

Optimasi Klasifikasi Parasit Malaria Dengan Metode LVQ, SVM dan *Backpropagation*

Jani Kusanti^{1*}, Tri Irianto Tjendrowarsono²

¹Program Studi Teknik Informatika, Universitas Surakarta

²Program Studi Teknik Elektro, Universitas Surakarta

^{1,2}Jln. Raya Palur Km.5 Surakarta, 57772, Indonesia

E-mail: jani_kusanti@yahoo.com¹, tri_irianto@yahoo.com²

Info Naskah:

Naskah masuk: 28 November 2020

Direvisi: 15 Maret 2021

Diterima: 20 Maret 2021

Abstrak

Penggunaan metode klasifikasi mempengaruhi hasil akurasi pengujian. Keakuratan metode klasifikasi dipengaruhi oleh jumlah kelas dalam gambar. Jumlah kelas dan jumlah data harus dipertimbangkan ketika membuat keputusan dalam pemilihan metode klasifikasi. Penelitian ini menggunakan 600 image, terbagi menjadi 510 image untuk pelatihan dan 90 image untuk tes. Jumlah kelas untuk diuji adalah 12 kelas dengan jumlah fitur awal yang digunakan oleh 22 fitur. Karakteristik yang digunakan dalam pengujian terdiri dari karakteristik bentuk dan karakteristik tekstur. Metode yang digunakan untuk klasifikasi pada penelitian ini adalah LVQ, Backpropagation, dan SVM. Data memiliki 22 fitur atau atribut yang merupakan hasil ekstraksi fitur tekstur dan bentuk. Fitur tekstur adalah energi 0°, energi 45°, energi 90°, energi 135°, entropi 0°, entropi 45°, entropi 90°, entropi 135°, kontras 0°, kontras 45°, kontras 90°, kontras 135°, homogenitas 0°, homogenitas 45°, homogenitas 90°, homogenitas 135°, korelasi 0°, Korelasi 45°, korelasi 90°, korelasi 135°, fitur bentuk area dan perimeter. Hasil pengujian menggunakan metode Backpropagation memperoleh hasil 89,7%, menggunakan metode LVQ memperoleh hasil 77,78%, dan metode SVM memperoleh hasil 99,1%.

Keywords:

LVQ;

SVM;

Backpropagation;

Malaria.

Abstract

The use of the classification method affects the results of the accuracy of the test. The accuracy of the classification method is affected by the number of classes in the image. The number of classes and the amount of data should be considered when making decisions in choosing a classification method. This study used 600 images, divided into 510 images for training and 90 images for testing. The number of classes to be tested is 12 classes with the initial number of features used by 22 features. The characteristics used in the test consist of shape characteristics and texture characteristics. The methods used for classification in this study are LVQ, Backpropagation, and SVM. The data has 22 features or attributes that are the result of texture and shape feature extraction. Texture features are energy 0°, energy 45°, energy 90°, energy 135°, entropy 0°, entropy 45°, entropy 90°, entropy 135°, contrast 0°, contrast 45°, contrast 90°, contrast 135°, homogeneity 0°, homogeneity 45°, homogeneity 90°, homogeneity 135°, correlation 0°, Correlation 45°, correlation 90°, correlation 135°, features of area and perimeter shape. The test results using the Backpropagation method obtained 89.7% results, using the LVQ method obtained 77.78% results, and the SVM method obtained 99.1% results.

*Penulis korespondensi:

Jani Kusanti

E-mail: jani_kusanti@yahoo.com

1. Pendahuluan

Covid-19 saat ini menjadi topik utama dalam setiap percakapan dan penelitian, karena dampaknya yang luar biasa di seluruh dunia. Begitu juga dengan malaria [1] berdasarkan laporan dari Organisasi Kesehatan Dunia (WHO) ditahun 2016, malaria masuk didaftar 10 penyakit yang paling mematikan yang terkait dengan lingkungan. Tak terkecuali dengan Indonesia [2], Dirilis situs web Kementerian Kesehatan Republik Indonesia, 72 persen dari data, penduduk di Indonesia tinggal di daerah bebas malaria. Namun masih ada 10,7 juta orang tinggal di daerah endemis malaria menengah dan tinggi, seperti Papua, Papua Barat, dan NTT. Untuk alasan ini, menjadi penting penelitian tentang malaria terus dikembangkan.

