

Deteksi Penyakit Malaria Menggunakan Convolutional Neural Network Berbasis Saliency (Detection of Malaria Using Convolutional Neural Network Based on Saliency)

Yohannes¹, Siska Devella², Kelvin Arianto³

^{1,2,3}Teknik Informatika, STMIK Global Informatika MDP

¹yohannesmasterous@mdp.ac.id

²siskadevella@mdp.ac.id

³ariantokelvin6@gmail.com

Abstrak - Malaria adalah penyakit mematikan yang menjadi masalah di berbagai negara. Metode yang paling umum untuk mendeteksi malaria adalah dengan memeriksanya secara manual, yang memakan waktu. Convolutional Neural Network (CNN) adalah salah satu solusi untuk deteksi malaria. CNN telah terbukti memberikan hasil yang sangat baik dalam klasifikasi gambar dan telah banyak digunakan dalam penelitian sebelumnya dan memiliki hasil yang baik. Sebelum proses klasifikasi, pra-pemrosesan gambar dapat digunakan untuk mendapatkan hasil klasifikasi yang lebih baik. Salah satu metode dalam pra-pemrosesan adalah arti-penting. Saliency adalah metode yang dapat mengambil bagian penting dari suatu gambar. Pada penelitian ini dilakukanlah pengujian terhadap metode saliency dan CNN untuk masalah pendeteksian penyakit malaria. Skenario pengujian dilakukan dengan membandingkan metode saliency, yaitu *Region Contrast Saliency*, *Frequency-tuned saliency*, *Spectral Residual*, dan *Histogram Contrast*. Metode saliency terbaik dalam mendeteksi penyakit malaria didapatkan oleh metode *frequency-tuned saliency* dengan akurasi sebesar 90,32% dibandingkan dengan metode saliency yang lain, yaitu 62,67% untuk *region contrast saliency*, 50% untuk *spectral residual saliency*, dan 79,06% untuk *histogram contrast saliency*.

Kata-kata kunci: Klasifikasi; CNN; Malaria; Saliency

Abstract - Malaria is a deadly disease that become a problem in various countries. The most common method for detecting malaria is through checking it manually, which is time consuming. Convolutional Neural Network (CNN) is one of solution for malaria detection. CNN has been proved to provide excellent result in image classification and has been widely used in previous studies and have good results. Before classification process, image pre-processing can be used to get better classification result. One of the method in pre-processing is saliency. Saliency is a method that is able to take an important part of an image. Among other saliency

methods, region contrast saliency have better result compared to spectral residual saliency. In this paper, saliency with convolutional neural network were used for malaria detection. Scenario testing is done by comparing the saliency method, namely Region Contrast Saliency, Frequency-tuned Saliency, Spectral Residual, and Histogram Contrast. The best saliency method in detecting malaria is obtained by the frequency-tuned saliency method with an accuracy of 90.32% compared to other saliency methods, namely 62.67% for region contrast saliency, 50% for spectral residual saliency, and 79.06% for contrast saliency histograms.

Keywords: Classification; CNN; Malaria; Saliency

I. PENDAHULUAN

Penyakit malaria merupakan penyakit yang disebabkan oleh parasit darah plasmodium. Penyakit ini ditularkan melalui gigitan nyamuk Anopheles. Selain ditularkan oleh nyamuk, malaria juga dapat ditularkan melalui transfusi darah maupun jarum suntik yang digunakan secara bergantian. Gejala malaria umumnya meliputi demam, kelelahan, muntah dan sakit kepala serta pucat karena kekurangan darah. Dengan kasus yang parah dapat menyebabkan kejang, gangguan kesadaran, sesak nafas, bahkan kematian. Penyakit malaria harus ditangani secara cepat dan tepat untuk menghindari penularan malaria lebih lanjut dan mencegah komplikasi. Parasit malaria (plasmodium) memiliki siklus hidup yang kompleks, dan membutuhkan inang atau tempat untuk hidup, baik manusia maupun nyamuk Anopheles. Terdapat 5 jenis parasit malaria yang dapat menyerang manusia, yaitu Plasmodium Falciparum, Plasmodium Vivax, Plasmodium Malariae, Plasmodium Ovale, dan Plasmodium Knowlesi. Penanganan malaria dapat meliputi diagnosis secara klinis dan diagnosis laboratorium. Diagnosis secara klinis umumnya

merupakan pemeriksaan berdasarkan gejala-gejala malaria, sedangkan diagnosis laboratorium merupakan pemeriksaan darah pasien di laboratorium [1].

Pada saat ini diagnosis laboratorium paling umum digunakan untuk mendeteksi penyakit malaria karena dapat digunakan untuk mendeteksi penyakit menular yang lain. Diagnosis laboratorium untuk deteksi penyakit malaria lebih fokus pada analisis sel darah merah atau eritrosit yang merupakan sel darah yang jumlahnya paling banyak dalam komponen darah manusia. Sel darah merah memiliki bentuk bikonkaf dan tidak berinti yang memiliki masa aktif selama 120 hari sebelum dihancurkan. Sel darah merah berfungsi untuk mengikat oksigen yang diperlukan untuk oksidasi jaringan-jaringan tubuh lewat darah [2]. Akan tetapi diagnosis pada sel darah merah sendiri dapat memakan waktu yang lama, dan sulit dikarenakan ukuran parasit plasmodium yang sangat kecil dan banyaknya objek lain yang mirip dengan parasit malaria [3].

