

# Klasifikasi Eritrosit Pada Thalasemia Minor Menggunakan Fitur Konvolusi dan Multi-Layer Perceptron

Zuhrufun Nufusy Nugroho<sup>\*1</sup>, Agus Harjoko<sup>2</sup>, Muhammad Auzan<sup>3</sup>

<sup>1</sup>Program Studi Elektronika dan Instrumentasi, FMIPA UGM, Yogyakarta, Indonesia

<sup>2,3</sup>Departemen Ilmu Komputer dan Elektronika, FMIPA UGM, Yogyakarta, Indonesia

e-mail: <sup>\*1</sup>zuhrufunnufusy@mail.ugm.ac.id, <sup>2</sup>aharjoko@ugm.ac.id,

<sup>3</sup>muhammad.auzan@mail.ugm.ac.id

## Abstrak

Kelainan darah thalassemia merupakan kondisi yang dapat mempengaruhi kemampuan darah untuk berfungsi dengan normal dan dapat mengakibatkan eritropoiesis. Pada kelainan darah ini, terdapat sembilan jenis sel eritrosit abnormal yaitu eliptosit, pensil, teardrop, akantosit, stomatosit, target, sferosit, hipokromik dan normal. Pada saat ini, pemeriksaan thalassemia dilakukan menggunakan elektroforesis Hb dan dilakukan secara manual sehingga akan bersifat subjektif dan membutuhkan waktu lama. Oleh karena itu, penelitian ini mengimplementasikan algoritma Convolutional Neural Network (CNN) dan Multi-Layer Perceptron (MLP). Penelitian ini bertujuan untuk mengetahui performa fitur konvolusi sebagai ekstraksi fitur citra dan MLP sebagai metode klasifikasi citra lalu diimplementasikan pada NVIDIA Jetson Nano. Fitur konvolusi yang digunakan pada penelitian ini menerapkan arsitektur CNN VGG16. Kemudian dilakukan pembelajaran model pada 7245 data dengan mengkonfigurasi hyperparameter. Akurasi terbaik dengan konfigurasi hyperparameter berupa batch yaitu 16, epoch yaitu 400, learning rate yaitu 0,0001, lapisan dropout1 yaitu 0.1 dan lapisan dropout2 yaitu 0,1. Dari konfigurasi tersebut menghasilkan akurasi optimal pada 96,175%. Berikut, model yang telah dibuat selanjutnya diimplementasikan pada NVIDIA Jetson Nano sebagai media mobile untuk diterapkan pada dunia medis menghasilkan kecepatan prediksi rata-rata tiap kelas yaitu 48,330 detik. Perolehan waktu performa dan akurasi tersebut layak untuk digunakan oleh tenaga medis untuk memprediksi kelas pada sel eritrosit abnormal.

**Kata kunci**— thalassemia, fitur konvolusi, CNN VGG16, MLP, Jetson Nano

## Abstract

Thalassemia blood disorder is a condition that can affect the blood's ability to function normally and can lead to erythropoiesis. In this blood disorder, there are nine types of abnormal erythrocytes, namely elliptocytes, pencils, teardrops, acanthocytes, stomatocytes, targets, spherocytes, hypochromic and normal. At present, thalassemia examination is carried out using Hb electrophoresis and is done manually so it will be subjective and take a long time. Therefore, this research implements the Convolutional Neural Network (CNN) and Multi-Layer Perceptron (MLP) algorithms. This study aims to determine the performance of convolution features as image feature extraction and MLP as an image classification method and then implemented on NVIDIA Jetson Nano. The convolution features used in this study apply the CNN VGG16 architecture. Then model learning is carried out on 7245 data by configuring hyperparameters. The best accuracy with the hyperparameter configuration is a batch that is 16, the epoch is 400, the learning rate is 0.0001, the dropout1 layer is 0.1 and the dropout2 layer is 0.1. From this configuration it produces optimal accuracy at 96.175%. In the following, the model that has been made is then implemented on the NVIDIA Jetson Nano as a mobile

*media to be applied to the medical world resulting in an average prediction speed for each class of 48.330 seconds. The obtained performance time and accuracy are suitable for use by medical personnel to predict the class of abnormal erythrocytes.*

