

ANALISIS PERFORMA RESNET-152 DAN ALEXNET DALAM KLASIFIKASI JENIS KANKER KULIT

Tommy Saputra ¹, Muhammad Ezar Al Rivan ²

Program Studi Informatika Fakultas Ilmu Komputer dan Rekayasa, Universitas Multi Data Palembang
hikeruhinara@gmail.com ¹, meedzhar@mdp.ac.id ²

Submitted February 10, 2023; Revised July 5, 2023; Accepted July 17, 2023

Abstrak

Kanker kulit merupakan penyakit berbahaya. Jenis kanker kulit terbanyak ditemukan di Indonesia adalah *melanoma*. Kasus *melanoma* mencapai 9,6 juta kasus pada tahun 2018. Penanganan cepat dan tepat dapat menyembuhkan kanker kulit. Deteksi kanker kulit membutuhkan ahli dan biaya yang mahal. Deteksi dini kanker kulit dapat dilakukan dengan sistem deteksi jenis kanker berdasarkan kelas *benign* dan *malignant* menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur *ResNet-152* dan *AlexNet*. Data yang digunakan diambil dari *International Skin Imaging Collaboration* (ISIC) *archives* tahun 2019. Algoritma *optimizer* yang digunakan yaitu *Adaptive Moment Estimation* (Adam) dan *Mini-Batch Gradient Descent* (MBGD). Arsitektur *ResNet-152* menggunakan *optimizer* MBGD memberikan hasil terbaik dengan akurasi sebesar 87,85%.

Kata Kunci : *AlexNet*, ISIC, Kanker Kulit, *Optimizer*, *ResNet-152*

Abstract

Skin cancer is a dangerous disease. The most common skin cancers in Indonesia is melanoma. Melanoma cases reached 9,6 million in 2018. Skin cancer can be cured with proper and quick treatment. Skin cancer early detection can be done by detection system types of skin cancer based on benign and malignant classes using Convolutional Neural Network (CNN) with ResNet-152 and AlexNet architecture. The data are taken from the 2019 International Skin Imaging Collaboration (ISIC) archives. The optimizer algorithms used are Adaptive Moment Estimation (Adam) and Mini-Batch Gradient Descent (MBGD). The result of the research indicates that ResNet-152 architecture using MBGD optimizer gives the best result with an accuracy of 87.85%

Keywords : *AlexNet*, ISIC, *Optimizer*, *ResNet-152*, *Skin Cancer*

1. PENDAHULUAN

Kulit merupakan lapisan terluar dari tubuh manusia yang sering memicu penyakit. Penyakit kulit muncul tidak hanya berasal dari interaksi sesama manusia, namun juga melalui media lainnya yang digunakan orang berpenyakit kulit menular [1]. Salah satu penyakit berbahaya yang menyerang kulit adalah kanker. Penyebab utama kanker kulit akibat dari paparan sinar *ultraviolet radiation* (UV-R) pada pigmen kulit yang rendah, dan faktor genetika [2]. Kanker kulit diketahui merupakan jenis kanker yang paling sering ditemukan di Amerika Serikat dengan perawatan melebihi \$8 miliar [3]. Kanker kulit berbahaya dapat dikategorikan menjadi 2 jenis yaitu

malignant dan *benign*. Kanker *malignant* merupakan kanker yang dapat berkembang dan menyebar pada tubuh penderita, sedangkan kanker *benign* merupakan kanker berbahaya yang dapat berkembang namun tidak dapat menyebar seperti jenis kanker *malignant* [4]. Jenis kanker yang dikategorikan sebagai *benign* antara lain *benign keratosis*, *dermatofibroma*, dan *melanocytic nevus*; sedangkan jenis kanker yang dikategorikan sebagai *malignant* antara lain *actinic keratosis*, *basal cell carcinoma*, *melanoma*, *vascular lesion* dan *squamous cell carcinoma* [5], [6]. Deteksi dini pada kanker kulit dapat dilakukan secara konvensional namun membutuhkan

keterampilan pengamat yang memungkinkan terjadinya *human error* [7].

Perkembangan teknologi sudah sangat maju sekarang ini khususnya teknologi yang mampu khususnya teknologi paten yang mampu mengklasifikasikan objek seperti benda, wajah, bahkan penyakit. Salah satu metode yang digunakan dalam klasifikasi jenis penyakit berbasis citra adalah *deep learning* dengan *Convolutional Neural Network* (CNN) [8]. Terdapat banyak model arsitektur yang dibangun dalam CNN, diantaranya *AlexNet* dan *ResNet*.

