

KLASIFIKASI PENYAKIT ANEMIA BERBASIS CITRA PALPEBRAL KONJUNGTTIVA DENGAN ALGORITMA TRANSFER LEARNING

Elva Amalia¹, Mustari Lamada², Andi Baso Kaswar³, Dyah Darma Andayani^{4*}

¹Program Studi Teknik Komputer, Universitas Negeri Makassar
elvaamaliaaa@gmail.com

²Program Studi Pendidikan Teknik Informatika dan Komputer, Universitas Negeri Makassar
mustarilamada@unm.ac.id

³Program Studi Teknik Komputer, Universitas Negeri Makassar
a.baso.kaswar@unm.ac.id

⁴Program Studi Pendidikan Teknik Informatika dan Komputer, Universitas Negeri Makassar
dyahdarma@unm.ac.id

ABSTRAK

Anemia merupakan masalah kesehatan yang ditandai dengan kekurangan kadar hemoglobin. Kemungkinan terburuk dari penyakit anemia adalah kematian. Anemia sangat sering disepelekan masyarakat sehingga menjadi permasalahan dunia. Wanita lebih rentan mengalami penyakit anemia. Berdasarkan prevalensi Dinas Kesehatan Republik Indonesia, sebagian besar wanita pada usia produktif dan wanita hamil mengalami anemia. Diagnosis anemia dapat dilakukan dengan mengambil sampel darah kemudian dilakukan uji laboratorium, atau sering disebut dengan pemeriksaan *invasive*. Seiring berjalannya waktu, berbagai metode *non-invasive* yang lebih praktis dikembangkan untuk mendeteksi penyakit anemia sebagai alternatif seperti pemeriksaan yang dilakukan dengan melihat tingkat kepucatan *konjungtiva* pada mata. Sehingga peneliti melakukan pengembangan dalam klasifikasi penyakit anemia secara *non-invasive* dengan menerapkan algoritma *Transfer Learning AlexNet* berbasis citra *palpebral konjungtiva*. Sebelum dataset *palpebral konjungtiva* melalui tahap *training* dilakukan augmentasi citra yang bertujuan untuk menghindari terjadinya *overfitting* atau *underfitting* akibat kekurangan data latih. Transfer learning yang digunakan yaitu model AlexNet yang diuji menggunakan *hyperparameter batch size* dan *epoch* berbeda. Model AlexNet menghasilkan performansi yang optimal yaitu akurasi 85% dengan waktu komputasi tahap *training* selama 16 menit 13 detik.

Kata Kunci: Anemia, *Convolutional Neural Network*, CNN, Klasifikasi, *Palpebral Konjungtiva*

CLASSIFICATION OF ANEMIA DISEASE BASED ON PALPEBRAL CONJUNCTIVA IMAGE USING TRANSFER LEARNING ALGORITHM

ABSTRACT

Anemia is a health problem characterized by a deficiency in hemoglobin levels. The worst possibility of anemia is death. Anemia is very frequently underestimated by society so it becomes a world problem. Women are more likely to have anemia. Based on the prevalence of the Health Office of the Republic of Indonesia, most women especially those who are in their productive age and pregnant have anemia. The diagnosis of anemia may be made by taking a blood sample and then conducting laboratory tests or often referred to as *invasive examinations*. Over time, various practical ways of *non-invasive* methods were developed to detect anemia as an alternative like a checkup by looking at the level of paleness in the conjunctiva eyes. So the researchers carried out the development of a *non-invasive* classification of anemia by applying the *Transfer Learning AlexNet* algorithm based on *palpebral conjunctival* images. Before the *palpebral conjunctival* dataset goes through the *training* stage, image augmentation is carried out which aims to avoid *overfitting* or *underfitting* due to a lack of training data. The transfer learning used is the AlexNet model which was tested using the different batch sizes and epoch hyperparameters. The AlexNet model produces optimal performance, namely 85% accuracy with a training stage computation time of 16 minutes and 13 seconds.