**Keywords**— *thalassemia, convolution features, CNN VGG16, MLP, Jetson Nano*

## 1. PENDAHULUAN

Kelainan darah merupakan kondisi yang dapat mempengaruhi kemampuan darah untuk berfungsi dengan normal. [1] Salah satu contoh kelainan darah yaitu thalassemia yang mampu mempengaruhi gen hemoglobin dan mengakibatkan eritropoiesis yang dihasilkan dari penurunan sintesis rantai alfa atau beta hemoglobin (Hb). [2]

Pemeriksaan penyakit thalassemia dapat dilakukan dengan elektroforesis untuk memisahkan hemoglobin normal dan abnormal. Jumlah hemoglobin dalam aliran darah yang terukur dapat menunjukkan potensi penyakit thalassemia. [3] Selain itu pemeriksaan dapat dilakukan secara visual dari sampel darah menggunakan mikroskop untuk dianalisis. Proses pemeriksaannya masih dilakukan secara manual sehingga memakan waktu dan cenderung subjektif. Untuk mempercepat proses pemeriksaan dapat dibantu dengan teknologi pengolahan citra digital sehingga dapat mempercepat waktu pemeriksaan dan menghindari subjektivitas [4]

Pengolahan citra digital merupakan teknologi yang telah diterapkan pada beberapa kasus medis contohnya pada diagnosa diabetes, kanker payudara, rheumatoid arthritis, abnormalitas darah merah, dsb. Sepertihalnya, penelitian yang dilakukan oleh Tyas et al., (2022) dalam pengklasifikasian tipe sel eritrosit pada penyakit thalassemia terdapat dataset berupa sembilan tipe sel yang dikelompokkan menjadi: sel eliptosit, sel pensil, sel tetesan air mata, sel akantosit, sel stomatosit, sel target, sel sperosit, sel hipokromik, sel normal. Untuk membedakan setiap objek tipe sel, diperlukan ekstraksi fitur. Fitur yang dapat diekstraksi dari eritrosit yaitu bentuk, tekstur dan warna. [5] Pada penelitian sebelumnya yang dilakukan Tyas et al., (2020) memerlukan beberapa metode ekstraksi fitur, yaitu momen invarian, parameter geometrik, dan distance angle signature (DAS) sebagai metode ekstraksi ciri bentuk, dan gray level co-occurrence matrices (GLCM) sebagai metode ekstraksi ciri tekstur serta menggunakan mean, standar deviasi, skewness, dan kurtosis dari nilai piksel saluran hijau sebagai fitur warna. [6]

Beberapa penelitian mengenai machine learning sebagai metode pengklasifikasian yang optimal telah dilakukan. Klasifikasi eritrosit dengan metode machine learning yang telah digunakan berupa CNN, SVM, deep learning, Naïve Bayes classifier, MLP and RBF Network. Penelitian yang dilakukan oleh (Tyas et al., 2020) membandingkan metode klasifikasi antaran MLP, Naïve Bayes Classifier, RBF Network dan SVM. Hasil perbandingan akurasi, menunjukkan MLP memiliki akurasi yang lebih unggul dengan nilai 89,6%. [6] Demikian dengan penelitian (Chihang Zhao et al., 2011) membuktikan MLP memiliki keunggulan dalam akurasi dibanding dengan naive Bayes classifier, subspace classifier, dan k-NN. [7] Perkembangan machine learning didukung dengan kehadiran perangkat yang dirancang khusus untuk proyek jaringan syaraf tiruan dan AI yaitu NVIDIA Jetson Nano yang bersifat compact sehingga efektif untuk keperluan mobilitas terutama dalam bidang medis. Oleh karenanya peneliti tertarik untuk mengembangkan dari penelitian sebelumnya terkait MLP dalam metode klasifikasi tipe eritrosit pada thalassemia dan ekstraksi fitur menggunakan CNN dan diimplementasikan pada perangkat Jetson Nano.