AlexNet merupakan arsitektur pertama dari *deep learning* yang memenangkan kompetisi *ImageNet Large Scale Visual Recognition Challenge* (ILSVRC) pada tahun 2012 [9]. *AlexNet* memiliki total 8 layer dengan 5 layer konvolusi dengan variasi ukuran *kernel* serta beberapa *filter*, dan 3 layer *fully connected*. Variasi ukuran *kernel* menjadi salah satu alasan *AlexNet* memiliki performa yang baik dalam mengklasifikasikan *dataset* citra [10].

ResNet merupakan salah satu arsitektur jaringan saraf tiruan yang mengusulkan logika pintasan pada beberapa lapisan serta menerapkan fungsi aktivasi pada lapisan layer sebelumnya. Metode ini memungkinkan perancangan sistem jaringan buatan dengan lapisan yang dalam tanpa terjadinya kehilangan gradien [11]. *ResNet* memiliki banyak varian, salah satunya adalah *ResNet-152* yang menerapkan 152 lapisan pada jaringan yang terbentuk. *ResNet-152* merupakan arsitektur yang memenangkan kompetisi ILSVRC pada tahun 2015 dengan 5 *error* teratas sebesar 3,6% yang setara dengan performa manusia dalam melakukan klasifikasi [9]. Arsitektur *ResNet-152* terdiri dari lima proses konvolusi utama dengan banyak blok konvolusi, serta satu lapisan *fully connected*.

Adaptive Moment Estimation (Adam) merupakan algoritma untuk optimasi fungsi

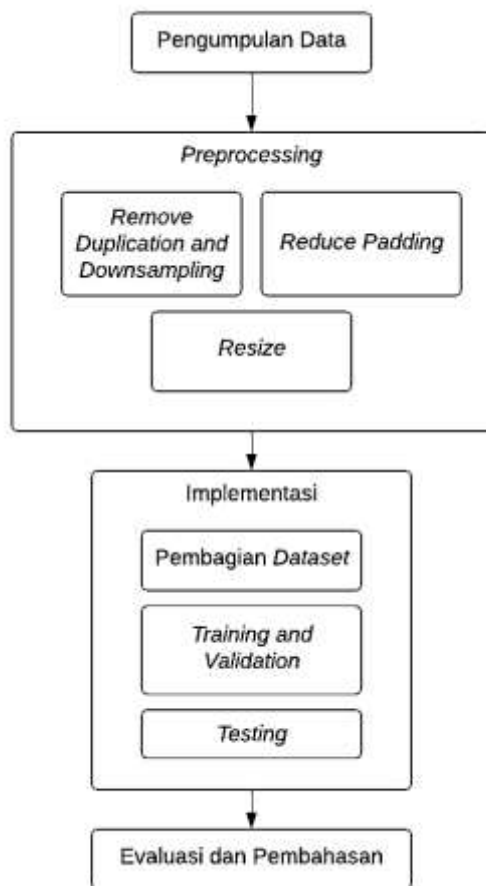
objektif *stochastic* berbasis gradient orde pertama berdasarkan estimasi *moment* orde rendah. Algoritma ini merupakan gabungan keunggulan yang ada pada algoritma *AdaGrad* dan *RMSProp*. Keuntungan dari menggunakan metode ini antara lain penerapan yang mudah, komputasi lebih efisien, membutuhkan sedikit memori, tidak bergantung pada perubahan skala *diagonal gradient*, dan sangat baik untuk kasus dengan parameter yang banyak [12].

Mini-Batch Gradient Descent (MBGD) merupakan varian dari optimasi *gradient descent* yang mempertimbangkan sejumlah sampel kecil dari keseluruhan sampel pelatihan untuk menghitung gradien secara bertahap dan dilanjutkan dengan pembaruan bobot. MBGD membagi *dataset* pelatihan menjadi beberapa kelompok (*batch*) dalam proses pelatihan. Algoritma ini mengurangi variasi pembaruan bobot sehingga hasil lebih stabil, dan pembaruan secara terus menerus dapat mempercepat proses pelatihan [13].