Pendeteksian penyakit malaria menggunakan teknologi sudah berkembang. Beberapa metode klasifikasi citra untuk penyakit malaria pada sel darah merah telah dilakukan, di antaranya *Support Vector Machine* (SVM) [4], *K-Nearest Neighbor* (KNN) [5], *Learning Vector Quantization* (LVQ) [6], dan lain-lain. Selain itu, metode klasifikasi citra yang saat ini sedang berkembang adalah *deep learning*. Terdapat berbagai jenis *deep learning*, di antaranya adalah *Convolutional Neural Network* (CNN), *Long Short Term Memories*, *Recurrent Neural Network* (RNN), dan lain-lain [7]. CNN merupakan pengembangan dari *Multilayer Perceptron* (MLP) yang terutama digunakan untuk klasifikasi citra. CNN dinilai lebih baik dari MLP karena CNN memiliki kedalaman jaringan yang lebih tinggi dari MLP, dan MLP juga memiliki banyak parameter bebas dan informasi yang berlebihan dalam arsitektur sehingga tidak efisien [8]. Penggunaan CNN sudah digunakan untuk diagnosis penyakit malaria [9], [10]. Di sisi lain, CNN juga diterapkan untuk pengenalan rambu-rambu lalu lintas [11]. Pada kasus klasifikasi malaria, CNN mampu memberikan hasil yang lebih baik dibandingkan dengan *transfer learning* SVM dan metode klasifikasi yang lain [9].

Dalam klasifikasi, citra dapat diproses terlebih dahulu agar dapat menghasilkan klasifikasi yang lebih baik. Salah satu metodenya adalah *saliency*. *Saliency* merupakan bentuk yang mampu memberikan informasi penting pada bagian tertentu yang lebih dominan dibandingkan dengan bagian lainnya dalam sebuah citra. Oleh karena itu, *Saliency* mampu mengambil bagian yang dianggap penting pada sebuah citra. Pada saat ini, *saliency* sudah banyak digunakan dalam berbagai bidang

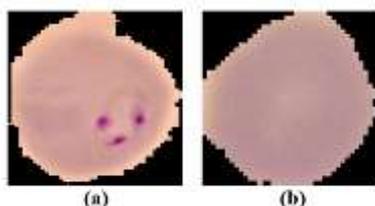
computer vision seperti pengenalan objek, *image segmentation*, *content aware* [12]. *Saliency* sendiri memiliki banyak metode seperti *region contrast*, *histogram contrast*, *local contrast*, dan lain-lain. Penggunaan *saliency* sudah banyak digunakan pada proses klasifikasi citra, di antaranya adalah *Graph-based visual saliency* untuk klasifikasi buah dan tanaman [13], *Saliency Attentive Model* untuk klasifikasi sel [14], *Co-saliency propagation* untuk klasifikasi arsitektur bangunan [15]. *Region contrast saliency* memiliki beberapa keunggulan, yaitu dapat menghasilkan *saliency map* dengan kualitas dan nilai *precision* dan *recall* yang lebih tinggi dibandingkan metode yang lain [12]. *Saliency* dapat digunakan pada klasifikasi citra dikarenakan *saliency* dapat memberikan *output* berupa *saliency map* yang memperlihatkan bagian yang bermakna pada sebuah citra.

II. METODE

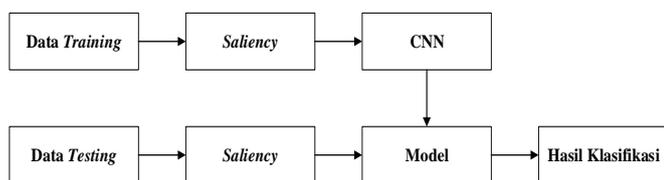
Penelitian ini menggunakan *Malaria Cell Images Dataset* berjumlah 27.558 citra sel darah merah yang terinfeksi malaria dan tidak yang diambil dari National Institute of Health yang telah digunakan oleh [16]. Citra sel darah yang terinfeksi malaria dan tidak terinfeksi dapat dilihat pada Gambar 1.

Tahapan metode dimulai dengan melakukan *image pre-processing* dengan *saliency* pada *dataset*, yang dilanjutkan dengan perancangan sistem *Convolutional Neural Network* (CNN). Sistem dirancang dengan membagi *dataset* menjadi dua bagian yaitu data *training* dan data *testing* dengan 70% merupakan data *training* dan 30% merupakan data *testing*. Pada data *training* citra akan melalui tahap *image pre-processing* yaitu *saliency* yang kemudian akan digunakan untuk membangun model CNN. Model CNN yang telah dibangun akan digunakan untuk data *testing*. Data *testing* akan melalui tahap *image pre-processing* dengan *saliency* yang kemudian akan menggunakan model yang telah dibangun sebelumnya dengan data *training* untuk mendeteksi penyakit malaria. Tahapan metode dapat dilihat pada Gambar 2.