## 2. METODE PENELITIAN

### 2.1 Gambaran Umum Klasifikasi Citra Eritrosit

Klasifikasi citra machine learning citra eritrosit adalah sebuah teknologi untuk membedakan tiap kelas yang memiliki bentuk abnormal. Pada penelitian ini terdiri dari

sembilan kelas, yaitu sel eliptosit, sel tetesan air mata, sel akantosit, sel stomatosit, sel target, sel sferosit, sel pensil, sel hipokromik dan sel normal. Proses klasifikasi memanfaatkan metode MLP dan fitur konvolusi pada tahapan ekstraksi fitur.

## 2.2 Analisis Sistem

Penelitian ini akan membuat sebuah algoritma untuk mengklasifikasikan tipe sel darah dari sampel darah pasien thalassemia menggunakan CNN pada tahapan ekstraksi fitur pada citra dan MLP untuk tahapan klasifikasi. Akuisisi data diperoleh dari sampel darah dalam RGB dari Departemen Patologi Klinik dan Kedokteran Laboratorium, Fakultas Kedokteran, Keperawatan dan Kesehatan Masyarakat, Universitas Gadjah Mada (UGM). Data kemudian dilakukan tahapan pre-processing, selanjutnya yaitu tahapan ekstraksi fitur dengan algoritma fitur konvolusi dengan arsitektur CNN VGG16 untuk mendapatkan perbedaan karakteristik citra untuk selanjutnya ditraining dengan algoritma MLP. Sistem klasifikasi yang sudah dibuat, lalu diimplementasikan pada perangkat NVIDIA Jetson Nano.

## 2.3 Peralatan Pendukung

Peralatan yang digunakan yaitu laptop sebagai perangkat pengembangan sistem. Perangkat keras merupakan perangkat utama untuk menjalankan perangkat lunak. dalam penelitian ini.

### 2.3.1 Perangkat Keras

Perangkat keras yang digunakan pada penelitian ini berperan dalam proses pelatihan dan pengujian sistem. *Personal Computer* (PC) berperan dalam pelatihan sistem memiliki spesifikasi prosesor Intel® Core™ i5-10400F CPU @ 2.90GHz × 12, grafik NVIDIA GeForce GTX 1660 SUPER, RAM 16,0 GiB dan OS Ubuntu 22,04 LTS. Sedangkan perangkat pengujian yaitu NVIDIA Jetson Nano dengan spesifikasi prosesor Quad-core ARM A57 @ 1.43 GHz, grafik 128-core Maxwell, RAM 4 GB 64-bit LPDDR4 25.6 GB/s dan OS Ubuntu 18,04 LTS.

### 2.3.2 Perangkat Lunak

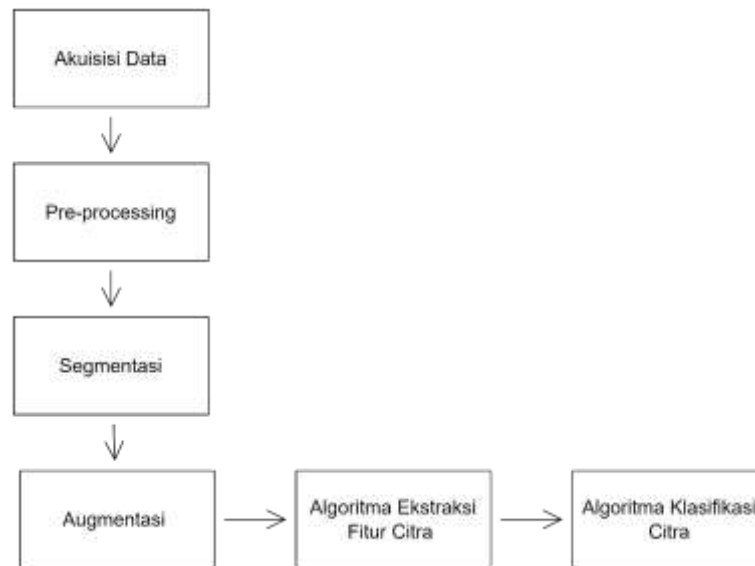
Perangkat lunak berperan dalam tahapan *pre-processing*, pelatihan dan pengujian sistem. Spesifikasi perangkat lunak yang digunakan yaitu Python 3.10.6, Tensorflow 2.9.0, Keras 2.2.4.1, Nvidia Driver 515.86.01, CUDNN 8.5.0.96 + CUDA11.7, Numpy 1.24.0, OpenCV 4.7.0, Matplotlib 3.6.3.