Tujuan dari penelitian ini adalah melihat performa CNN dengan model arsitektur *ResNet-152* dan *AlexNet* menggunakan *dataset* ISIC 2019 untuk proses klasifikasi jenis kanker kulit pada penderita. Manfaat penelitian ini berupa pemahaman dalam *preprocessing* data kanker kulit, mengetahui perbandingan performa dari model yang diteliti, dan mempermudah manusia dalam mengenali jenis kanker kulit.

2. METODE PENELITIAN

Metode penelitian diterapkan dengan menggunakan *VSCode*, *GoogleColab*, dan *Kaggle* dengan bahasa pemrograman *python*. *VSCode* digunakan untuk *preprocessing*, *GoogleColab* digunakan dalam melakukan *hyperparameter tuning*, dan *Kaggle* digunakan dalam membangun sistem serta menampilkan hasil pelatihan dan pengujian. Metode penelitian dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

Teknik Pengumpulan Data

Dataset penelitian diperoleh dengan teknik pengumpulan data sekunder. *Dataset* diambil dari situs ISIC khususnya *archive* tahun 2019 yang dapat diakses melalui halaman website <https://challenge.isic-archive.com/landing/2019/>. *Dataset* berisi citra pada 8 jenis kanker kulit yang dikategorikan menjadi 2 kelas penelitian yaitu *benign* dan *malignant*.

Preprocessing

Preprocessing atau pemrosesan data merupakan tahapan penyesuaian *dataset* yang digunakan dengan penelitian yang dilakukan. *Preprocessing* diterapkan untuk mengatasi masalah data yang tidak sesuai dengan objek penelitian seperti data berulang (*duplication*) dan data yang belum sesuai dengan objek penelitian (*noise*). Pada kasus ini diterapkan beberapa *code* untuk

mengurangi *noise* pada tiap citra, serta proses penghapusan citra. Citra yang sudah sesuai dilakukan *resize* menjadi ukuran 224x224

Implementasi

Implementasi merupakan tahapan dalam mendapatkan hasil pengujian yang terdiri dari pembagian *dataset*, proses pelatihan, dan pengujian. Implementasi pelatihan dan pengujian diterapkan untuk masing-masing skenario model.

1. Proses pembagian *dataset* dilakukan untuk membagi data pelatihan, pengujian dan validasi sesuai dengan rasio objek penelitian yaitu 80:10:10.
2. Pelatihan atau *training* merupakan proses pembentukan model yang akan digunakan dalam proses pengujian atau *testing*. Proses pelatihan pada model dapat berpengaruh pada hasil dari pengujian.
3. Pengujian atau *testing* bertujuan untuk melihat performa model yang sudah dibangun terhadap data *test* yang digunakan.

Evaluasi dan Pembahasan

Evaluasi dan pembahasan dilakukan dengan menerapkan perbandingan untuk tiap model skenario yang sudah diuji. Perbandingan diterapkan pada nilai *accuracy*, *precision*, *recall*, dan *f1-score* pada hasil prediksi dalam proses pengujian yang dihitung menggunakan *confusion matrix* seperti yang ditunjukkan pada Tabel 1. *True Positive* (TP) menunjukkan banyak data aktual dan prediksi yang sama-sama bernilai positif, dan sebaliknya *True Negative* (TN) menunjukkan banyak data aktual dan prediksi yang sama-sama bernilai negatif. *False Positive* (FP) menunjukkan banyak data aktual yang negatif namun diprediksi positif, sebaliknya *False Negative* (FN) menunjukkan data aktual yang bernilai positif namun diprediksi bernilai negatif.

Tabel 1. Confusion Matrix

		Predicted	
		Positive	Negative
Actual	Positive	TP	FN
	Negative	FP	TN

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$precision = \frac{TP}{TP+FP} \quad (2)$$

$$recall = \frac{TP}{TP+FN} \quad (3)$$

$$f1 - score = \frac{2*precision*recall}{precision+recall} \quad (4)$$

Hasil evaluasi ditunjukkan dalam bentuk tabel perbandingan untuk setiap arsitektur dan grafik perbandingan untuk keseluruhan skenario pengujian.

3. HASIL DAN PEMBAHASAN

Hasil yang dibahas pada penelitian ini berupa perbandingan performa dari masing-masing skenario pengujian yang dilakukan. Hasil akhir berupa pemilihan skenario terbaik dalam melakukan klasifikasi kanker kulit jenis *benign* dan *malignant*.