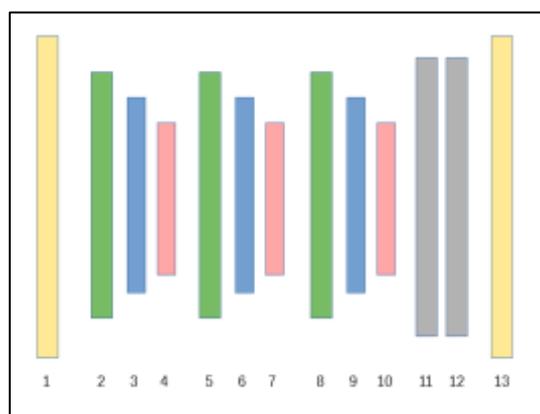
Susunan *layer convolutional neural network* yang digunakan pada tahap klasifikasi dapat dilihat pada Gambar 3 dengan warna krem (1 dan 13) merupakan *input* dan *output* citra, warna hijau (2, 5, 6) merupakan *convolutional layer*, warna biru (3, 6, 9) merupakan ReLU, warna pink (4, 7, 10) merupakan *pooling layer* dengan jenis *max pooling*, dan warna abu-abu merupakan *fully connected layer*.



Gambar 1. (a) Citra sel darah terinfeksi malaria, (b) Citra sel darah tidak terinfeksi malaria



Gambar 2. Tahapan metode yang digunakan



Gambar 3. Susunan layer pada CNN yang digunakan

Metode saliency yang digunakan pada penelitian ini adalah *region contrast saliency*, *frequency-tuned saliency*, *histogram contrast saliency*, dan *spectral residual saliency*.

A. Region Contrast Saliency

Saliency detection adalah sebuah metode yang mendeteksi bagian yang memberikan informasi penting dibandingkan dengan bagian lainnya. *Saliency detection* biasanya dipakai sebagai langkah awal dari banyak tahapan aplikasi citra seperti *image segmentation*, *object recognition*, *adaptive compression image*, *context-aware*, dll [12]. Metode *region contrast saliency* mengintegrasikan hubungan spasial ke dalam perhitungan kontras pada *region*. *Region contrast saliency* diawali dengan membagi citra menjadi beberapa *region*. Lalu membangun histogram warna untuk setiap regionnya. Untuk setiap wilayah r_k nilai *saliency* dihitung dengan mengukur kontras warnanya

dengan semua wilayah lain pada citra, yang dihitung dengan menggunakan persamaan 1 :

$$S(r_k) = \sum_{r_k \neq r_i} \omega(r_i) D_r(r_k, r_i) \quad (1)$$

Dimana $S(r_k)$ adalah nilai *saliency* dari region r_k , $\omega(r_i)$ adalah bobot dari *region* dan $D_r(r_k, r_i)$ adalah jarak warna antara *region* r_k dan r_i . Dengan jarak warna menggunakan persamaan 2:

$$D_r(r_k, r_i) = \sum_{i=1}^{n1} \sum_{j=1}^{n2} f(c_{1,i}) f(c_{2,j}) D(c_{1,i}, c_{2,j}) \quad (2)$$

Dimana $f(c_{k,i})$ adalah probabilitas dari warna c_k ke- i dari semua warna n_k pada *region* r_k ke- k , $k = (1, 2)$ [12].

B. Spectral Residual Saliency

Spectral residual saliency merupakan metode *saliency* yang mengalkulasi *saliency map* dengan menganalisis *log-spectrum* dari input gambar. Model ini tidak bergantung pada fitur, kategori, maupun pengetahuan lain tentang objek. Dimulai dari prinsip natural *image statistics*, metode ini merupakan metode *front-end* yang mengikuti perilaku pada *pre-attentive visual search*. Metode ini dimulai dengan menganalisis *log-spectrum* pada gambar untuk mendapatkan *spectral residual*. Lalu mengubah *spectral residual* menjadi spatial domain untuk mendapatkan *saliency map*. Dikarenakan sumber daya yang digunakan untuk melakukan FFT cukup kecil, hal ini membuat SR memiliki kelebihan yaitu memiliki performa yang lebih cepat. *Spectral residual saliency* juga dapat digunakan untuk mendeteksi beberapa objek sekaligus dengan hasil yang cukup baik [17]. Citra yang dihasilkan dari *spectral residual saliency* memiliki resolusi yang kecil.

C. Histogram Contrast Saliency

Histogram contrast saliency merupakan metode *saliency* yang menghitung nilai *saliency* berdasarkan statistik warna dari gambar masukan. Nilai *pixel saliency* tersebut akan didapatkan berdasarkan perbedaan konlatitras warna dengan semua pixel lain pada gambar. Karena perhitungan tersebut dapat memakan waktu yang cukup lama, maka perhitungan tersebut dipercepat dengan mengurangi jumlah warna *pixel* pada gambar. Metode ini merupakan metode yang sederhana, cepat, dan efisien yang memiliki hasil *precision* dan *recall* yang bagus dibandingkan beberapa metode *saliency* yang lain pada *dataset* tertentu [12].

D. Frequency-tuned Saliency

Pendekatan metode *saliency* menggunakan *frequency-tuned* memiliki beberapa keunggulan utama dibandingkan beberapa metode *saliency* terdahulunya.

Keunggulan tersebut yaitu dapat menentukan batas-batas wilayah dengan baik, resolusi yang tinggi, dan komputasinya efisien. Hasil *saliency map* yang dihasilkan juga dapat digunakan untuk aplikasi yang lain dengan lebih efektif. Nilai *saliency* pada metode ini dihitung langsung dari perbedaan warna dengan warna gambar rata-rata dan pencahayaan. Pendekatan ini memiliki hasil yang sangat baik dengan nilai *precision* dan *recall* yang tinggi [18].