Keyword: Anemia, *Convolutional Neural Network*, Classification, *Palpebral Conjunctiva*

PENDAHULUAN

Anemia merupakan salah satu gangguan kesehatan dengan jumlah penderita yang cukup banyak. Anemia adalah masalah kesehatan yang menyebabkan penderitanya mengalami kelelahan, letih dan lesu sehingga akan berdampak pada kreativitas dan produktivitasnya [1]. Kadar hemoglobin pada darah seseorang dapat dijadikan salah satu parameter untuk mengetahui status anemia. Menurut World Health Organization, sekitar 42.6% wanita pada usia produktif dan 36.5% wanita hamil menderita anemia [2]. Di Indonesia sendiri angka kejadian anemia dapat dikatakan cukup tinggi. Berdasarkan data Riskesdas (Riset Kesehatan Dasar) pada tahun 2018, prevalensi anemia pada remaja sebesar 32% yang berarti 3-4 dari 10 remaja menderita anemia [3].

Penyakit anemia pada tubuh manusia dapat didiagnosis dengan cara mengambil sampel darah dan dilakukan uji laboratorium atau disebut dengan pemeriksaan bersifat *invasive*. Beberapa informasi yang dapat diambil dari tes darah yaitu bentuk, ukuran dan jumlah sel darah merah [4]. Anemia diperoleh dari informasi jumlah sel darah merah yang lebih rendah dari jumlah normal [5]. Dengan cara ini membutuhkan waktu dan harus merasakan nyeri saat proses pengambilan darah. Hal tersebut menjadi salah satu faktor sebagian besar masyarakat enggan untuk memeriksa kesehatan dirinya secara rutin ke puskesmas, klinik maupun rumah sakit. Seiring berjalannya waktu, berbagai metode *non-invasive* yang lebih praktis dikembangkan untuk mendeteksi penyakit anemia sebagai alternatif seperti pemeriksaan yang dilakukan dengan melihat tingkat kepukatan konjungtiva pada mata. Sistem pendeteksian anemia secara *non-invasive* menggunakan citra *palpebral konjungtiva* ini menjadi salah satu alternatif pemeriksaan yang mampu memberikan kepastian pada hasil keputusan pemeriksaan awal. Sehingga dapat meminimalisir kesalahan persepsi kepuatan warna *konjungtiva* mata saat pemeriksaan pasien.


Adapun penelitian sebelumnya yang melakukan deteksi anemia secara otomatis dengan memanfaatkan *thresholding* yang membandingkan spektrum warna merah dan hijau dari citra *konjungtiva* sehingga mendapat nilai akurasi 78.9% [6]. Sementara itu penelitian oleh [7], melakukan *self-care anemia detection* pada ibu hamil dengan rentang usia 22-36 tahun dan golongan darah yang bervariasi (A, B, AB, dan O) menggunakan kamera *smartphone*. Deteksi anemia dilakukan menggunakan intensitas warna RGB dari citra *palpebral konjungtiva* menggunakan alat *Spectrophotometer* standar. Hasil dari analisis

regresi menyatakan bahwa metode *non-invasive* sangat baik digunakan dalam mendeteksi anemia dengan nilai LOD (*Limit of Detection*) sebesar 3.79 g/dL. Kemudian penelitian lainnya dilakukan perbandingan beberapa algoritma *machine learning* untuk melakukan klasifikasi anemia. Algoritma K-Means memiliki nilai akurasi tertinggi dalam melakukan clustering fitur warna (RGB) pada citra *palpebral* dengan memanfaatkan algoritma SMOTE untuk menyeimbangkan dataset [8]. Pada penelitian lainnya, [9] melakukan deteksi anemia secara *non-invasive* menggunakan citra *konjungtiva* dengan menerapkan algoritma *neural network*. Hasil penelitian menunjukkan bahwa sistem berhasil memperoleh nilai akurasi 97% dengan sensitivitas 99.21% dan spesifitas 95.42%. Selain itu, penelitian yang dilakukan oleh [10] menggunakan citra digital kuku dan telapak tangan untuk mendeteksi anemia yang memanfaatkan salah satu algoritma *machine learning*. Algoritma yang digunakan adalah algoritma *naïve bayes* dengan pengembangan menggunakan algoritma *waterfall*. Dengan intensitas cahaya yang bervariasi menghasilkan nilai akurasi 87.5% dan saat menggunakan intensitas cahaya 5362 Lux mendapatkan nilai akurasi 92.3%. Akan tetapi, pada penelitian diatas menggunakan metode *neural network* biasa yang hanya memuat skala panjang dan tinggi sebagai inputan dimana hal ini dapat mengakibatkan kehilangan informasi spasialnya.