Dalam studi parasit malaria seperti yang dilakukan [3]–[10] identifikasi dengan berbagai metode digunakan untuk hasil yang optimal, mulai dari metode ROI untuk pemrosesan gambar seperti yang sudah dilakukan [6][7][9], penggunaan skala abu-abu seperti yang sudah dilakukan [3]–[5], peregangkan kontras yang juga sudah digunakan dalam penelitian [6][7][9]. Penggunaan segmentasi dengan fitur bentuk sudah dilakukan dalam penelitian [6][7][11], fitur tekstur [4][6][12][13], dan fitur warna [3][4][14]

Untuk hasil pengolahan berdasarkan kelompok atau kelas dilakukan menggunakan metode klasifikasi. Dalam penelitian yang sudah dilakukan sebelumnya oleh [4][9][11][15] metode klasifikasi SVM dipilih dan diperoleh hasil akurasi tinggi dengan rata-rata di atas 80%. Beberapa penelitian yang sudah dilakukan oleh [16]–[18] untuk klasifikasi dipilih dengan metode Backpropagation, pada pengujian akurasi diperoleh tinggi dengan rata-rata di atas 80%. Penelitian yang dilakukan oleh [6][16][15][17][18] hasil di atas 80% dengan metode LVQ. Namun, dari banyak penelitian yang telah dilakukan, belum diketahui apakah akan menghasilkan nilai akurasi yang sama pada objek menggunakan data, kelas, dan fitur yang sama.

Untuk alasan ini, penting dalam penelitian ini melakukan penelitian yang membandingkan metode LVQ, SVM, dan Backpropagation. Tujuannya untuk mengetahui apakah hasilnya akan sama dengan penggunaan data, kelas, dan karakteristik yang sama dan untuk mengetahui apa yang mempengaruhi hasil akurasi tinggi di setiap metode klasifikasi.

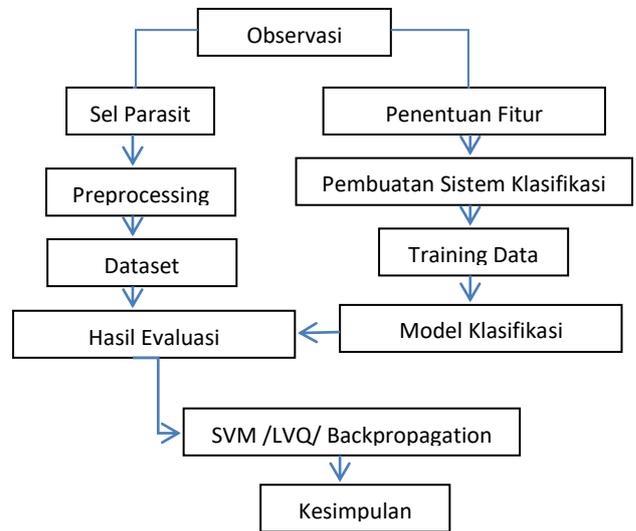
2. Metode

Pada Gambar 1 menunjukkan metode yang dilakukan dalam penelitian. Pada penelitian ini menggunakan data citra sediaan darah tebal, sebanyak 600 data yang terbagi menjadi 510 data latih dan 90 data uji.