## 2.4 Akuisisi Data

Data yang digunakan dalam penelitian ini merupakan data sekunder dari pasien penderita thalassemia dan pasien sehat. Proses akuisisi data dilakukan menggunakan kamera Optilab Advance Plus dan mikroskop Olympus CX2. Citra objek sel darah diambil dengan perbesaran 1000x dari lensa objektif minyak imersi (100x) yang dikombinasikan dengan lensa okuler 10x. Resolusi gambar asli adalah  $4100 \times 3075$  piksel (gambar RGB). Setelah dilakukan akuisisi data, lalu citra diresize ukuran untuk mengurangi beban komputasi. [5]

## 2.5 Pelatihan Sistem

Proses awal dalam pengklasifikasian citra yaitu pengambilan citra sampel darah sebagai dataset. Gadjah Mada (UGM). Tahapan selanjutnya yaitu pre-processing, yaitu dengan konversi citra dalam grayscale, transformasi morfologi, augmentasi dan standardisasi citra. Selanjutnya yaitu tahapan ekstraksi fitur pada sistem dilakukan dengan metode CNN. Tahapan akhir yaitu klasifikasi citra dalam sembilan kelas menggunakan metode MLP (Multi-Layer Perceptron). Diagram blok rancangan pelatihan sistem sebagai berikut pada Gambar 1.



Gambar 1 Tahapan Pelatihan Sistem

## 2.6 Implementasi Akuisisi Data

Akuisisi data digunakan untuk mendapatkan data sehingga data dapat diproses pada algoritma CNN dan MLP. Dataset pada penelitian adalah data yang telah terdahulu digunakan pada penelitian yang dilakukan oleh Tyas et al. pada tahun 2019.

Penyortiran dilakukan secara manual untuk mengklasifikasikan citra sel darah merah tunggal berdasarkan jenisnya. Ada sembilan jenis sel yang dikumpulkan dalam dataset RBC: sel eliptosit, sel pensil, sel tetesan air mata, sel akantosit, sel stomatosit, sel target, sferosit, sel hipokromik, sel normal. Resolusi sel darah merah tunggal sangat bervariasi [5]. Dataset yang digunakan pada pelatihan model dibagi menjadi tiga jenis dataset, yaitu data training, data validation dan data testing.

## 2.7 Implementasi Augmentasi Data

Augmentasi merupakan tahapan pra-pemrosesan dengan memodifikasi atau memanipulasi data untuk memperbanyak data sehingga performa model akan meningkat. Augmentasi bertujuan untuk menambah citra data latih sebelum diproses pada algoritma CNN. Pada penelitian ini, augmentasi dengan melakukan vertical flip, horizontal flip, pengubahan brightness, dan mengubah citra menjadi blur.

## 2.8 Implementasi Normalisasi Data

Normalisasi data citra digunakan untuk menyamakan dan menstandarkan ukuran citra pada folder dataset sebelum diolah pada algoritma CNN. Tujuan dari dilakukan normalisasi yaitu data citra yang akan diproses memiliki spesifikasi yang sama. Tahap normalisasi citra dalam penelitian ini menggunakan *library* dari Tensorflow. *Resizing* dilakukan dengan mengubah ukuran dan dimensi citra yang berbeda-beda menjadi seragam dengan mengubah ukuran dan menambahkan padding diluar citra yang menjadi *background* citra.

## 2.9 Implementasi Ekstraksi Fitur Citra

Ekstraksi fitur pada penelitian ini memanfaatkan layer konvolusi dari algoritma CNN. Library yang digunakan yaitu tensorflow yang membuat susunan arsitektur VGG16. Arsitektur ini termasuk dalam deep CNN yang dikembangkan untuk meningkatkan kedalaman CNN untuk meningkatkan performa.

