

## Klasifikasi Kanker Kulit Menggunakan Metode VGG-19

Abdullah Sani<sup>1</sup>, Eiffel Twins Raudatul Jannah<sup>1</sup>, Budiana Budiana<sup>1</sup>

<sup>1</sup>Program Studi Teknologi Rekayasa Elektronika – Politeknik Negeri Batam

Jl. Ahmad Yani Batam Kota–Kepulauan Riau - Indonesia

[sani@polibatam.ac.id](mailto:sani@polibatam.ac.id), [eiffeljannah22@gmail.com](mailto:eiffeljannah22@gmail.com), [budiana@polibatam.ac.id](mailto:budiana@polibatam.ac.id)

**Abstrak**—Salah satu tantangan dalam dunia kesehatan adalah identifikasi kanker kulit secara cepat, presisi dan akurat. Kemajuan teknologi yang terus berkembang menjadikan salah satu potensi untuk mempelajari kanker kulit. *Convolutional neural network* (CNN) dengan arsitektur VGG-19 merupakan salah satu metode yang dapat digunakan sebagai diagnosa kanker kulit. Model CNN ini dilatih menggunakan 23.688 citra kulit dari delapan jenis kanker kulit seperti jenis kanker kulit *melanoma*, *basal cell carcinoma*, *squamous cell carcinoma*, *actinic keratoses*, *benign keratosis-like lesions*, *dermatofibroma*, *melanocytic nevi*, dan *pigmented benign keratosis* dan terdapat satu kelas kulit sehat. Dataset ini melalui tahapan augmentasi citra serta dibagi secara proporsional untuk data latih, validasi, dan uji. Evaluasi model dilakukan melalui dua skenario, yaitu secara otomatis dan secara manual menggunakan *Graphical User Interface* (GUI). Hasil pengujian menunjukkan tingkat akurasi 97,41% dengan *loss* 0,0759. Pengujian otomatis menghasilkan akurasi 96,69% dan *F1-score* 96,22%, sedangkan pengujian melalui GUI mencapai akurasi 93,89% dan *F1-score* 93,9%. Model ini terbukti efektif dalam membantu identifikasi kanker kulit secara cepat dan non-invasif.

**Kata Kunci**— Klasifikasi, kanker kulit, VGG-19

**Abstrak**—One of the challenges in healthcare is identifying skin cancer quickly, precisely, and accurately. Technological advances continue to develop, making it a promising area for studying skin cancer. A convolutional neural network (CNN) with the VGG-19 architecture is one of the methods that can be used for diagnosing skin cancer. The CNN model was trained on 23,688 skin images from eight types of skin cancer, including melanoma, basal cell carcinoma, squamous cell carcinoma, actinic keratoses, benign keratosis-like lesions, dermatofibroma, melanocytic nevi, and pigmented benign keratosis, as well as one healthy skin class. This dataset undergoes image augmentation and is split proportionally into training, validation, and test sets. Model evaluation is carried out in two scenarios: automatic and manual, using the Graphical User Interface (GUI). The test results showed an accuracy rate of 97.41% with a loss of 0.0759. Automated testing achieved 96.69% accuracy and 96.22% F1-score, while GUI testing achieved 93.89% accuracy and 93.9% F1-score. This model is effective at identifying skin cancer quickly and non-invasively.

**Kata Kunci**— Classification, Skin Cancer, VGG-19

### I. PENDAHULUAN

Dewasa ini, kanker merupakan salah satu tantangan serius dalam kesehatan global. Pada tahun 2020, Terdapat sekitar 19,3 juta kasus baru dan sekitar 10 juta kematian yang telah teridentifikasi di seluruh dunia. Pesatnya kanker dan kematian yang cenderung meningkat disebabkan karena beberapa hal seperti perubahan gaya hidup, peningkatan faktor resiko, keterbatasan dalam pendeteksian dini dan keterbatasan pengobatan efektif pada daerah tertentu [1], [2], [3].