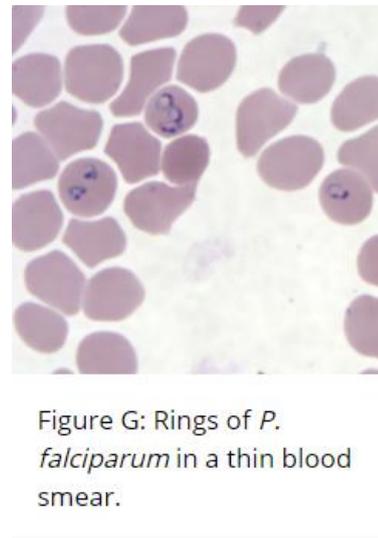
2.1 Preprocessing, Dataset, dan Penentuan Fitur

Data yang dihasilkan merupakan data yang sudah dilabeling diambil dari <https://www.cdc.gov/dpdx/malaria/index.html> Seperti ditunjukkan pada Gambar 2. Data diolah dengan tahapan, data yang diambil dari dataset yang sudah dilabeling disimpan pada drive dataset malaria, satu persatu data yang sudah dilabeling dipanggil dan dilakukan ROI. Langkah awal ini merupakan langkah yang penting dan perlu

pendampingan oleh pakar ahli yaitu dokter spesialis di bidang penyakit malaria. Data hasil ROI sebanyak 600 disimpan pada *drive* data latih. Langkah selanjutnya dilakukan proses pelatihan yang diawali dengan proses penyamaan ukuran pada citra parasite malaria, dan diikuti proses *contrast stretching*.



Gambar 1. Metode Penelitian



Gambar 2. Data yang sudah dilabeling

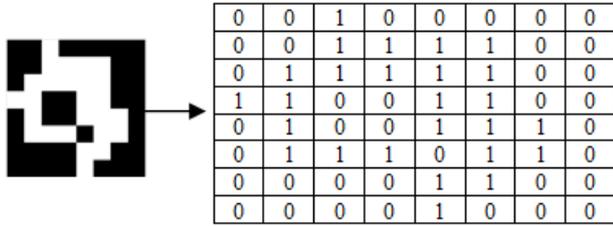
Hasil proses *contrast stretching* digunakan dalam proses segmentasi pada tahap ini digunakan metode otsu untuk memisahkan background dan mengambil citra parasit yang akan diukur berdasarkan ciri bentuk menggunakan morphology.

Morphologi digunakan untuk pembatas objek agar dapat dilakukan perhitungan seperti perimeter dan area, yang ditunjukkan pada persamaan (1) dan (2) [19].

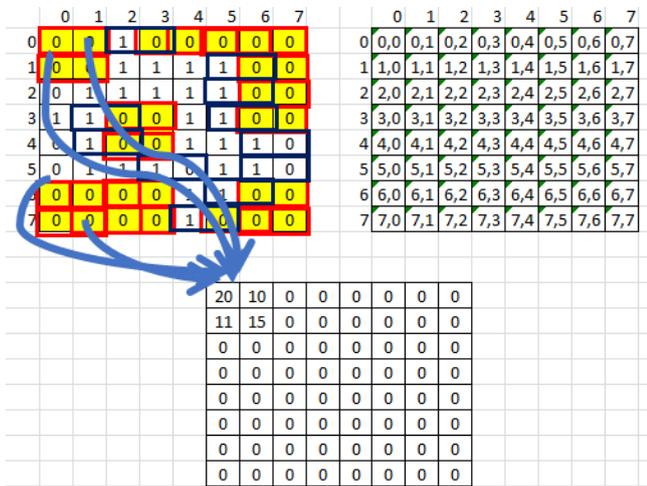
$$Area = \sum_x \sum_y f(x, y) \quad (1)$$

$$Perimeter = \sum_x \sum_y f(x, y), x, y \in Boundary\ region \quad (2)$$

Setelah nilai area dan perimeter diperoleh, selanjutnya dilakukan proses untuk mencari nilai ciri fitur dengan perhitungan statistic orde kedua yaitu matriks kookurensi. Hasil dilakukan dengan menghitung probabilitas hubungan ketetanggaan antara dua pixel terhadap jarak dengan berorientasi pada sudut tertentu. Seperti ditunjukkan pada Gambar 3