Pengumpulan Data


Data diperoleh dari situs resmi ISIC *archive* tahun 2019 yang terdiri dari 8 label jenis kanker yaitu *Melanocytic Nevus* (NV), *Benign Keratosis* (BKL), *Dermatofibroma* (DF), *Melanoma* (MEL), *Basal Cell Carcinoma* (BCC), *Actinic Keratosis* (AK), *Vascular Lesion* (VASC) dan *Squamous Cell Carcinoma* (SCC) [14], [15], [16]. *Dataset* ISIC 2019 terdiri dari 25331 citra kanker kulit. *Dataset* dibagi menjadi 2 kategori jenis kanker yaitu *benign* dan *malignant* dimana kategori jenis kanker ditunjukkan pada Tabel 1.

Tabel 1. Pembagian Kelas

Kelas Penelitian	Kelas <i>Dataset</i> ISIC 2019
<i>Benign</i>	<i>Melanocytic Nevus</i> (NV)
	<i>Benign Keratosis</i> (BKL)
	<i>Dermatofibroma</i> (DF)
<i>Malignant</i>	<i>Melanoma</i> (MEL)
	<i>Basal Cell Carcinoma</i> (BCC)
	<i>Actinic Keratosis</i> (AK),
	<i>Vascular Lesion</i> (VASC)
	<i>Squamous Cell Carcinoma</i> (SCC)

Preprocessing

Preprocessing atau pemrosesan data merupakan tahapan penting agar data yang digunakan dapat menghasilkan performa terbaik dalam proses pelatihan dan pengujian. *Dataset* dibersihkan terlebih dahulu dari data yang sama (*duplication*) dan data yang tidak sesuai dengan objek penelitian. Pada kasus ini, data yang tidak sesuai dengan penelitian adalah citra *padding*. Citra dengan *padding* diproses dengan menghilangkan *padding* sebanyak mungkin untuk mengurangi *noise* pada proses pelatihan model. Data yang sudah diperiksa kemudian diterapkan *resize* menjadi 224x224 piksel untuk mengurangi beban memori pada proses pelatihan model. Pada proses ini juga dilakukan penghapusan citra untuk data yang tidak dapat digunakan dalam penelitian yaitu data dengan *tag* nama *downsampled* karena data tersebut merupakan data yang sudah diproses sebelumnya untuk kepentingan penelitian tertentu pada *dataset* ISIC 2019, sehingga total *dataset* yang digunakan ada 23257 citra.



Gambar 2. Pengurangan *Padding* pada Citra

Implementasi

Implementasi yang diterapkan berupa pembagian data, pelatihan, dan pengujian model yang sudah dibangun.

1. Pembagian Data

Pembagian data dilakukan dengan membagi data menjadi rasio 80:10:10. Sebelum masuk pada proses pelatihan, data perlu dilakukan *balancing* terlebih dahulu untuk mengatasi *imbalance data* pada masing-masing kelas penelitian. *Balancing* data dilakukan dengan mengurangi beberapa data pada kelas NV karena memiliki data terbanyak pada *dataset* ISIC 2019. Pada Tabel 2 ditunjukkan pembagian data sebelum dilakukan *balancing* dan Tabel 3 menunjukkan pembagian data setelah proses *balancing*.

Tabel 2. Jumlah Data yang Unbalanced

Kelas	Train		Test		Validation	
BKL	181		225		202	
DF	191	1120	19	142	29	140
NV	920	6	118	8	117	4
	2		4		3	
AK	692		78		97	
BCC	265		343		328	
	2					
MEL	332	7367	412	918	410	934
	6					
SCC	501		59		68	
VAS	196		26		31	
C						
Total	18573		2346		2338	

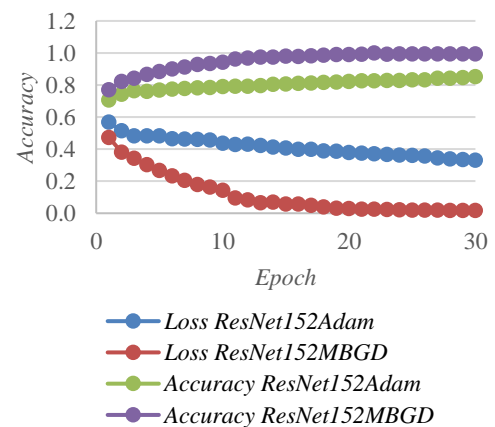
Tabel 3. Jumlah Data Balanced

Kelas	Train		Test		Validation	
BKL	1813		225		202	
DF	191	7367	19	918	29	934
NV	5363		674		703	
AK	692		78		97	
BCC	2652		343		328	
MEL	3326	7367	412	918	410	934
SCC	501		59		68	
VASC	196		26		31	
Total	14734		1836		1868	

