/10.1016/j.asoc.2009.12.025>
- Kaya Keles, M., & Kilic, U. (2018). Artificial Bee Colony Algorithm for Feature Selection on SCADI Dataset. *UBMK 2018 - 3rd International Conference on Computer Science and Engineering*, 463–466. <https://doi.org/10.1109/UBMK.2018.8566287>
- 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.
- Monika Parapat, I., & Tanzil Furqon, M. (2018). *Penerapan Metode Support Vector Machine (SVM) Pada Klasifikasi Penyimpangan Tumbuh Kembang Anak* (Vol. 2, Issue 10). <http://j-ptiik.ub.ac.id>
- 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>

- Sekhar, P. R., & Sujatha, B. (2020). A literature review on feature selection using evolutionary algorithms. *2020 7th International Conference on Smart Structures and Systems, ICSSS 2020*. <https://doi.org/10.1109/ICSSS49621.2020.9202257>
- 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>
- Singh, S., & Malik, K. (2022). Feature selection and classification improvement of Kinnow using SVM classifier. *Measurement: Sensors*, *24*. <https://doi.org/10.1016/j.measen.2022.100518>
- Soh, L. K., & Tsatsoulis, C. (1999). Texture analysis of sar sea ice imagery using gray level co-occurrence matrices. *IEEE Transactions on Geoscience and Remote Sensing*, *37*(2 I), 780–795. <https://doi.org/10.1109/36.752194>
- Zulpe, N., & Pawar, V. (2012). GLCM Textural Features for Brain Tumor Classification. *International Journal of Computer Science Issues*, *9*(3). www.IJCSI.org