E. Convolutional Neural Network

Convolutinal Neural Network (CNN) adalah sebuah jaringan saraf tiruan yang terinspirasi oleh sistem visual hewan. CNN sangat cocok untuk mengenali citra. Model CNN menggunakan banyak layer untuk memproses data masukan. Awal penggunaan CNN ditelusuri kembali pada tahun 1990an untuk pengenalan suara dan pengenalan teks, lalu lanjut ke pengenalan tulisan tangan kemudian pengenalan citra [9]. Terdapat 6 layer pada CNN, yaitu:

1) Convolutional Layer. Sebagian besar proses perhitungan dilakukan pada convolutional layer. Convolutional layer melakukan proses untuk memberi label pada input dengan merujuk kepada yang sudah dipelajari sebelumnya. Sebuah filter akan dipakai pada citra, sebagai contoh filter 3x3 digunakan pada citra 8x8, maka filter akan menghitung pada lokasi pikselnya yang sekarang, kemudian bergeser ke kanan, menghitung kembali sampai semua posisi piksel telah dihitung. Hasilnya akan membentuk sebuah kernel persegi yang akan digunakan sebagai input pada layer selanjutnya. Pada convolutional layer biasanya menggunakan lebih dari satu filter [19]. Contoh proses konvolusi dapat dilihat pada Gambar 4.

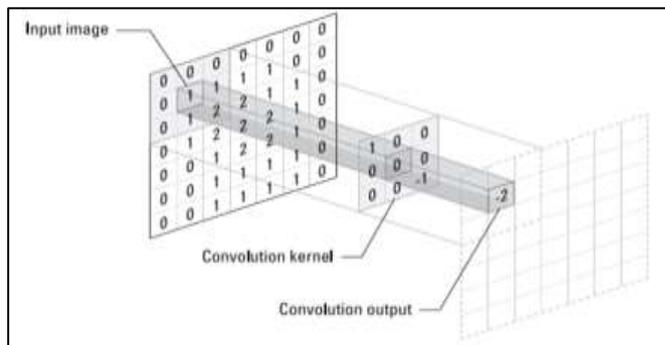
2) Pooling Layer. Pooling layer menyederhanakan output yang diterima dari convolutional layer sehingga data menjadi lebih kecil, dan mudah dikelola. Pada layer ini, input akan dipotong menjadi grid, dimana setiap grid terdiri dari sejumlah neuron. Kemudian operasi pooling akan digunakan pada setiap sel pada grid. Terdapat beberapa tipe pooling layer, seperti max pooling, dan average pooling. Max pooling merupakan operasi pooling dimana neuron dengan nilai aktivasi terbesar yang digunakan. Sedangkan average pooling memiliki output berupa nilai rata-rata dari setiap neuron yang terdapat dalam satu sel grid [21]. Contoh proses max pooling dapat dilihat pada Gambar 5.

3) ReLU Layer. Rectified Linear Units (ReLU) layer, layer ini mengaplikasikan fungsi aktivasi (Persamaan 3):

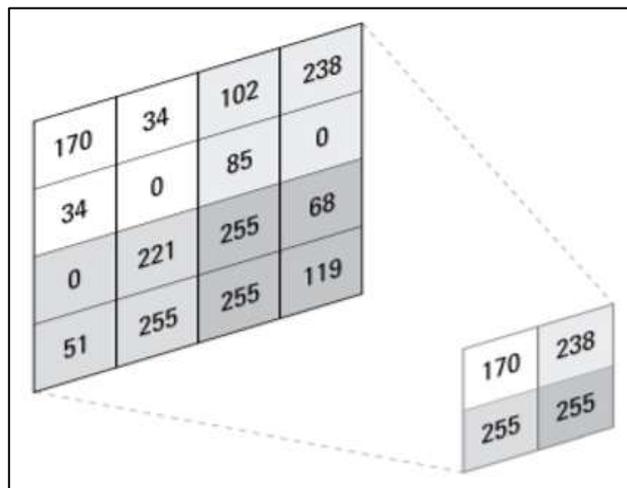
$$f(x) = \max(0, x) \quad (3)$$

yang kemudian hasilnya akan digunakan pada layer berikutnya. Layer ini berfungsi untuk meningkatkan sifat non linearitas dari jaringan secara keseluruhan tanpa mempengaruhi bidang reseptif convolutional layer [22].

4) Fully Connected Layer. Pada fully connected layer, setiap neuron memiliki koneksi penuh ke semua aktivasi pada layer sebelumnya untuk klasifikasi citra. Cara kerja fully connected layer sama persis dengan feed-forward network. Fully connection layer mungkin digunakan lebih dari satu untuk memperkuat proses komputasi yang dilakukan [22].



Gambar 4. Proses konvolusi pada CNN [20]



Gambar 5. Proses max pooling pada pooling layer [20]

III. HASIL DAN PEMBAHASAN

A. Saliency

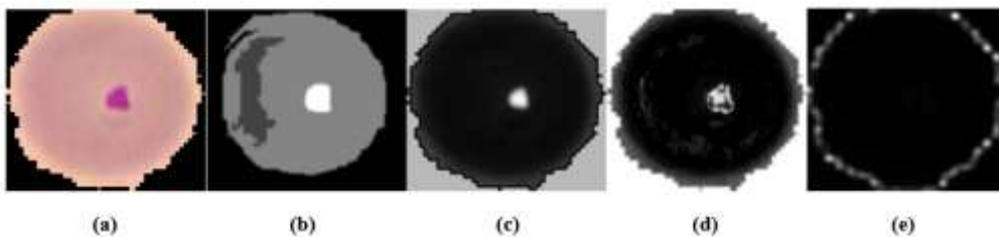
Dari penelitian yang dilakukan, didapatkan hasil dari *saliency*. Hasil akan ditampilkan berupa citra original tanpa *saliency* (Gambar 6a), citra *region contrast saliency* (Gambar 6b), citra *frequency-tuned saliency* (Gambar 6c), citra *histogram contrast saliency* (Gambar 6d), dan citra *spectral residual saliency* (Gambar 6e) untuk citra yang mempunyai parasit malaria.