2. Pelatihan

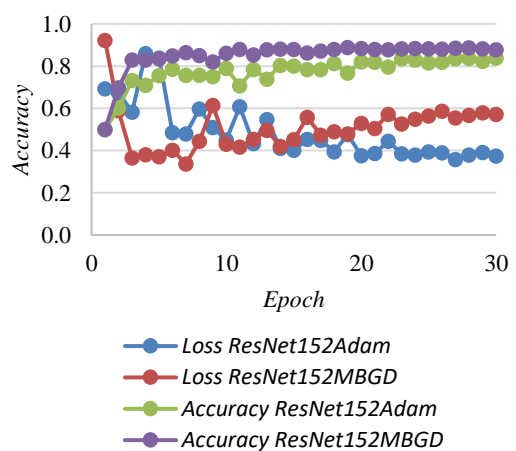
Sebelum masuk proses pelatihan, dilakukan *hyperparameter tuning* terlebih dahulu menggunakan data validasi untuk mendapatkan banyak *batch size* dan *epoch* yang optimal. Pada kasus ini didapat nilai *batch size* dan *epoch* yang paling sesuai dengan penelitian adalah *batch size* sebesar 32, dan *epoch* sebanyak 30. Proses pelatihan meliputi penerapan arsitektur

AlexNet dan *ResNet-152* kemudian setiap arsitektur diterapkan *optimizer* Adam dan MBGD dengan *learning rate* awal 0.0001. Pada Gambar 3 dan Gambar 4 menunjukkan hasil pelatihan menggunakan arsitektur *ResNet-152*, sedangkan Gambar 5 dan Gambar 6 menunjukkan hasil pelatihan menggunakan arsitektur *AlexNet*.



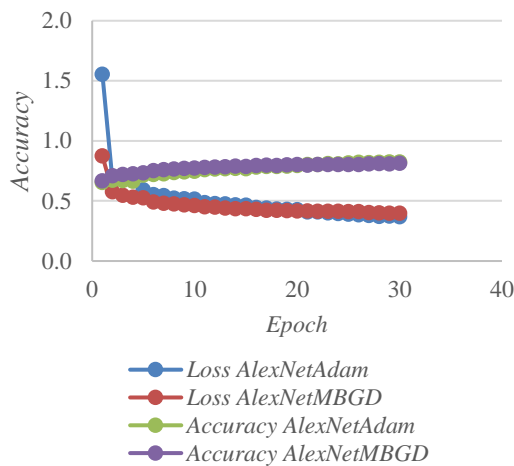
Gambar 3. Training Accuracy dan Loss pada Arsitektur ResNet-152

Jika dilihat pada Gambar 3, hasil terbaik pada *training accuracy* dan *loss* pada *ResNet-152* dicapai menggunakan *optimizer* MBGD dengan *accuracy* terbaik sebesar 99,43% dan *loss* terendah sebesar 0.017. Pada grafik terlihat dengan jelas bahwa *accuracy* terus meningkat dan *loss* semakin berkurang kemudian mulai stabil pada *epoch* ke 19.



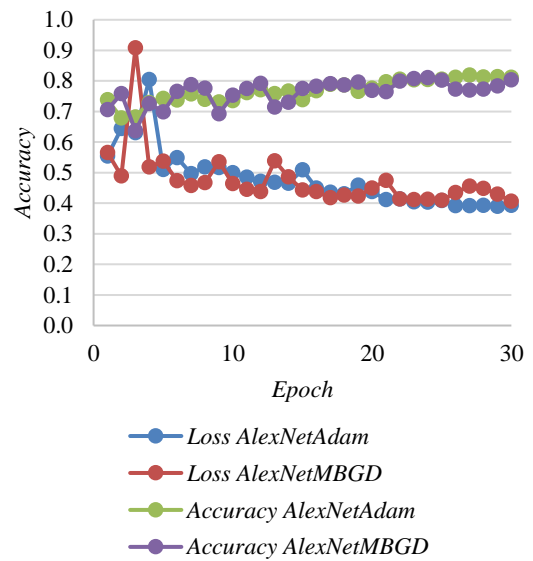
Gambar 4. Validation Accuracy dan Loss pada Arsitektur ResNet-152

Pada Gambar 4 hasil terbaik pada *validation accuracy* dicapai dengan menggunakan *optimizer* MBGD dengan *accuracy* terbaik sebesar 88,16% dan *validation loss* terendah dicapai dengan *optimizer* Adam dengan *loss* terendah sebesar 0,3581. Pada grafik *validation* terlihat kenaikan dan penurunan yang tidak stabil, hal ini terjadi karena data validasi cenderung lebih beragam dibandingkan data latih yang sudah diterapkan *data augmentation* pada proses pelatihannya.