### 2.10 Implementasi Klasifikasi Citra

*Feature map* yang telah didapatkan dari proses ekstraksi fitur di layer konvolusi lalu di-*reshape* dari *array* multidimensional menjadi sebuah *vector*. Pada lapisan *fully-connected layer* merupakan metode *Multi-Layer Perceptron*. Pada lapisan ini terjadi proses pengolahan data sehingga dapat diklasifikasikan. Arsitektur yang digunakan untuk klasifikasi citra merupakan arsitektur *Multi-Layer Perceptron* (MLP) yang terdiri atas tiga layer, yaitu *input layer*, *hidden layer*, dan *output layer*. Banyaknya jumlah *layer* pada arsitektur MLP ini mengikuti dengan arsitektur VGG16 yang terdiri dari 13 *convolutional layer* dan 3 *fully connected layer* dengan fungsi aktivasi berupa ReLu[8].

### 2.11 Validasi dan Testing Data

Pengujian performa sebuah model dapat dilakukan menggunakan *confusion matrix* yang mana matriks ini akan menampilkan jumlah data yang diklasifikasikan benar ataupun salah. Tahapan ini disebut juga simulasi penggunaan model machine learning di dunia nyata sebab data yang digunakan pada proses pengujian ini merupakan data diluar data training dan data validasi.

```

===== CONFUSION MATRIX =====
[[ 36  0  0  1  0  0  0  0  0]
 [  0 117  6  1  0  0  2  0  2]
 [  0  0 22  1  0  0  0  0  0]
 [  1  1  4 136  0  0  1  0  0]
 [  0  0  0  0 17  0  0  0  0]
 [  0  0  0  1  0 56  0  0  0]
 [  0  4  0  4  0  0 30  1  0]
 [  0  0  0  0  0  0  3 82  1]
 [  0  0  0  0  0  0  0  0 208]]
  
```

Gambar 1 Cuplikan Hasil Confusion Matrix

```

Akurasi = 0.9617486338797814
Precision = 0.947739420899718
Recall = 0.9494150375855168
f1-score = 0.9480098312059331
  
```

Gambar 2 Cuplikan Hasil Pelatihan Model

### 2.12 Pengujian pada Jetson Nano

Algoritma klasifikasi yang telah dibuat, lalu disimpan dalam bentuk model dengan format h5. Format data h5 merupakan salah satu Format Data Hierarkis (HDF) yang digunakan untuk menyimpan data dalam jumlah besar. Format ini digunakan untuk menyimpan data dalam bentuk *array* multidimensi. Model ini nantinya dapat mempermudah pengguna untuk menggunakan algoritma tanpa perlu melakukan training yang mana waktu yang diperlukan untuk training tentu tidak sebentar

## 3. HASIL DAN PEMBAHASAN

### 3.1 Hasil Normalisasi Citra

Berdasarkan hasil normalisasi, ukuran yang dihasilkan setelah proses normalisasi adalah seragam, yaitu 60 piksel x 60 piksel. Channel ruang warna yang dimiliki citra juga diubah dari L dimana gambar tersebut memiliki channel warna tunggal atau disebut juga dengan *grey scale* yang artinya hanya menyimpan *Luminance*, menjadi citra dengan ruang warna RGB

### 3.2 Proses Tuning Sistem

Setelah dilakukan normalisasi ukuran, selanjutnya dataset citra displit untuk memisahkan antara data untuk pelatihan, validasi dan pengujian. Rasio yang digunakan pada penelitian ini yaitu 7:2:1.

Pada sistem ini, terdapat beberapa *hyperparameter* yang dapat di-*tuning* sehingga penulis mendapatkan nilai optimal pada setiap *hyperparameter*. *Hyperparameter* yang dilakukan *tuning* antaralain, nilai *batch*, *epochs*, *learning rate*, dan *dropout* untuk mendapatkan *global optima*. Tuning dilakukan secara sequensial, yaitu dengan melakukan tuning pada nilai

batch. Setelah mendapatkan nilai akurasi terbaik dari tuning batch, lalu batch tersebut ditetapkan untuk tuning pada nilai *epoch*. Begitu seterusnya hingga tuning *learning rate* dan *layer dropout*. Pada penelitian ini metrics yang digunakan adalah metrik akurasi sebab metrik akurasi menjalankan performa model di semua kelas ketika semua kelas sama pentingnya.