Metode yang biasa dilakukan untuk mendiagnosis kanker kulit ialah metode biopsi. Metode Biopsi merupakan metode pengambilan sampel jaringan kulit untuk diperiksa secara histopatologis di laboratorium. Biopsi kulit dapat memberikan informasi mengenai jenis penyakit kulit, membantu dalam mendiagnosis pola spongiotic, mendiagnosis alopesia [4]

Alat bantu mikroskop cahaya (ILM) dan imunofluoresensi (IF) dapat memberikan gambaran lengkap terkait dengan diagnosis biopsi kulit. Alat bantu lain yang dapat digunakan dalam menunjang analisis kanker kulit yaitu penggunaan teknologi deep learning [5], [6]

Perkembangan teknologi deep learning menjadi peluang besar dalam bidang diagnosis medis yang dapat digabungkan dengan metode biopsi kulit tradisional. Penggabungan metode tradisional dengan teknologi modern seperti AI dan CNN. Penggabungan metode tradisional dan metode modern sangat menjanjikan untuk dapat melakukan peningkatan akurasi dan efisiensi diagnostik [4]

Penerapan *convolutional neural network* (CNN) telah dilakukan oleh beberapa peneliti seperti penelitian yang dilakukan oleh Musthafa (2024) tentang lesi dermatologis otomatis yang memperkenalkan klasifikasi lesi kulit. Penerapan CNN secara signifikan mampu meningkatkan tingkat akurasi diagnostik, penggunaan metode augmentasi data inovatif dapat mengatasi masalah ketidakseimbangan kelas dalam dataset HAM10000 sehingga mampu meningkatkan kekokohan model. Hasil penelitian Mustafa menunjukkan tingkat akurasi sebesar 97,78%, presisi sebesar 97,9%, recall 97,9%, dan skor F2 97,8% [7], [8], [9]

Arsitektur vgg-19 (*Visual Geometry Group-19*) merupakan salah satu tipe CNN dengan 19 lapisan (16 lapisan konvolusi dan 3 lapisan *fully connected*) [10]. Arsitektur VGG-19 cocok untuk klasifikasi gambar medis yang kompleks karena struktur jaringannya yang dalam dan kemampuan untuk mengekstraksi informasi visual dengan detail tinggi.

Penggunaan arsitektur vgg-19 telah mengalami perkembangan seperti penggunaan bersama dengan ResNet-50


[10], [11]. Namun, hasil akurasi yang diperoleh masih terbatas, yakni sebesar 65,33%, yang menunjukkan bahwa penggunaan metode *hybrid* tersebut belum optimal dalam menangani kompleksitas data citra kanker kulit. Peneliti lain telah menunjukan tingkat akurasi yang lebih baik sebesar 92,00%. Namun, penelitian ini memiliki keterbatasan pada area klasifikasi dengan hanya berfokus pada dua kelas atau biner (*Malignant* dan *Benign*).

Pada penelitian ini, penggunaan arsitektur VGG-19 murni yang dioptimasi untuk klasifikasi multi-kelas dengan jumlah kategori yang lebih luas. Kemudian, penggunaan dataset yang lebih besar secara signifikan diharapkan dapat memberikan generalisasi model yang lebih baik dibandingkan penelitian sebelumnya. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi kanker kulit berbasis *deep learning* dengan menggunakan arsitektur VGG-19. Pada penelitian, model dibuat secara otomatis dan mampu mengklasifikasi gambar citra kulit ke dalam sembilan kategori, yaitu *Basal Cell Carcinoma*, *Squamous Cell Carcinoma*, *Melanoma*, *Actinic Keratoses*, *Benign Keratosis-like Lesions*, *Dermatofibroma*, *Melanocytic Nevi*, *Seborrheic Keratosis*, dan *Pigmented Benign Keratosis*, serta satu kelas kulit sehat (*Healthy Skin*).

II. METODE PENELITIAN

A. Desain Penelitian

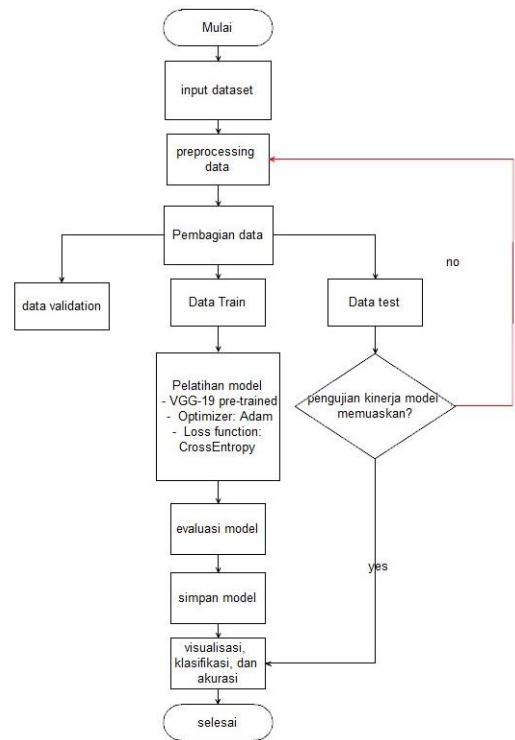
Tahapan penelitian disajikan pada gambar 1. Secara keseluruhan penelitian yang dilakukan meliputi studi literatur, pengumpulan dataset, perancangan sistem, implementasi model, pengujian sistem, hingga tahap akhir berupa analisis hasil pengujian.