Pada penelitian ini memanfaatkan algoritma *Convolutional Neural Network* dalam mengklasifikasi penyakit anemia pada citra *palpebral konjungtiva*. Tahapan dari metode yang diusulkan meliputi memasukkan citra *palpebral konjungtiva*, *preprocessing*, dan klasifikasi menggunakan algoritma CNN. Salah satu algoritma *deep learning* ini (sub bidang *machine learning*) menggunakan kombinasi lapisan konvolusi untuk proses ekstraksi fitur yang akan menghasilkan pola-pola sehingga memudahkan proses klasifikasi citra. Algoritma CNN dapat memuat semua informasi dari keseluruhan skala dalam objek seperti panjang, lebar dan tinggi. Hal ini menjadi kelebihan algoritma CNN karena dapat mengurangi resiko kehilangan informasi spasial pada tahap ekstraksi fitur dan klasifikasi yang mempengaruhi optimasi model. Maka dari itu, diharapkan hasil klasifikasi penyakit anemia menggunakan algoritma *Transfer Learning AlexNet* mendapatkan performansi yang lebih tinggi dan akurat dengan waktu komputasi yang relatif lebih sederhana dibandingkan dengan metode-metode sebelumnya.

METODE PENELITIAN

Tahapan-tahapan pada penelitian ini meliputi pengumpulan data, *pre-processing*, perancangan dan analisis (modelling), evaluasi, dan penarikan kesimpulan. Alur penelitian dapat dilihat pada Gambar 1.



Gambar 1. Alur Penelitian

a. Akuisisi Data Citra Palpebral Konjungtiva

Penelitian ini menggunakan data yang bersumber dari IEEE DataPort yaitu citra *palpebral konjungtiva* pada dataset *eyes-defy-anemia*. Citra *palpebral konjungtiva* sebanyak 639 citra berukuran 1067×800 terbagi menjadi dua class yaitu normal dan anemia. Pada label normal terdiri dari 419 citra dan label anemia terdiri dari 220 citra.

b. Pre-processing

Dataset citra *palpebral konjungtiva* yang telah diperoleh diberikan label sesuai dengan data hemoglobinnnya berupa label anemia atau normal. Kategori yang diberikan pada citra *palpebral konjungtiva* mengacu pada Tabel 1 sebagai patokan kadar normal hemoglobin (Hb) penderita anemia yang bersumber dari WHO.

TABEL 1. BATASAN NORMAL HEMOGLOBIN (HB)

Kelompok	Nilai Normal
Remaja Laki-laki	14-18 g/dl
Remaja Wanita	12-16 g/dl
Wanita hamil trimester 1	11-13 g/dl
Wanita hamil trimester 2	10-15 g/dl
Bayi baru lahir	12-24 g/dl
Anak	10-16 g/dl

*Sumber: (WHO, 2019)

c. Augmentasi Citra

Dataset yang digunakan tergolong dalam data medis, dimana data yang tersedia sangatlah


terbatas. Untuk mengatasi jumlah dataset yang masih sedikit, maka dilakukanlah *image augmentation* sebagai tahap *pre-processing* pada penelitian ini. Augmentasi citra merupakan teknik yang efektif ketika data yang dimiliki tidak cukup untuk dilakukan tahap training model *deep learning*. Hasil yang diperoleh dari tahapan augmentasi citra adalah variasi baru dari data citra yang sudah ada dengan menerapkan beberapa teknik transformasi [11]. Tujuan lain dari penggunaan metode ini yaitu dapat memperkuat regularisasi dalam model CNN dengan menghindari masalah *overfitting*. Ada beberapa operasi augmentasi data yang dilakukan, pada penelitian ini menggunakan *horizontal flip*, *random brightness contrast* dan *random contrast*.

TABEL 2. TAHAPAN AUGMENTASI CITRA

Original image	Horizontal flip	Random brightness contrast	Random contrast

d. Perancangan CNN

Arsitektur Alexnet menjadi salah satu arsitektur CNN yang meraih juara di salah satu kompetisi *image classification* berskala besar pada tahun 2012 yaitu kompetisi ImageNet Large Scale Visual Recognition Challenge atau ILSVRC. Sebuah inovasi baru di bidang *deep learning* yang ditawarkan oleh AlexNet yaitu kombinasi penerapan ConvsNet dengan teknik *Dropout Regularization*, menggunakan fungsi aktivasi ReLU serta *image augmentation*. Kelebihan yang dimiliki oleh arsitektur AlexNet yaitu dapat melakukan klasifikasi dengan 1000 kategori. Susunan dari arsitektur AlexNet sendiri terdiri dari 5 lapisan konvolusi, 3 lapisan Pooling, 2 lapisan *dropout*, dan 3 *fully-connected layer*. Gambar 2 menampilkan ilustrasi dari arsitektur Alexnet.