Tabel 1 Hasil Tuning Batch

Batch	Akurasi
8	94,945%
16	95,902%
32	93,989%
64	90,027%
128	87,842%



Gambar 3 Grafik Tuning Batch Size

Tabel 2 Hasil Tuning Epoch

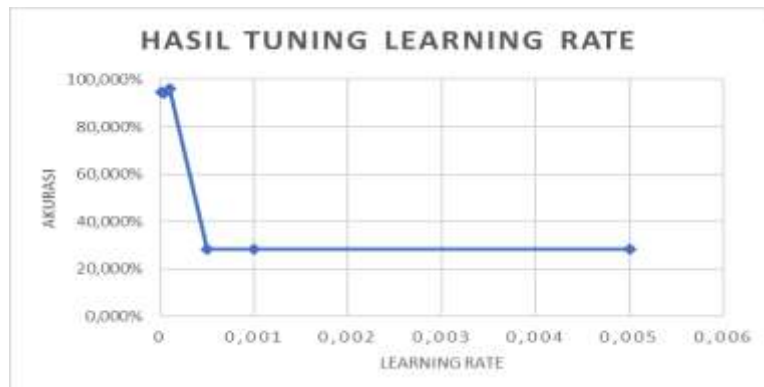
Epochs	Akurasi
100	95,902%
200	94,809%
300	95,355%
400	96,175%
500	94,536%



Gambar 4 Grafik Tuning Epoch

Tabel 3 Hasil Tuning Learning Rate

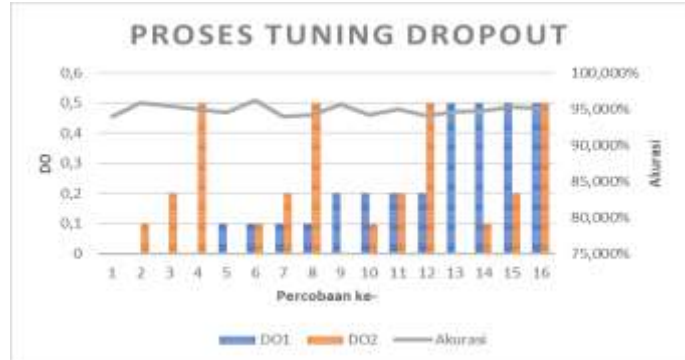
Learning Rate	Akurasi
0,00001	94,672%
0,00005	94,262%
0,0001	96,175%
0,0005	28,415%
0,001	28,415%
0,005	28,415%



Gambar 5 Grafik Tuning Learning Rate

Tabel 4 Hasil Tuning Dropout

Dropout 1	Dropout 2	Akurasi
0	0	95,219%
0	0,1	95,902%
0	0,2	95,492%
0	0,5	95,082%
0,1	0	94,536%
0,1	0,1	96,175%
0,1	0,2	94,809%
0,1	0,5	94,262%
0,2	0	95,628%
0,2	0,1	94,262%
0,2	0,2	95,628%
0,2	0,5	94,945%
0,5	0	94,672%
0,5	0,1	96,038%
0,5	0,2	95,355%
0,5	0,5	95,082%



Gambar 6. Grafik Tuning Dropout

Berdasarkan percobaan yang telah dilakukan, banyaknya *batch* yang menghasilkan nilai akurasi paling maksimum yaitu *batch* = 16 dengan nilai akurasi mencapai 95,902% dan akurasi yang dihasilkan sudah stabil. Pada percobaan *tuning epoch*, didapatkan bahwa nilai *epoch* = 400 mencapai akurasi maksimal. Nilai *epoch* akan berpengaruh pada akurasi model namun semakin banyak nilai *epoch*, belum tentu akan meningkatkan akurasi. Dengan kata lain bahwa semakin banyak nilai *epoch* tidak berbanding lurus dengan kenaikan akurasi. Dari pengujian yang telah dilakukan, nilai learning rate yang paling optimum untuk sistem klasifikasi ini adalah 0.0001 dengan perolehan akurasi 96,175%. Hal ini dikarenakan semakin besar nilai learning rate, proses pembelajaran akan cepat namun ketelitian model untuk akan semakin berkurang sehingga akurasi yang dihasilkan akan rendah. Sedangkan semakin kecil nilai learning rate, maka membutuhkan waktu training yang lebih lama atau membutuhkan epoch yang besar. Hasil dari percobaan yang dilakukan dengan memvariasikan nilai DO1 dan DO2 dengan nilai 0, 0.1, 0.2 dan 0.5 menghasilkan nilai akurasi training dan akurasi validasi yang cenderung stagnan. Sehingga, dapat disimpulkan bahwa akurasi tertinggi dicapai ketika DO1 = 0.1 dan DO2 = 0.1 yaitu sebesar 96,175%.