Gambar 3. Citra parasite malaria yang diresize ke [8 x 8]



Gambar 4. Penentuan awal matriks GLCM

0,36	0,19	0	0	0	0	0	0
0,19	0,27	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	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

Gambar 5. Hasil normalisasi GLCM

Satu level nilai pixel yang bertetangga dengan satu level nilai pixel lain dijumlahkan dalam jarak (d) dengan berorientasi pada sudut (θ) tertentu. Seperti ditunjukkan pada Gambar 4. Hasil transpose matrik yang sudah diolah menghasilkan nilai yang dilanjutkan dengan proses normalisasi agar jumlahnya bernilai 1, seperti ditunjukkan pada Gambar 5. Dari sudut empat arah dengan orientasi pada interval sudut yaitu 0° , 45° , 90° , dan 135° . Nilai fitur dari GLCM yang digunakan dihitung berdasarkan homogenitas, kontras, energy, entropi dan korelasi.

2.2 Klasifikasi SVM

Metode klasifikasi berdasarkan teori pembelajaran mesin[19] yang dikenal dengan *Support Vector Machines* (SVMs). Keunggulan SVMs terletak pada tingkat akurasi yang tinggi dibandingkan dengan jaringan saraf tiruan, *decision tree*, dan *Bayesian*. Hal ini terjadi dikarenakan sebelum digunakan untuk klasifikasi, terlebih dahulu dilakukan pelatihan pada data yang digunakan. Proses pelatihan menggunakan matriks fitur, sebagai input pelatihan. Data diperoleh dari hasil proses ekstraksi fitur. Pada klasifikasi, proses data pelatihan digunakan untuk mencari vektor pendukung dan bias data input. Berikut algoritma pelatihan untuk SVM,

Input: Z = Hasil proses ekstraksi fitur dalam bentuk matriks. Output: *Strain vector* sebagai target. Vektor Y_{train} = vektor untuk kolom klasifikasi pada kelas pertama, seluruh hasil pada kelas pertama diberikan symbol dengan angka 1, semua gambar apusan darah dari kelas lain dengan angka -1 . Dalam penelitian ini, fungsi kernel *Gaussian* dengan varians (α) = 1. Selanjutnya hitung matriks Hessian, misalnya,

Perkalian dari Gaussian untuk Y_{train} . Y_{train} merupakan vektor dengan nilai 1 dan -1 . Matriks Hessian berfungsi sebagai variabel input pemrograman kuadratik.

Algoritma pelatihan sebagai berikut:

- a. Menentukan input ($Z = X_{train}$) dan Target (Y_{train}) untuk pelatihan pada dua kelas.
- b. Menghitung *Gaussian*, ditunjukkan dengan rumus (3)

$$K(Z, Z_i) = \exp\left(\frac{-|Z - Z_i|^2}{2\sigma^2}\right) \tag{3}$$

- c. Hitung Hessian Matrix ditunjukkan pada rumus (4)

$$H = K(Z, Z_i) * Y * Y^T \tag{4}$$

- d. Tetapkan c dan *epsilon*. c =konstanta dalam pangganda *Lagrangian* dan *epsilon* (parameter biaya) = nilai batas atas dari a , yang berfungsi untuk mengontrol kesalahan klasifikasi. Penelitian ini menggunakan nilai $c=100000$ dan *epsilon* = 1×10^{-7} .

- e. Menetapkan vektor e untuk vektor satuan dengan dimensi = dimensi Y .