Gambar 2. Arsitektur AlexNet

Beberapa parameter yang dapat mempengaruhi performa saat membangun model seperti *learning rate*, *batch size* dan *epoch*. *Learning rate* bertugas untuk mengatur seberapa besar pembaruan yang dilakukan terhadap nilai parameter bobot. *Batch size* adalah jumlah data training yang digunakan untuk satu kali iterasi dalam tahap training model. Jika *batch size* memiliki nilai yang sangat besar maka membutuhkan waktu yang lebih lama agar mencapai nilai akurasi tertentu atau bahkan nilai akurasi tidak meningkat. Sebaliknya, jika *batch size* memiliki nilai terlalu rendah maka nilai akurasi yang diperoleh menurun setelah tahap training model tanpa mencapai nilai akurasi yang diharapkan. Serta ada *epoch* yang merupakan salah satu *hyperparameter* yang berfungsi untuk penentuan frekuensi seluruh dataset dipelajari pada proses training oleh *neural network*. Satu *epoch* artinya seluruh batch telah melewati *neural network* sekali putaran. Pada penelitian ini membandingkan akurasi dari beberapa nilai *batch size* yang digunakan pada tahap pembelajaran model yaitu 5, 10 dan 15. Sedangkan untuk nilai *epoch* menggunakan 30, 50 dan 70.

e. Pengujian Model

Evaluasi merupakan suatu metode yang digunakan untuk memahami keandalan dari suatu API dan didasarkan pada output yang diterima dengan memasukkan data ke dalam model dan membandingkan output dengan jawaban yang sebenarnya. Matriks yang digunakan untuk menentukan loss model dalam penelitian ini adalah Binary Cross Entropy/Log Loss. Binary Cross Entropy digunakan untuk membandingkan masing-masing probabilitas yang diprediksi dengan output berupa 0 atau 1. Kemudian menghitung skor probabilitas berdasarkan jarak dari nilai yang diharapkan menggunakan Persamaan (1) berikut.

$$loss(x, y) = - \sum x \cdot \log(y) \quad (1)$$

Dimana x adalah nilai target klasifikasi dan y adalah hasil aktivasi sigmoid. Persamaan tersebut juga digunakan pada penelitian yang dilakukan oleh [12].

Untuk melihat tingkat akurasi dari model digunakan *confusion matrix*. *Confusion matrix* sebagai alat ukur untuk menghitung kinerja atau tingkat kebenaran proses klasifikasi [13]. Cara termudah untuk menghitung akurasi model pembelajaran mesin klasifikasi adalah dengan menggunakan jumlah titik yang diklasifikasikan dengan benar dalam data pengujian dan jumlah total titik dalam data pengujian untuk menghitung akurasi sederhana. Nilai *accuracy* diperoleh dengan Persamaan (2) serta *loss* pada Persamaan (3).

$$accuracy = \frac{\text{jumlah citra diprediksi benar (anemia+normal)}}{\text{jumlah seluruh citra}} \quad (2)$$

$$loss = -\frac{1}{N} \sum_{i=1}^N y_i \times \log(p(y_i)) + (1 - y_i) \times \log(1 - p(y_i)) \quad (3)$$

Dimana :

N : Jumlah sampel
 y_i : Label
 $p(y_i)$: Prediksi

Selain melihat tingkat akurasi dari model CNN dalam mengklasifikasi citra, estimasi waktu komputasi juga menjadi salah satu faktor yang menentukan kualitas suatu model dalam mengklasifikasi. Untuk itu, pada penelitian ini juga mengukur dan menganalisis *time execution* atau estimasi waktu komputasi model tiap masing-masing skenario yang dilakukan. Persamaan 3.4 digunakan untuk menghitung *time execution* model.

$$time\ execution = waktu\ berakhir - waktu\ mulai \quad (4)$$

Skenario pengujian menggunakan tiga tingkatan *batch size* serta *epoch* pada training model AlexNet yang diilustrasikan pada Tabel 3.