Gambar 5. Training Accuracy dan Loss pada Arsitektur AlexNet

Gambar 5 menunjukkan hasil terbaik dari *training accuracy* dan *loss* dicapai dengan *optimizer* Adam dengan nilai *accuracy* sebesar 81,18% dan *loss* terendah sebesar 0.3681. Pada grafik terlihat kenaikan *accuracy* dan penurunan *loss* yang stabil.



Gambar 6. Validation Accuracy dan Loss pada Arsitektur AlexNet

Pada gambar 6 terlihat hasil terbaik dari *validation accuracy* dan *loss* pada arsitektur AlexNet dicapai menggunakan *optimizer* Adam dengan *accuracy* tertinggi sebesar 81,91% dan *loss* terendah sebesar 0.3922. Sama halnya dengan grafik validasi pada ResNet-152, *validation accuracy* dan *loss* pada AlexNet juga mengalami kenaikan dan penurunan yang tidak stabil akibat data validasi yang cenderung beragam dibandingkan data latih.

3. Pengujian

Pengujian atau *testing* meliputi beberapa tahapan yaitu prediksi dalam bentuk *confusion matrix*, perhitungan *accuracy*, *recall*, *precision*, dan *f1-score*; serta perbandingan hasil pengujian. Berikut ini ditunjukkan hasil prediksi berupa *confusion matrix* untuk skenario pertama yaitu model ResNet-152 dengan *optimizer* Adam.

Tabel 4. Confusion Matrix ResNet-152 dengan Optimizer Adam

		Predicted	
		Benign	Malignant
Actual	Benign	757	138
	Malignant	161	780

Pada kelas *benign*, jumlah data *benign* yang diklasifikasikan bernilai benar oleh sistem (*True Positive*) sebanyak 757 data dan terklasifikasi bernilai salah (*False Positive*) sebanyak 161 data. Sebaliknya, jumlah data *malignant* yang diklasifikasikan bernilai benar oleh sistem (*False Negative*) sebanyak 138 data dan terklasifikasi bernilai salah (*True Negative*) sebanyak 780 data. Hasil prediksi kemudian dihitung untuk mencari nilai *accuracy*, *recall*, *precision*, dan *f1-score*.

$$\begin{aligned} accuracy &= \frac{TP+TN}{TP+TN+FP+FN} \quad (1) \\ &= \frac{757+780}{757+780+161+138} \\ &= 0,83716 \end{aligned}$$

Nilai *precision*, *recall*, dan *f1-score* untuk kelas *benign* pada model *ResNet-152* dengan *optimizer Adam*.

$$\begin{aligned} precision &= \frac{TP}{TP+FP} \quad (2) \\ &= \frac{757}{757+161} \\ &= 0,82462 \end{aligned}$$

$$\begin{aligned} recall &= \frac{TP}{TP+FN} \quad (3) \\ &= \frac{757}{757+138} \\ &= 0,84581 \end{aligned}$$

$$\begin{aligned} f1 - score &= \frac{2*precision*recall}{precision+recall} \quad (4) \\ &= \frac{2 \times 0,82462 \times 0,84581}{0,82564 + 0,84581} \\ &= 0,83457 \end{aligned}$$

Langkah yang sama digunakan untuk mencari nilai *precision*, *recall*, dan *f1-score* pada kelas *malignant* pada model *ResNet-152* dengan *optimizer Adam*.

$$\begin{aligned} precision &= \frac{TP}{TP+FP} \\ &= \frac{780}{780+161} \\ &= 0,82891 \end{aligned}$$

$$\begin{aligned} recall &= \frac{TP}{TP+FN} \\ &= \frac{780}{780+138} \\ &= 0,84967 \end{aligned}$$

$$\begin{aligned} f1 - score &= \frac{2*precision*recall}{precision+recall} \\ &= \frac{2 \times 0,82891 \times 0,84967}{0,82891 + 0,84967} \\ &= 0,83916 \end{aligned}$$

Tahapan yang sama diterapkan untuk seluruh skenario pengujian sehingga didapatkan tabel hasil pengujian sebagai berikut.