### 3.3 Analisa Kecepatan Komputasi

Analisa pada penelitian ini yaitu membandingkan antara kecepatan komputasi pengujian ketika diuji pada Personal Computer (PC) dan NVIDIA Jetson Nano Developer Kit B01 4GB. Pengujian dilakukan menggunakan data *test* berupa sel *teardrop* seperti pada Gambar 7. Hasil kecepatan komputasi dapat dilihat pada Gambar 8 dan Gambar 9.



Gambar 7 Sel Teardrop

```
Predicted Class: teardrop
--- waktu testing = 0.4215238094329834 detik ---
```

Gambar 8 Hasil Deteksi Sel Darah dengan PC

```
there could be performance gains if more memory we
Predicted Class: teardrop
--- waktu load = 18.306220769882202 detik ---
--- waktu testing = 51.49512767791748 detik ---
```

Gambar 9 Hasil Deteksi Sel Darah dengan NVIDIA Jetson Nano

Berdasarkan pengujian yang telah dilakukan, rata-rata waktu komputasi yang digunakan untuk deteksi kelas eritrosit pada thalassemia minor menggunakan personal computer (PC) menghasilkan kecepatan 0,181 detik untuk memprediksi kelas suatu sel citra eritrosit abnormal termasuk pada semua kelas. Sedangkan, rata-rata waktu komputasi yang digunakan untuk deteksi kelas eritrosit pada thalassemia minor menggunakan NVIDIA Jetson Nano yaitu 48,330 detik. Hal ini dapat disimpulkan bahwa PC lebih cepat dibandingkan dengan Jetson Nano hal ini dikarenakan adanya perbedaan TDP (Thermal Design Power) antara GPU pada PC dan Jetson Nano. GPU pada PC (NVIDIA GTX 1660S) memiliki TDP 125 watt. Sedangkan Jetson Nano (NVIDIA Tegra X1) memiliki TDP 10 watt. Namun bila dibandingkan dengan sekelasnya, NVIDIA Jetson Nano Developer Kit B01 4GB memiliki CPU arsitektur ARM yang dilengkapi dengan Graphic Processing Unit (GPU) yang mana *Single Board Computer* (SBC) lain sekelasnya tidak dilengkapi dengan GPU seperti halnya raspberryPi. Keunggulan NVIDIA Jetson Nano yang dilengkapi GPU ini akan mempercepat proses yang pengolahan citra. Sehingga untuk pemrosesan untuk memprediksi kelas dari sel eritrosit abnormal, penggunaan Jetson Nano cukup bisa digunakan sebagai solusi untuk petangkat klasifikasi eritrosit abnormal pada thalassemia minor yang bersifat *mobile*. Perbandingan antara kecepatan prediksi kelas pada sel eritrosit abnormal dapat dilihat pada Tabel 5.

Tabel 5 Perbandingan Kecepatan Komputasi PC dan NVIDIA Jetson Nano

Kelas Sel	NVIDIA Jetson Nano RAM 4 GiB dan Grafik 128-core Maxwell (detik)	PC RAM 16 GiB dan Grafik NVIDIA GeForce GTX 1660 SUPER (detik)
Akantosit	47,756	0,135
Eliptosit	47,224	0,139
Hipokromik	47,222	0,137
Normal	47,183	0,136
Pensil	48,237	0,285
Sperosit	48,646	0,273
Stomatosit	48,534	0,133
Target	48,673	0,135
Teardrop	51,495	0,258