TABEL 3. SKENARIO PENGUJIAN

Arsitektur	Epoch	Batch size
AlexNet	30	5
		10
		15
	50	5
		10
		15
	70	5
		10
		15

Skenario tersebut dilakukan perbandingan antar nilai akurasi, nilai *loss* serta estimasi waktu komputasi model (*time execution*) menggunakan persamaan berturut-turut (2), (3), dan (4). Skenario yang memiliki nilai akurasi tertinggi dan nilai *loss* terendah serta *time execution* tercepat menjadi model optimal dalam mengklasifikasi penyakit anemia berbasis citra *palpebral konjungtiva*.


HASIL DAN PEMBAHASAN

Pengujian dilakukan dengan menggunakan dataset *Eyes Defy Anemia* yang telah diunduh dari IEEE Dataport. Data yang diperoleh berisikan citra *palpebral konjungtiva* sebanyak 639 citra berukuran 1067×800 pixel yang telah disegmentasi secara manual sehingga citra hanya berfokus pada objek *palpebral konjungtiva*. Dataset yang telah diunduh selanjutnya diberikan label sesuai dengan data

hemoglobin yang disertai dalam dataset. Label yang diberikan terdiri dari dua kategori yaitu anemia dan normal. Tahap pelabelan dilakukan dengan memisahkan dua *directory*, sehingga diperoleh citra *palpebral konjungtiva* berlabel anemia sebanyak 220 citra dan 419 citra berlabel normal seperti Gambar 3.




(a)



(b)


Gambar 3. Hasil labelling dataset

Sebelum dilakukannya pelatihan model, dataset perlu melewati tahap augmentasi menggunakan *library albumentations*. Adapun parameter-parameter yang digunakan dalam metode augmentasi citra *palpebral konjungtiva* antara lain *HorizontalFlip* dengan nilai *probability* $p=0.5$. Nilai parameter p pada *library albumentations* berfungsi untuk mengontrol kemungkinan penerapan augmentasi citra. Penggunaan nilai p 0.5 telah terbukti efektif dalam meningkatkan akurasi model yang dibuktikan pada penelitian-penelitian terdahulu, seperti penelitian yang dilakukan oleh [14]. Ketika nilai p dari *HorizontalFlip* adalah 0.5 maka artinya kemungkinan 50% data mendapat perlakuan dibalik atau *flip* secara horizontal dan 50% lainnya tetap atau tidak diubah. Parameter selanjutnya yaitu *RandomBrightnessContrast* dengan nilai $p=0.2$, serta *RandomContrast* dengan nilai $p=0.2$. Ilustrasi pada tahapan augmentasi menggunakan *library Albumentations* dapat dilihat pada Gambar 4.



Gambar 4. Tahapan Augmentasi Citra dengan *Library Albumentations*

Kemudian, dataset yang telah melalui augmentasi sebanyak 1199 citra berlabel anemia dan normal displit menjadi data latih dan data validasi dengan *validation split* 0.2 yaitu perbandingan 80:20 yang disimpan pada folder train dan test. Distribusi data setelah tahap augmentasi dapat dilihat pada Gambar 5.




Gambar 5. Distribusi Data setelah Tahap Augmentasi

Data tersebut selanjutnya di-generate dengan image size berukuran (256, 256) yang mengubah ukuran citra menjadi 256×256 pixel, *class name* yang mendefinisikan label citra yaitu anemia ataupun normal, subset training digunakan untuk menentukan data latih dan *validation* untuk data validasi, serta label mode *binary* untuk menentukan kelas secara biner atau dua kategori yaitu 0 atau 1. Selanjutnya penjelasan mengenai hasil uji coba skenario nilai *batch size* serta *epoch* sebagai *hyperparameter*.