Tabel 5. Hasil Pengujian *ResNet-152* dengan *Optimizer Adam*

No.	Class	Precision	Recall	F1-score
1.	<i>Benign</i>	84,58%	82,46%	83,51%
2.	<i>Malignant</i>	82,89%	84,97%	83,92%
Accuracy				83,71%

Tabel 6. Hasil Pengujian *ResNet-152* dengan *Optimizer MBGD*

No.	Class	Precision	Recall	F1-score
1.	<i>Benign</i>	87,25%	88,67%	87,95%
2.	<i>Malignant</i>	88,48%	87,04%	87,75%
Accuracy				87,85%

Tabel 7. Hasil Pengujian *AlexNet* dengan *Optimizer Adam*


No.	Class	Precision	Recall	F1-score
1.	<i>Benign</i>	80,68%	82,35%	81,51%
2.	<i>Malignant</i>	81,98%	80,28%	81,12%
Accuracy				81,32%

Tabel 8. Hasil Pengujian *ResNet-152* dengan *Optimizer Adam*

No.	Class	Precision	Recall	F1-score
1.	<i>Benign</i>	86,09%	72,11%	78,48%
2.	<i>Malignant</i>	76,01%	88,34%	81,71%
Accuracy				80,23%

Evaluasi dan Pembahasan

Evaluasi dilakukan dengan melakukan perbandingan hasil pengujian untuk setiap skenario. Hasil dari evaluasi berupa hasil performa model skenario terbaik dalam melakukan klasifikasi jenis kanker *benign* dan *malignant*. Pada Gambar 7 ditunjukkan grafik perbandingan untuk setiap skenario pengujian.



Gambar 7. Perbandingan Hasil Pengujian Model

Berdasarkan perbandingan hasil pengujian model untuk setiap skenario pengujian menunjukkan bahwa model dengan arsitektur *ResNet-152* secara keseluruhan memiliki *accuracy* yang lebih baik dibandingkan *AlexNet* dengan rata-rata hasil *accuracy*, *precision*, *recall*, dan *f1-score* diatas 87%, dan model dengan *optimizer* MBGD memiliki akurasi yang

cenderung lebih baik pada arsitektur *ResNet-152*, namun sedikit lebih buruk pada arsitektur *AlexNet* dibandingkan *optimizer* Adam.

4. SIMPULAN

Berdasarkan penelitian yang sudah dilakukan dapat disimpulkan bahwa model dengan arsitektur *ResNet-152* dan *AlexNet* dapat digunakan dalam mengklasifikasikan jenis kanker *benign* dan *malignant* dengan baik. Algoritma optimasi yang digunakan dapat berpengaruh terhadap akurasi pelatihan dan pengujian model dimana pada kasus ini algoritma optimasi MBGD cenderung lebih baik dibandingkan Adam. Arsitektur yang berbeda juga menghasilkan akurasi yang berbeda. Hal ini dapat dilihat pada kelas *benign* dimana hasil terbaik dicapai dengan arsitektur *ResNet-152* menggunakan *optimizer* MBGD dengan *accuracy*, *precision*, *recall*, dan *f1-score* secara berurutan sebesar 87,85%, 87,25%, 88,65%, dan 87,95% yang jauh lebih baik jika dibandingkan dengan arsitektur *AlexNet*.

DAFTAR PUSTAKA

- [1] A. Rosana, P. Wijaya, dan F. Bimantoro, "Sistem Pakar Diagnosa Penyakit Kulit pada Manusia dengan Metode Dempster Shafer," *J. Comput. Sci. Informatics Eng.*, vol. 4, no. 2, hal. 129–138, Des 2020, doi: 10.29303/jcosine.v4i2.285.
- [2] A. Tarbuk, A. M. Grancarić, dan M. Šitum, "Skin Cancer and UV Protection," *Autex Res. J.*, vol. 16, no. 1, hal. 19–28, Mar 2016, doi: 10.1515/aut-2015-0050.
- [3] N. C. F. Codella, D. Gutman, M. E. Celebi, B. Helba, M. A. Marchetti, S. W. Dusza, A. Kalloo, K. Liopyris, N. Mishra, H. Kittler, dan A. Halpern, "Skin lesion analysis toward melanoma detection: A challenge at the 2017 International symposium on