- f. Menghitung solusi pemrograman kuadratik ditunjukkan pada persamaan (5).

$$L(\alpha) = \frac{1}{2} \alpha^T H \alpha + e^T \alpha \tag{5}$$

Untuk pengujian, digunakan data diluar data pelatihan. Hasil proses merupakan nilai indeks dari fungsi nilai maksimum keputusan, menyatakan kelas pengujian. Jika suatu kelas dalam uji klasifikasi cocok dengan kelas data uji, klasifikasi dinyatakan benar. Hasil akhir dari klasifikasi adalah gambar darah yang cocok dengan nilai indeks fungsi keputusan menggunakan SVM satu terhadap semua. Memiliki fitur input data vektor T untuk data uji (w, x, b), dan k = jumlah kelas, data input digunakan untuk proses pengujian.

Hasil input dalam proses ekstraksi fitur, Proses pengujian adalah sebagai berikut:

- a. Menghitung *Kernel Gaussian* ditunjukkan pada rumus (6)

$$K(T, x_i) = \exp\left(\frac{-|T - x_i|^2}{2\sigma^2}\right) \quad (6)$$

- b. Penghitungan ditunjukkan pada rumus (7)

$$f_i = K(T, x_i)w_i + b_i \quad (7)$$

- c. Ulangi langkah 1, 2 untuk $I = 1$ sampai k
- d. Menentukan nilai maksimum dari f_i
- e. Kelas i adalah kelas dari T yang memiliki nilai f_i terbesar

2.3 Klasifikasi LVQ

Algoritma LVQ ada 2 bagian, sebagai berikut [20]:

Algoritma Pelatihan:

- a. Menetapkan:
 - 1) Variabel untuk bobot awal input ke- j sebagai kelas (cluster) ke- i : W_{ij} , dengan $i = 1, 2, \dots, k$; dan $j = 1, 2, \dots, m$.
 - 2) Max Epoch
 - 3) α (alpha)
 - 4) Dec α
 - 5) Min α
- b. Memasukkan :
 - 1) Data input x_{ij} , $i = 1, 2, \dots, n$ dan $j = 1, 2, \dots, m$
 - 2) Target = T_k , $k = 1, 2, \dots, n$
- c. Menetapkan kondisi awal : epoch = 0;
- d. Mengerjakan jika : (epoch \leq MaxEpoch) dan ($\alpha \geq$ Min α)
 - 1) Epoch = epoch + 1
 - 2) Untuk $i = 1$ sampai n
 - a) Menentukan J sehingga $|x_i - w_j|$ minimum, dengan $j = 1, 2, \dots, K$
 - b) Memperbaharui w_j : dengan ketentuan:
If $T = C_j$, then:
 $w_j(\text{baru}) = w_j(\text{lama}) + \alpha [x_i - w_j(\text{lama})]$
 - c) If $T \neq C_j$, then:
 $w_j(\text{baru}) = w_j(\text{lama}) - \alpha [x_i - w_j(\text{lama})]$;
 - 3) Pengurangan laju pelatihan ($\alpha = \alpha - \text{Dec}\alpha * \alpha$)

Dimana dengan parameter x , T , w_j , C_j , $|x - w_j|$

x = vektor input training ($x_1, \dots, x_i, \dots, x_n$)

T = kelas yang benar

w_j = bobot untuk keluaran ke- j

($w_{1j}, \dots, w_{ij}, \dots, w_{nj}$)

C_j = kelas yang ditunjukkan oleh keluaran ke- j

$|x - w_j|$ = jarak antara input training dan bobot ke- j

Algoritma Pengujian:

- a. Input data uji, misalkan: x_{ij} ; dimana $i = 1, 2, \dots, np$; dan $j = 1, 2, \dots, m$
- b. Untuk $i = 1 \rightarrow np$ kerjakan,
 - 1) Tentukan j hingga $Q\% X_i - W_j Q\%$ minimum; dengan $j = 1, 2, \dots, K$
 - 2) $J = \text{kelas } X_i$