(a)



(b)



(c)

Gambar 6. Performansi Model AlexNet tiap Setting Penelitian

Berdasarkan grafik pada Gambar 6, setting penelitian ke-9 tidak memiliki nilai loss serta akurasi. Hal ini disebabkan oleh penggunaan hyperparameter *epoch* 70 dan *batch size* 15. Dimana jumlah data training pada *train generator* hanya 964, sedangkan dalam tahap training penggunaan *epoch* dan *batch size* harus disesuaikan dengan jumlah data train yang dimiliki. Karena dalam satu iterasi (*epoch*) melatih data sesuai dengan nilai *batch size* yang menentukan banyak data yang dilatih dalam sekali iterasi. Sehingga penggunaan *epoch* dan *batch size* membutuhkan minimal data training sebanyak $epoch \times batch\ size$, atau pada *setting* penelitian ini $70 \times 15 = 1050$. Hal

ini menjadi alasan mengapa proses training pada setting penelitian ke-9 berhenti pada *epoch* ke-65 *step* 4 atau dalam perhitungannya $epoch\ 65 \times 15 = 975$. Tahap training tidak dapat diselesaikan hingga *step* 15 dikarenakan data training yang dimiliki hanya 964. Tampilan tahap training *setting* penelitian ke-9 ditunjukkan pada Gambar 7 berikut.

```
Epoch 60/70
15/15 [=====] - 23s 2s/step - loss: 0.3204 - accuracy: 0.8479 - val_loss: 0.2684 - val_accuracy: 0.868
7
Epoch 61/70
15/15 [=====] - 37s 3s/step - loss: 0.2660 - accuracy: 0.8625 - val_loss: 0.3583 - val_accuracy: 0.858
9
Epoch 62/70
15/15 [=====] - 51s 4s/step - loss: 0.2490 - accuracy: 0.9042 - val_loss: 0.6350 - val_accuracy: 0.791
3
Epoch 63/70
15/15 [=====] - 63s 4s/step - loss: 0.3020 - accuracy: 0.8479 - val_loss: 0.5767 - val_accuracy: 0.718
8
Epoch 64/70
15/15 [=====] - 50s 3s/step - loss: 0.3687 - accuracy: 0.8220 - val_loss: 0.4272 - val_accuracy: 0.808
3
Epoch 65/70
4/15 [====] - ETA: 26s - loss: 0.2643 - accuracy: 0.8960
tensorflow:Your input ran out of data;
interrupting training. Make sure that your dataset or generator can generate at least 'steps_per_epoch * epochs' batches (in
this case, 1050 batches). You may need to use the repeat() function when building your dataset.
15/15 [=====] - 19s 1s/step - loss: 0.2643 - accuracy: 0.8968 - val_loss: 0.7931 - val_accuracy: 0.679
2
Wall time: 47min 58s
```

Gambar 7. Tahap Training Setting Penelitian ke-9

Pengujian model AlexNet yang dikombinasikan menggunakan *hyperparameter batch size* dan *epoch* menghasilkan loss terendah pada setting penelitian ke-4 yaitu 0.3089. Pada *setting* penelitian ini menggunakan *batch size* 5, dimana *batch size* yang gunakan berukuran paling kecil. Penggunaan nilai *batch size* yang kecil berdampak pada waktu komputasi yang semakin singkat dibandingkan dengan skenario penggunaan *batch size* 10 dan 15. Akurasi yang diperoleh yaitu 85% dimana akurasi dari setting penelitian ke-6 lebih tinggi. Setting penelitian ke-6 menggunakan *batch size* yang lebih tinggi yaitu *batch size* 15 dengan akurasi 85,62%. Dimana semakin besar jumlah data training dalam satu kali iterasi pada tahap training, model akan semakin cerdas mempelajari data dengan memperoleh pola-pola tertentu berdasarkan hasil perbandingan antar data yang lebih banyak dalam sekali iterasi. Semakin kaya data yang dimiliki, maka model semakin dalam mempelajari pola-pola antar data.

Namun, perbedaan antar setting penelitian ke-4 dan ke-6 terpatut jauh pada sisi *time execution* tahap training. *Setting* penelitian ke-6 melakukan training model selama 39 menit 36 detik. Sedangkan waktu eksekusi *setting* penelitian ke-4 lebih cepat yaitu selama 16 menit 13 detik. Perbedaan dari segi waktu menjadikan alasan *setting* penelitian ke-4 lebih optimal dibandingkan dengan model AlexNet yang menggunakan *batch size* 15. Kedua setting penelitian juga sama-sama menggunakan nilai *epoch* 50, sehingga untuk penggunaan nilai *epoch* user dapat menyesuaikan dengan jumlah data training yang dimiliki.