- biomedical imaging (ISBI), hosted by the international skin imaging collaboration (ISIC),” in *Proceedings - International Symposium on Biomedical Imaging*, IEEE, Okt 2018, hal. 168–172. doi: 10.1109/ISBI.2018.8363547.
- [4] M. R. Hasan, M. I. Fatemi, M. Monirujjaman Khan, M. Kaur, dan A. Zaguia, “Comparative Analysis of Skin Cancer (Benign vs. Malignant) Detection Using Convolutional Neural Networks,” *J. Healthc. Eng.*, vol. 2021, hal. 1–17, Des 2021, doi: 10.1155/2021/5895156.
- [5] B. Harangi, A. Baran, dan A. Hajdu, “Assisted deep learning framework for multi-class skin lesion classification considering a binary classification support,” *Biomed. Signal Process. Control*, vol. 62, Sep 2020, doi: 10.1016/j.bspc.2020.102041.
- [6] W. Yan, I. I. Wistuba, M. R. Emmert-Buck, dan H. S. Erickson, “Squamous Cell Carcinoma - Similarities and Differences among Anatomical Sites.,” *Am. J. Cancer Res.*, vol. 1, no. 3, hal. 275–300, 2011, [Daring]. Tersedia pada: www.ajcr.us
- [7] D. Z. Haq, “Klasifikasi Citra Kanker Kulit Menggunakan Convolutional Neural Network Model Googlenet,” UIN Sunan Ampel Surabaya, 2021. [Daring]. Tersedia pada: <http://digilib.uinsby.ac.id/id/eprint/46741>
- [8] D. Gunawan dan H. Setiawan, “Convolutional Neural Network dalam Citra Medis,” *KONSTELASI Konvergensi Teknol. dan Sist. Inf.*, vol. 2, no. 2, hal. 376–390, Mei 2022, doi: 10.24002/konstelasi.v2i2.5367.
- [9] C. C. Aggarwal, *Neural Networks and Deep Learning*, 1 ed. Cham: Springer International Publishing, 2018. doi: 10.1007/978-3-319-94463-0.
- [10] I. Singh, G. Goyal, dan A. Chandel, “AlexNet architecture based convolutional neural network for toxic comments classification,” *J. King Saud Univ. - Comput. Inf. Sci.*, Okt 2022, doi: 10.1016/j.jksuci.2022.06.007.
- [11] B. Falahkhi, E. F. Achmal, M. Rizaldi, R. Rizki, dan N. Yudistira, “Perbandingan Model AlexNet dan ResNet dalam Klasifikasi Citra Bunga Memanfaatkan Transfer Learning Comparison of AlexNet and ResNet Models in Flower Image Classification Utilizing Transfer Learning,” *J. Ilmu Komput. Agri-Informatika*, vol. 9, no. 1, hal. 70–78, 2022, [Daring]. Tersedia pada: <http://journal.ipb.ac.id/index.php/jika>
- [12] D. P. Kingma dan J. L. Ba, “Adam: A Method for Stochastic Optimization,” *ICLR*, Des 2015, [Daring]. Tersedia pada: <http://arxiv.org/abs/1412.6980>
- [13] F. R. J. Simanungkalit, H. Hanifah, G. Ardaneswari, N. Hariadi, dan B. D. Handari, “Prediction of students’ academic performance using ANN with mini-batch gradient descent and Levenberg-Marquardt optimization algorithms,” in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Nov 2021. doi: 10.1088/1742-6596/2106/1/012018.
- [14] P. Tschandl, C. Rosendahl, dan H. Kittler, “Data descriptor: The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions,” *Sci. Data*, vol. 5, no. 1, hal. 180161, Agu 2018, doi: 10.1038/sdata.2018.161.
- [15] M. Combalia, N. C. F. Codella, V. Rotemberg, B. Helba, V. Vilaplana, O. Reiter, C. Carrera, A. Barreiro, A. C. Halpern, S. Puig, dan J. Malvehy,

- “BCN20000: Dermoscopic Lesions in the Wild,” Agu 2019, [Daring]. Tersedia pada: <http://arxiv.org/abs/1908.02288>
- [16] H. Luqman, Z. Sari, dan Handhajani, “Klasifikasi Citra Pigmen Kanker Kulit Menggunakan Convolutional Neural Network,” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 2, hal. 379–385, Apr 2021, doi: 10.29207/resti.v5i2.3001.