Beberapa data pada *dataset* memiliki perubahan *contrast* pada data sel yang sangat mempengaruhi *saliency map* yang dihasilkan. Perubahan *contrast* tersebut dengan kurangnya *contrast* pada parasit menyebabkan *saliency map* yang dihasilkan sangat buruk sehingga dapat mempengaruhi hasil klasifikasi CNN yang dilakukan pada tahap berikutnya. Gambar yang memiliki hasil *saliency map* yang buruk dapat dilihat pada Gambar 7 dengan Gambar 7a merupakan

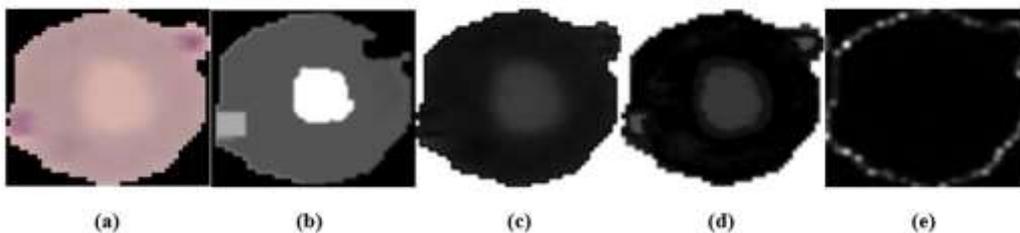
citra original, Gambar 7b merupakan *region contrast saliency*, Gambar 7c merupakan *frequency-tuned saliency*, Gambar 7d merupakan *histogram contrast saliency*, dan Gambar 7e merupakan *spectral residual saliency*.

Proses *saliency* juga dilakukan pada gambar yang tidak berparasit. Hasil *saliency* ini dapat dilihat pada Gambar 8. Gambar dengan tidak menggunakan *saliency* (Gambar 8a), *region contrast saliency* (Gambar 8b), *frequency-tuned saliency* (Gambar 8c), *histogram contrast saliency* (Gambar 8d), dan *spectral residual saliency* (Gambar 8e).

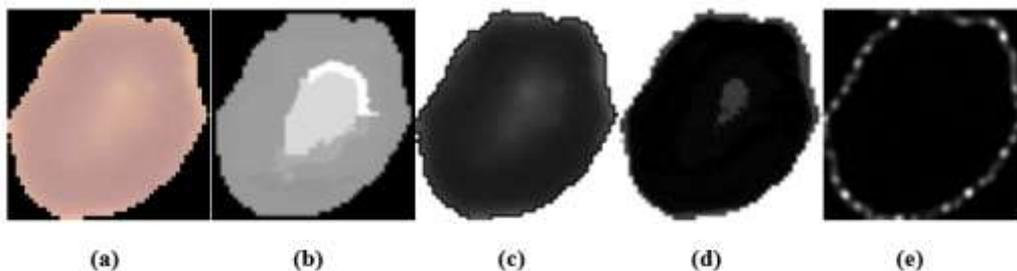
Dari Gambar 8 hasil *saliency* pada *region contrast saliency* memiliki hasil yang kurang baik karena *saliency map* yang dihasilkan memiliki nilai *saliency* yang buruk sehingga bagian tengah pada gambar terlihat lebih terang yang seharusnya tidak. *Spectral residual saliency* memiliki hasil yang paling buruk karena hanya dapat mengambil tepi sel darah (Gambar 8e).



Gambar 6. (a) Citra Original, (b) RC, (c) FT, (d) HC, (e) SR



Gambar 7. (a) Citra Original, (b) RC, (c) FT, (d) HC, (e) SR



Gambar 8. (a) Citra Original, (b) RC, (c) FT, (d) HC, (e) SR

B. Hasil CNN

CNN diterapkan pada 19.292 data *training* dan 8.266 data *testing* dengan 10 *epoch* dan 2 *batch size*. Metode yang diterapkan dalam CNN yaitu tanpa *saliency*, *region contrast saliency* (RC), *spectral residual saliency* (SR), *histogram contrast saliency* (HC), dan *frequency-tuned saliency* (FT). Hasil dari CNN akan ditampilkan dalam bentuk grafik berdasarkan jenis metode *saliency*.

Hasil tanpa *saliency* memiliki hasil yang sangat baik dengan akurasi diatas 90%. Dapat dilihat bahwa akurasi kurang stabil karena mengalami beberapa penurunan dan peningkatan seperti pada *epoch* 1 dan *epoch* 2 meningkat yang kemudian turun lagi pada *epoch* 3. Nilai paling tinggi berada pada *epoch* 10 dengan nilai 95,06% dan nilai terendahnya berada pada *epoch* 3 dengan nilai 91,5%. Grafik hasil *training* dan *testing* tanpa *saliency* dapat dilihat pada Gambar 9.