2.4 Klasifikasi Backpropagation

Backpropagation disebut algoritma pembelajaran terbimbing yang ada pada jaringan syaraf tiruan, yang biasanya terbentuk dari banyak lapisan yang berfungsi sebagai pengubah bobot yang terhubung pada neuron yang ada pada hidden layer. sebagai contoh pada jaringan saraf tiruan untuk tiga layer terdapat input layer, Hidden Layer, dan output layer. Data latih yang di penelitian yang dilakukan sejumlah 510 untuk input layer, untuk hidden layer, dan keluaran untuk output layer sebanyak dua belas. Terdapat duabelas kelas yang akan diproses pada klasifikasi, dengan duabelas output layer. Ciri yang digunakan sebagai input sebanyak dua puluh dua fitur. 22 fitur dilakukan proses normalisasi, selanjutnya berfungsi untuk input jaringan syaraf tiruan.

Untuk training langkah pertama digunakan *Perceptron*. Fungsi aktivasi digunakan untuk mengatur bobot. Model *feed forward* yang digunakan oleh *Perceptron* artinya sebelum neuron diproses dengan aktivasi terlebih dahulu input dikirim ke sebuah neuron sehingga menghasilkan output.

3. Hasil dan Pembahasan

Hasil pengujian menggunakan metode SVM terhadap 510 data citra yang terbagi kedalam 12 kelas. Sebelum dilakukan proses pengujian terlebih dahulu dilakukan pemilihan learning rate yang terbaik menggunakan model *k-fold cross validation*, dengan $k = 1, 2, 3, 4, 5$. Dari hasil pengujian menggunakan K-Fold dapat dilihat pada Tabel 1 dan Tabel 2.

Tabel 1. Hasil pengujian klasifikasi SVM dengan linear

	K = 1	K = 2	K = 3	K = 4	K = 5
Akurasi (%)	53.0	52.0	62.0	60.0	56.0
Presisi (%)	33.0	34.4	45.3	37.8	44.0
Sensitifitas (%)	38.9	37.4	45.4	44.1	43.4
Spesifisitas (%)	95.4	95.6	95.5	96.3	95.7

Tabel 2. Hasil pengujian klasifikasi SVM dengan RBF

	K = 1	K = 2	K = 3	K = 4	K = 5
Akurasi (%)	100	98.0	100	100	98.0
Presisi (%)	100	96.2	100	100	97.9
Sensitifitas (%)	100	99.1	100	100	97.0
Spesifisitas (%)	100	99.8	100	100	99.8

Hasil pengujian Tabel 1. dan Tabel 2. Menunjukkan SVM dengan kernel linear memberikan akurasi rata-rata 57% yang tidak memuaskan. Akurasi tertinggi, yaitu 62%, diperoleh ketika $k = 3$. Seperti yang ditunjukkan pada Tabel 2, SVM dengan RBF kernel menghasilkan hasil yang jauh lebih baik dengan akurasi rata-rata 99,1%. Untuk hasil pengujian menggunakan metode *Backpropagation*, dari hasil pengujian diperoleh hasil seperti yang dapat dilihat pada Tabel 3.

Tabel 3. Hasil uji menggunakan metode *backpropagation*

Kelas	Akurasi
parasit dan bukan	95.7%
Gametosit falcifarum dan bukan	88.4%
Thropozoit dan bukan	91.3%
Ring dan bukan	98.6%
Thropozoit Vivax dan bukan	100%
Thropozoit Malaria dan bukan	95.7%

Tabel 4. Hasil Pengujian klasifikasi LVQ

Akurasi(%)	Sensitifitas (%)	Spesifisitas (%)
	FR 0.00	FR 82.35
	FS 40.00	FS 80.00
	FT 100.00	FT 76.47
	GF 100.00	GF 73.33
	MG 40.00	MG 80.00
77.78	MR 20.00	MR 81.18
	MS 100.00	MS 74.36
	MT 50.00	MT 79.76
	VG 100.00	VG 75.31
	VR 100.00	VR 74.03
	VS 50.00	VS 79.07
	VT 100.00	VT 76.19
	Rata-rata 66.67	Rata-rata 77.67