#### 4. KESIMPULAN

Berdasarkan penelitian mengenai klasifikasi eritrosit pada thalassemia minor menggunakan fitur konvolusi dan MLP yang telah dilakukan, kesimpulan yang dapat diambil adalah nilai parameter optimal CNN pada penelitian ini yaitu batch = 16, epoch = 400, -learning rate = 0.0001, dan nilai pada lapisan dropout setelah dense layer pertama = 0.1 serta nilai pada lapisan dropout setelah dense layer kedua = 0.1. Arsitektur CNN yaitu VGG16 optimal untuk diimplementasikan sebagai arsitektur konvolusi pada model untuk menguji 732 citra uji yang terdiri dari sembilan kelas sel eritrosit abnormal dapat menghasilkan akurasi = 96,175%. Dari penelitian sebelumnya yang dilakukan oleh Tyas et al., 2020, menghasilkan akurasi 98,11% sedangkan pada penelitian ini menghasilkan akurasi 96,175%.

NVIDIA Jetson Nano cukup baik digunakan sebagai media pengimplementasian yang bersifat mobile untuk sistem klasifikasi eritrosit abnormal pada thalassemia minor dengan waktu pemrosesan prediksi rata-rata setiap kelas = 48,330 detik.

#### 5. SARAN

Saran-saran yang disampaikan untuk pengembangan penelitian selanjutnya adalah mengembangkan algoritma CNN diikuti dengan algoritma ekstraksi fitur lainnya, untuk mendukung kinerja algoritma tersebut dan mempertimbangkan pemilihan arsitektur CNN lain untuk pengoptimalan pengambilan fitur selama proses konvolusi.

#### UCAPAN TERIMA KASIH

Bagian ini bersifat opsional. Apabila ada, maka ucapan terimakasih ditujukan kepada **institusi** yang telah memberi “**dukungan financial**” terhadap penelitian ini.

#### DAFTAR PUSTAKA

- [1] Huizen, “What types of blood disorders are there?,” Jun. 2018, [Online]. Available: <https://www.medicalnewstoday.com/articles/263489>
- [2] H. Bajwa and H. Basit, “Thalassemia,” *StatPearls Internet*, Aug. 2022, [Online]. Available: <https://www.ncbi.nlm.nih.gov/books/NBK545151/?report=reader>
- [3] F. Rizal Makarim, “Minor atau Mayor, Mana Thalassemia yang Paling Parah?,” *halodoc*, Desember 2019, [Online]. Available: <https://www.halodoc.com/artikel/minor-atau-mayor-mana-thalassemia-yang-paling-parah>
- [4] D. A. Tyas, S. Hartati, A. Harjoko, and T. Ratnaningsih, “Erythrocyte Classification using Multi Layer Perceptron, Naïve Bayes Classifier, RBF Network and SVM,” *Int. J. Eng. Adv. Technol.*, vol. 9, no. 2, pp. 2024–2028, Dec. 2019, doi: 10.35940/ijeat.B3231.129219.
- [5] D. A. Tyas, T. Ratnaningsih, A. Harjoko, and S. Hartati, “Erythrocyte (red blood cell) dataset in thalassemia case,” *Data Brief*, vol. 41, p. 107886, Apr. 2022, doi: 10.1016/j.dib.2022.107886.
- [6] D. A. Tyas, S. Hartati, A. Harjoko, and T. Ratnaningsih, “Morphological, Texture, and Color Feature Analysis for Erythrocyte Classification in Thalassemia Cases,” *IEEE Access*, vol. 8, pp. 69849–69860, 2020, doi: 10.1109/ACCESS.2020.2983155.
- [7] Chihang Zhao, Jie He, Tiantian Zhu, Jie Lian, Jing Shen, and Hongjuan Zhang, “Recognition of driver’s fatigue expressions by Gabor wavelet transform and Multilayer

- Perceptron classifier,” in *Proceedings 2011 International Conference on Transportation, Mechanical, and Electrical Engineering (TMEE)*, ChangChun, China, Dec. 2011, pp. 617–620. doi: 10.1109/TMEE.2011.6199279.
- [8] R. J. Gunawan, B. Irawan, and C. Setianingsih, “PENGENALAN EKSPRESI WAJAH BERBASIS CONVOLUTIONAL NEURAL NETWORK DENGAN MODEL ARSITEKTUR VGG16”.