Hasil *region contrast saliency* memiliki hasil yang kurang baik. Hal ini disebabkan oleh beberapa faktor pada perhitungan *saliency* seperti perbedaan warna yang sedikit yang menyebabkan perubahan warna yang kecil dapat mempengaruhi hasil *saliency*. Hasil akurasi *region contrast saliency* memiliki nilai yang cukup stabil diatas 60%. Dapat dilihat bahwa perubahan terjadi pada *epoch* 6 ketika akurasi mengalami penurunan dibandingkan dengan *epoch* sebelumnya dan merupakan *epoch* dengan nilai akurasi terendah yaitu sebesar 56,9%. Akurasi tertinggi berada pada *epoch* 1 yaitu sebesar 67,78%. Grafik hasil *training* dan *testing* *region contrast saliency* dapat dilihat pada Gambar 10.

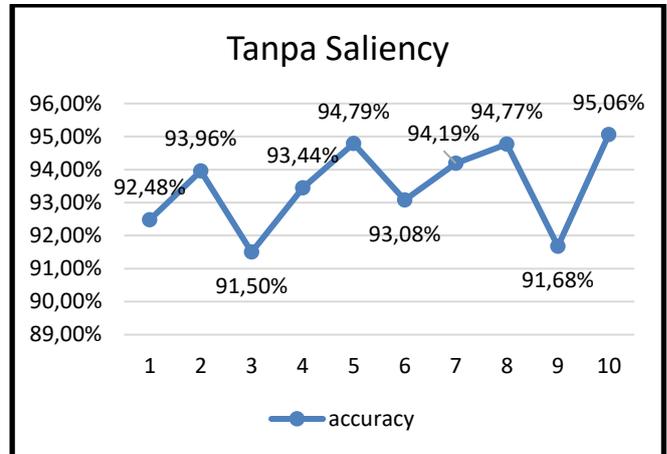
Histogram contrast saliency memiliki hasil akurasi yang cukup baik dengan nilai akurasi rata-rata diatas 80%. Akurasi paling tinggi dimiliki *epoch* 6 dengan nilai 88,24% yang kemudian akurasi terus menurun sampai *epoch* 10. Akurasi terendah dimiliki pada *epoch* 3 yang mengalami penurunan yang cukup besar dibandingkan *epoch* sebelumnya. Grafik hasil *training* dan *testing* *histogram contrast saliency* dapat dilihat pada Gambar 11.

Spectral residual saliency memiliki hasil yang buruk karena tidak dapat mengambil bagian yang berparaset dengan baik. Hasil *spectral residual saliency* hanya menghasilkan bagian tepi sel saja. Akurasi yang didapat tetap pada 50%. Grafik hasil *training* dan *testing* *spectral residual saliency* dapat dilihat pada Gambar 12.

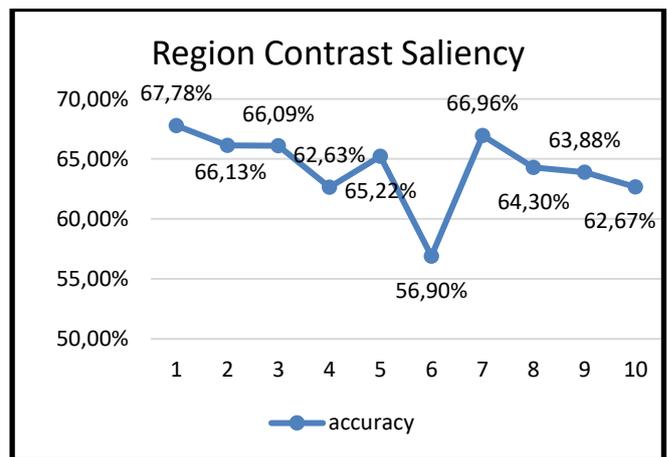
Frequency tuned saliency memiliki hasil yang paling baik diantara *saliency* yang lain. Akurasi memiliki rata-rata nilai diatas 85%. Dapat dilihat bahwa akurasi mengalami penurunan mulai dari *epoch* 5 sampai *epoch* 6, dengan *epoch* 6 merupakan *epoch* dengan akurasi terkecil. Kenaikan akurasi dialami mulai dari *epoch* 7 dan *epoch* 8 yang kemudian cukup stabil sampai dengan

epoch 10. Grafik hasil *training* dan *testing* *frequency tuned saliency* dapat dilihat pada Gambar 13.

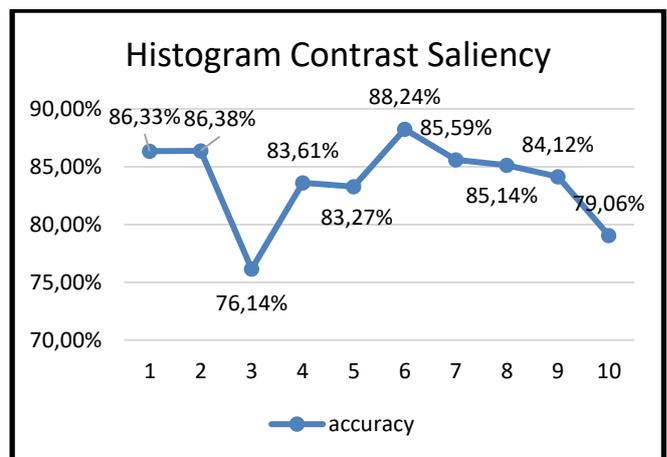
Hasil perbandingan *region contrast saliency*, *frequency-tuned saliency*, *histogram contrast saliency*, *spectral residual saliency* dan tanpa *saliency* dalam bentuk bar dapat dilihat pada Tabel 1.