Tabel 5. Perbandingan Hasil Pengujian

Metode Klasifikasi	SVM	Backpropagation	LVQ
Akurasi	99,1	89,7	77,78
Presisi	98,8	88,2	83,2
Sensitifitas	99,2	82,9	60,5
Spesifisitas	99,9	87,2	90,7

Dari Tabel 3 dapat dilihat hasil akurasi bernilai 95%, untuk *gametosit falcifarum* dengan akurasi 88,4%, *ring* dengan akurasi 98,6%, dan *Thropozoit* dengan akurasi 91,3%. Secara keseluruhan, pengujian menggunakan metode *backpropagation* memiliki akurasi 89,5 %. Pada pengujian dengan LVQ untuk pengujian menggunakan uji K-Fold yang sama dan diperoleh nilai akurasi tertinggi pada 3-fold, learning rate 0,01, Deca 0,001 dan Minα 0,0001 sebesar 99% Pada Tabel 4 dapat dilihat hasil pengujian dengan menggunakan metode LVQ.

Dari Tabel 4 hasil pengujian menggunakan LVQ menghasilkan akurasi 77,78%. Hasil perbandingan pengujian dari SVM, Backpropagation, dan LVQ ditunjukkan pada Tabel 5.

4. Kesimpulan

Dari keseluruhan pengujian dapat disimpulkan hasil pengujian menggunakan metode Backpropagation memperoleh hasil 89,7%, menggunakan metode LVQ memperoleh hasil 77,78%, dan metode SVM memperoleh hasil 99,1%. Sehingga pada pengujian dengan 600 data, yang terbagi menjadi 510 data latih dan 90 data uji, dengan

pengolah ciri bentuk dan ciri tekstur yang sama, diperoleh hasil metode klasifikasi SVM memiliki tingkat akurasi paling baik.

Untuk saran selanjutnya dapat dilakukan pengujian dengan nilai α yang berbeda, dilanjutkan dengan jumlah data yang berbeda lebih dari 1000 data. Dilakukan juga uji K-Fold untuk klasifikasi. Dari kesemuanya dilakukan perbandingan waktu yang terbaik.

Daftar Pustaka:

- [1] D. G. D. D. O. MALARIA., "Malaria." p. 1882, 1882.
- [2] Kementerian Kesehatan RI, "Epidemiologi Malaria di Indonesia," *Bul. Jendela Data dan Inf. Kesehat.*, vol. 1, pp. 1–16, 2011, doi: 2088-270X.
- [3] V. S. Neeru Singla, "Deep learning enabled multi-wavelength spatial coherence microscope for the classification of malaria-infected stages with limited labelled data size," *Opt. Laser Technol.*, vol. 130, no. March, p. 106335, 2020, doi: 10.1016/j.optlastec.2020.106335.
- [4] C. Z. Dongyao Jia, Zhengyi li, "Detection of cervical cancer cells based on strong feature CNN-SVM network," *Neurocomputing*, 2020, doi: 10.1016/j.neucom.2020.06.006.
- [5] J. S. C. Luis Rosado, Jose M. Correia da Costa, Dirk Elias, "A Review of Automatic Malaria Parasites Detection and Segmentation in Microscopic Images," *Anti-Infective Agents*, vol. 14, no. 1, pp. 11–22, 2016, doi: 10.2174/221135251401160302121107.
- [6] E. Rika Rosnelly, Sri Hartati and S. M. Winarko, "Identification of Malaria Disease and Its Stadium Based on Digital Image Processing," *J. Theor. Appl. Inf. Technol.*, vol. 95, no. 3, pp. 700–710, 2017.
- [7] L. Rika Rosnelly, Jani Kusanti and S. Wahyuni, "Combination of thresholding and otsu method in increasing results of identification of malaria parasite type in thin blood smear image," *Int. J. Psychosoc. Rehabil.*, vol. 24, no. 4, pp. 3807–3818, 2020, doi: 10.37200/IJPR/V24I4/PR201494.
- [8] T. N. C. Margaret A. Philips, Jeremy N. Burrows, ando, Christine Manyando, Van Huijsduijnen, Rob Hooft Van Voorhis, Wesley C. Wells, "Malaria," *Nat. Rev. Dis. Prim.*, vol. 3, 2017, doi: 10.1038/nrdp.2017.50.
- [9] C. Mehanian, M. Jaiswal, C. Delahunt, and C. THOMPson, "Computer-Automated Malaria Diagnosis and Quantitation Using Convolutional Neural Networks," *Proc. ICCVW, Venice, Italy*, pp. 116–125, 2017.
- [10] M. Kannaiyan, G. Karthikeyan, and J. G. Thankachi Raghuvaran, "Prediction of specific wear rate for LM25/ZrO2 composites using Levenberg-Marquardt backpropagation algorithm," *J. Mater. Res. Technol.*, vol. 9, no. 1, pp. 530–538, 2020, doi: 10.1016/j.jmrt.2019.10.082.
- [11] A. Sapkal and U. V. Kulkarni, "Modified backpropagation with added white Gaussian noise in weighted sum for convergence improvement," *Procedia Comput. Sci.*, vol. 143, pp. 309–316, 2018, doi: 10.1016/j.procs.2018.10.401.
- [12] M. Kumar and M. Diwakar, "CT image denoising using locally adaptive shrinkage rule in tetrolet domain," *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 30, no. 1, pp. 41–50, 2018, doi: 10.1016/j.jksuci.2016.03.003.
- [13] Y. Wang, J. Liu, R. Li, X. Suo, and E. Lu, "Precipitation forecast of the Wujiang River Basin based on artificial bee colony algorithm and backpropagation neural network," *Alexandria Eng. J.*, vol. 59, no. 3, pp. 1473–1483, 2020, doi: 10.1016/j.aej.2020.04.035.
- [14] H. Di, X. Ke, Z. Peng, and Z. Dongdong, "Surface defect classification of steels with a new semi-supervised learning method," *Opt. Lasers Eng.*, vol. 117, no. September 2018, pp. 40–48, 2019, doi: 10.1016/j.optlaseng.2019.01.011.

- [15] X. Liu, K. Chen, T. Wu, D. Weidman, F. Lure, and J. Li, "Use of multimodality imaging and artificial intelligence for diagnosis and prognosis of early stages of Alzheimer's disease," *Transl. Res.*, vol. 194, pp. 56–67, 2018, doi: 10.1016/j.trsl.2018.01.001.
- [16] B. Mokbel, B. Paassen, F. M. Schleif, and B. Hammer, "Metric learning for sequences in relational LVQ," *Neurocomputing*, vol. 169, pp. 306–322, 2015, doi: 10.1016/j.neucom.2014.11.082.
- [17] B. B. Traore, B. Kamsu-Foguem, and F. Tangara, "Deep convolution neural network for image recognition," *Ecol. Inform.*, vol. 48, pp. 257–268, 2018, doi: 10.1016/j.ecoinf.2018.10.002.
- [18] S. Robertson, H. Azizpour, K. Smith, and J. Hartman, "Digital image analysis in breast pathology—from image processing techniques to artificial intelligence," *Transl. Res.*, vol. 194, pp. 19–35, 2018, doi: 10.1016/j.trsl.2017.10.010.
- [19] B. R. Gonzalez, R. C., Woods, R. E., & Masters, *Digital Image Processing Using Matlab - Gonzalez Woods & Eddins*. 2013.
- [20] L. Fausett, *Fundamentals Of Neural Network Architectures, Algorithms, and Applications*, vol. 116, no. 0. 1994.