SIMPULAN

Berdasarkan hasil uji skenario penelitian model AlexNet dalam mengklasifikasi penyakit anemia menggunakan citra *palpebral conjunctiva*,

dapat disimpulkan bahwa model AlexNet dapat menghasilkan model yang optimal dengan menggunakan *hyperparameter batch size* yang kecil dalam hal ini nilai yang digunakan yaitu 5 yang dikombinasikan dengan nilai *epoch* 50. Untuk nilai *epoch* yang digunakan dapat disesuaikan oleh user berdasarkan jumlah data yang dimiliki. Akurasi yang diperoleh model Alexnet yaitu 85% dan loss 0.3089 dengan waktu training selama 16 menit 13 detik. Pengembangan penelitian lebih lanjut dapat melakukan penyusunan *hyperparameter* dari struktur arsitektur *Convolutional Neural Network* (CNN) agar dapat diperoleh hasil model yang lebih optimal, baik dari segi *loss*, akurasi serta waktu komputasi.

DAFTAR PUSTAKA

- [1] K. RI, Pedoman Pencegahan Dan Penanggulangan Anemia Pada Remaja dan Wanita Usia Subur (WUS). KEMENKES RI, 2018.
- [2] "GHO." <https://www.who.int/data/gho> (accessed May 05, 2023).
- [3] Laporan nasional Riskesdas 2018. Kementerian Kesehatan, Republik Indonesia, Badan Penelitian dan Pengembangan Kesehatan, 2019.
- [4] S. Y. Putri, "Identifikasi Penyakit Anemia Defisiensi Besi Berdasarkan Kelainan Sel Darah Merah Menggunakan Metode Probabilistic Neural Network," Thesis, Universitas Sumatera Utara, 2018. Accessed: May 05, 2023. [Online]. Available: <https://repositori.usu.ac.id/handle/123456789/7292>
- [5] L. Listyalina, "Identifikasi Otomatis Anemia pada Citra Sel Darah Merah Berbasis Komputer," vol. 11, no. 3, 2017.
- [6] A. Tamir et al., "Detection of anemia from image of the anterior conjunctiva of the eye by image processing and thresholding," in 2017 IEEE Region 10 Humanitarian Technology Conference (R10-HTC), Dec. 2017, pp. 697–701. doi: 10.1109/R10-HTC.2017.8289053.
- [7] M. D. Anggraeni and A. Fatoni, "Non-invasive Self-Care Anemia Detection during Pregnancy Using a Smartphone Camera," IOP Conf. Ser.: Mater. Sci. Eng., vol. 172, no. 1, p. 012030, Feb. 2017, doi: 10.1088/1757-899X/172/1/012030.
- [8] G. Dimauro, A. Guarini, D. Caivano, F. Girardi, C. Pasciolla, and A. Iacobazzi, "Detecting Clinical Signs of Anaemia From Digital Images of the Palpebral Conjunctiva," IEEE Access, vol. 7, pp. 113488–113498, 2019, doi: 10.1109/ACCESS.2019.2932274.
- [9] "Neural network based non-invasive method to detect anemia from images of eye conjunctiva - Jain - 2020 - International Journal of Imaging Systems and Technology - Wiley Online Library." <https://onlinelibrary.wiley.com/doi/abs/10.1002/ima.22359> (accessed May 05, 2023).
- [10] N. J. Peksi, B. Yuwono, and M. Y. Florestiyanto, "Classification of Anemia with Digital Images of Nails and Palms using the Naive Bayes Method," Telematika : Jurnal Informatika dan Teknologi Informasi, vol. 18, no. 1, Art. no. 1, Mar. 2021, doi: 10.31315/telematika.v18i1.4587.
- [11] "Deep Learning mit Python und Keras - Das Praxis-Handbuch vom Entwickler der Keras-Bibliothek [Book]." <https://www.oreilly.com/library/view/deep-learning-mit/9783958458406/> (accessed May 05, 2023).
- [12] S. Goel et al., "Deep Learning Approach for Stages of Severity Classification in Diabetic Retinopathy Using Color Fundus Retinal Images," Mathematical Problems in Engineering, vol. 2021, pp. 1–8, Nov. 2021, doi: 10.1155/2021/7627566.
- [13] A. H. Al Kabir, S. Basuki, and G. W. Wicaksono, "Analisis sentimen kritik dan saran pelatihan aplikasi teknologi informasi (PATI) menggunakan algoritma support vector machine (SVM)," Repositor, vol. 1, no. 1, Art. no. 1, Nov. 2019.
- [14] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA: IEEE, Jun. 2016, pp. 770–778. doi: 10.1109/CVPR.2016.90.