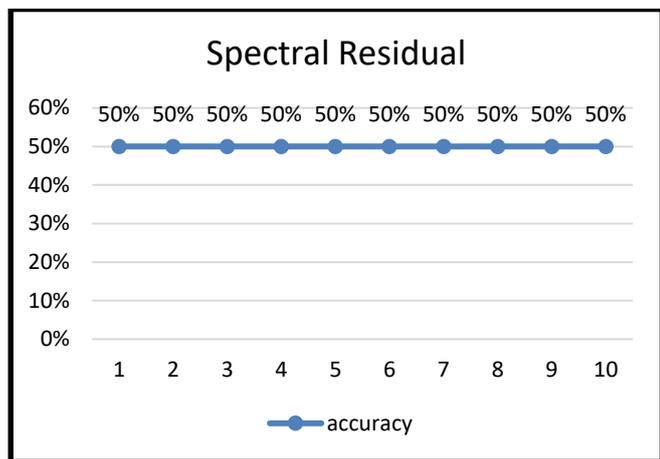
Gambar 9. Hasil klasifikasi CNN pada citra original



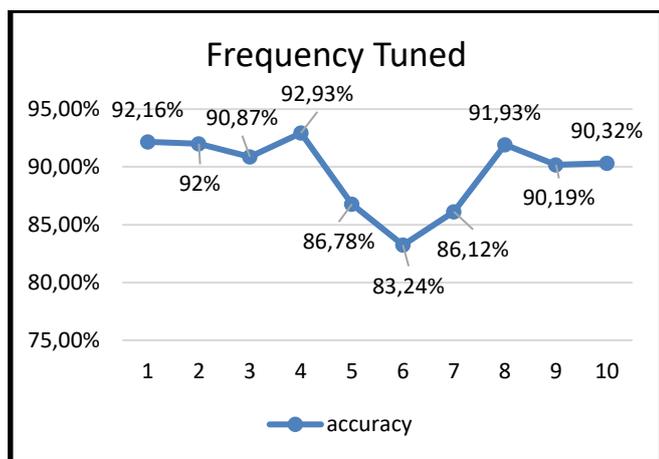
Gambar 10. Hasil klasifikasi CNN pada citra RC



Gambar 11. Hasil klasifikasi CNN pada citra HC



Gambar 12. Hasil klasifikasi CNN pada citra SR



Gambar 13. Hasil klasifikasi CNN pada citra FT

TABEL I
HASIL KLASIFIKASI CNN PADA SEMUA SKENARIO

Kategori	Accuracy
Tanpa Saliency	95,06%
Region Contrast Saliency	62,67%
Frequency-Tuned Saliency	90,32%
Histogram Contrast Saliency	79,06%
Spectral Residual Saliency	50,00%

C. Analisis Hasil Pengujian

Dari hasil penelitian yang dilakukan pada 5 skenario dengan 4 jenis saliency yang berbeda, didapatkan accuracy yang dapat dilihat pada Tabel 1.

Pada Tabel 1 didapatkan bahwa metode saliency tidak dapat meningkatkan accuracy pada CNN dengan dataset sel darah. Hal ini dikarenakan metode saliency mengambil bagian yang bermakna pada gambar, tetapi pada sel yang tidak berparasit tidak memiliki bagian yang lebih bermakna dari bagian yang lain yang menyebabkan penurunan accuracy sehingga hasilnya tidak optimal. Berdasarkan hasil pengujian juga didapat

metode saliency yang paling baik dalam mendeteksi penyakit malaria adalah frequency-tuned dengan accuracy sebesar 90,32%. Region contrast saliency memiliki accuracy yaitu sebesar 62,67%. Metode yang paling buruk untuk mendeteksi penyakit malaria adalah spectral residual saliency yang memiliki accuracy yang paling rendah dibandingkan dengan metode saliency lain yaitu sebesar 50,00%. Metode histogram contrast saliency memiliki nilai accuracy yang cukup baik yaitu sebesar 79,06%. Metode tanpa saliency memiliki akurasi yang paling tinggi dibandingkan dengan metode saliency dengan nilai akurasi sebesar 95,06%.

IV. PENUTUP

Hasil pengujian menunjukkan bahwa metode region contrast saliency, frequency-tuned saliency, spectral residual saliency, dan histogram contrast saliency tidak dapat meningkatkan akurasi convolutional neural network pada kasus pendeteksian penyakit malaria pada dataset sel darah. Berdasarkan pengujian pada 5 skenario yang dilakukan didapatkan urutan metode saliency dari yang terbaik ke terburuk adalah frequency-tuned saliency, histogram contrast saliency, region contrast saliency, dan spectral residual saliency. Frequency-tuned saliency mampu mendeteksi parasit malaria dengan lebih baik dibandingkan dengan metode saliency lainnya.

DAFTAR PUSTAKA

- [1] L. Hakim, "Malaria Epidemiology and Diagnostic," *Aspirator J. Vector Borne Dis. Stud.*, vol. 3, no. 2, hal. 107–116, 2011, doi: 10.22435/aspirator.v3i2.2965.
- [2] D. R. Anamisa, "Rancang Bangun Metode OTSU Untuk Deteksi Hemoglobin," *S@Cies*, vol. 5, no. 2, hal. 106–110, 2015, doi: 10.31598/sacies.v5i2.64.
- [3] C. Mehanian dkk., "Computer-Automated Malaria Diagnosis and Quantitation Using Convolutional Neural Networks," *Proc. - 2017 IEEE Int. Conf. Comput. Vis. Work. ICCVW 2017*, hal. 116–125, 2017, doi: 10.1109/ICCVW.2017.22.
- [4] I. R. Dave, "Image Analysis For Malaria Parasite Detection From Microscopic Images of Thick Blood Smear," *Proc. 2017 Int. Conf. Wirel. Commun. Signal Process. Networking, WiSPNET 2017*, hal. 1303–1307, 2018, doi: 10.1109/WiSPNET.2017.8299974.
- [5] A. Nanoti, S. Jain, C. Gupta, dan G. Vyas, "Detection of Malaria Parasite Species and Life Cycle Stages Using Microscopic Images of Thin Blood Smear," *Proc. Int. Conf. Inven. Comput. Technol. ICICT 2016*, vol. 1, 2016, doi: 10.1109/INVENTIVE.2016.7823258.
- [6] F. Z. Rahmanti, H. A. Santoso, P. wahyu Adi, ketut E. Purnama, dan M. H. Purnomo, "LVQ (Learning Vector

- Quantization) Method for Identification of Plasmodium Vivax in Thick Blood Film,” *ICBETA*, 2014.
- [7] S. C. Kalkan dan O. K. Sahingoz, “Deep Learning Based Classification of Malaria From Slide Images,” *2019 Sci. Meet. Electr. Biomed. Eng. Comput. Sci. EBBT 2019*, hal. 1–4, 2019, doi: 10.1109/EBBT.2019.8741702.
- [8] M. Zufar dan B. Setiyono, “Convolutional Neural Networks Untuk Pengenalan Wajah Secara Real-Time,” *J. Sains dan Seni ITS*, vol. 5, no. 2, hal. 72–77, 2016, doi: 10.12962/j23373520.v5i2.18854.
- [9] Z. Liang *dkk.*, “CNN-based Image Analysis For Malaria Diagnosis,” *Proc. - 2016 IEEE Int. Conf. Bioinforma. Biomed. BIBM 2016*, hal. 493–496, 2017, doi: 10.1109/BIBM.2016.7822567.
- [10] W. D. Pan, Y. Dong, dan D. Wu, “Classification of Malaria-Infected Cells Using Deep Convolutional Neural Networks,” *Mach. Learn. - Adv. Tech. Emerg. Appl.*, 2018, doi: 10.5772/intechopen.72426.
- [11] N. Jmour, S. Zayen, dan A. Abdelkrim, “Convolutional Neural Networks For Image Classification,” *2018 Int. Conf. Adv. Syst. Electr. Technol. IC_ASET 2018*, hal. 397–402, 2018, doi: 10.1109/ASET.2018.8379889.
- [12] M. M. Cheng, N. J. Mitra, X. Huang, P. H. S. Torr, dan S. M. Hu, “Global Contrast Based Salient Region Detection,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 37, no. 3, hal. 569–582, 2015, doi: 10.1109/TPAMI.2014.2345401.
- [13] G. Zeng, “Fruit and Vegetables Classification System Using Image Saliency and Convolutional Neural Network,” *Proc. 2017 IEEE 3rd Inf. Technol. Mechatronics Eng. Conf. ITOEC 2017*, hal. 613–617, 2017, doi: 10.1109/ITOEC.2017.8122370.
- [14] D. S. Ferreira *dkk.*, “Saliency-driven System Models For Cell Analysis With Deep Learning,” *Comput. Methods Programs Biomed.*, vol. 182, hal. 1–13, 2019, doi: 10.1016/j.cmpb.2019.105053.
- [15] A. M. Obeso, J. Benois-Pineau, K. Guissous, V. Gouet-Brunet, M. S. Garcia Vazquez, dan A. A. Ramirez Acosta, “Comparative Study of Visual Saliency Maps in the Problem of Classification of Architectural Images With Deep CNNs,” *2018 8th Int. Conf. Image Process. Theory, Tools Appl. IPTA 2018 - Proc.*, 2019, doi: 10.1109/IPTA.2018.8608125.
- [16] S. Rajaraman *dkk.*, “Pre-trained convolutional neural networks as feature extractors toward improved malaria parasite detection in thin blood smear images,” *PeerJ*, hal. 1–17, 2018, doi: 10.7717/peerj.4568.
- [17] X. Hou dan L. Zhang, “Saliency Detection: A Spectral Residual Approach,” *IEEE Conf. Comput. Vis. Pattern Recognit.*, hal. 1063–6919, 2007, doi: 10.1109/CVPR.2007.383267.
- [18] R. Achanta, S. Hemami, F. Estrada, dan S. S`usstrunk, “Frequency-tuned Salient Region Detection,” *IEEE Conf. Comput. Vis. Pattern Recognit.*, hal. 1063–6919, 2009, doi: 10.1109/CVPR.2009.5206596.
- [19] A. Trask, *Grokking Deep Learning*. Shelter Island, New York, United States: Manning Publications, 2019.
- [20] J. P. Mueller dan L. Massaron, *Deep Learning For Dummies*. United States: For Dummies, 2019.
- [21] I. Vasilev, D. Slater, G. Spacagna, P. Roelants, dan V. Zocca, *Python Deep Learning: Exploring Deep Learning Techniques and Neural Network Architectures With PyTorch, Keras, and TensorFlow*. Birmingham, United Kingdom: Packt Publishing, 2019.
- [22] Suyanto, *Machine Learning: Tingkat Dasar dan Lanjut*. Bandung: Informatika, 2018.