Gbr.1 Diagram alir perancangan sistem

B. Desain Sistem

Diagram alir pada penelitian disajikan pada gambar 2.



Gbr. 2 Diagram Alir Perancangan Sistem

Proses dimulai dengan menjalankan program klasifikasi kanker kulit yang telah dibuat. Kemudian, gambar lesi kulit diunggah pada sistem dan diproses oleh model *deep learning* VGG-19. Model ini telah dilatih sebelumnya dengan menggunakan dataset gambar kulit dengan berbagai jenis penyakit. Model akan menganalisis gambar tersebut dan memberikan hasil klasifikasi, yaitu jenis penyakit kulit yang terdeteksi, beserta tingkat keyakinan atau *confidence* dari prediksi tersebut.


Setelah hasil klasifikasi ditampilkan, dilakukan evaluasi model untuk menilai performa prediksi, seperti akurasi, *precision*, *recall*, dan metrik lainnya. Evaluasi ini penting untuk mengetahui sejauh mana model bekerja dengan baik. Setelah semua proses selesai, sistem berakhir dan hasilnya bisa digunakan untuk keperluan analisis atau konsultasi medis lebih lanjut

C. Pengumpulan dan pengolahan Dataset

Dataset yang digunakan dalam penelitian ini bersumber dari *kaggle* dan *internasional skin imaging collaboration (ISIC)*.

1. Data awal


Data primer yang yang dikumpulkan berjumlah 4002 gambar citra kuit. Data ini mencakup 8 kategori penyakit kanker kulit.



Gbr. 3 Dataset Kanker [12]

2. *Preprocessing dan augmentasi*

Proses *preprocessing* (termasuk *resize* dan *normalize*) dan augmentasi citra digunakan untuk meningkatkan variasi data dan mengoptimalkan generalisasi model. Teknik yang diterapkan meliputi *random birghtness*, *contrast*, *affine*, *gaussian blur*, *horizontal flip*, dan *random resized crop*.



Gbr 4. Augmentasi Gambar [12]


3. *Total data*

Setelah melalui tahap augmentasi, total dataset meningkatkan dan meghasilkan 23.688 gambar citra kulit.

D. *Skenario Pembagian Dataset (Data Splitting)*

Total dataset adalah 23.688. Gambar didistribusikan ke dalam tiga subset yang berbeda sebelum proses pelatihan:

1. Data Training (70%) : sebanyak 15.750 gambar dialokasikan untuk melatih model mengenali fitur dan pola dari tiap keas.
2. Data validasi (20%) : sebanyak 5.216 gambar dialokasikan untuk melatih model selama proses training berlangsung dan mencegah *overfitting*.
3. Data Testing (10%) : sebanyak 2.722 gambar disishkan murni untuk menguji performa generalisasi model setelah proses training selesai.



Gbr 5. File yang dipersiapkan untuk *training*

E. *Lingkungan Pengembangan dan Konfigurasi Sistem*

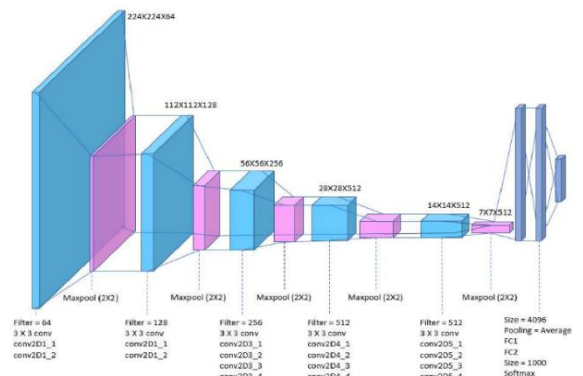
Proses pelatihan pada model vgg-19 dilakukan menggunakan hyparameter yang telah ditetapkan untuk mencapai hasil yang optimal. Pengaturan ini mengontrol bagaimana model belajar dari dataset yang diberikan.

TABEL I  
TABEL KONFIGURASI TRAINING

Parameter	Nilai / Konfigurasi
Model arsitektur	VGG-19
Epoch	200
Learning Rate	0.0001
Batch Size	32
Optimizer	Adam
Image Size	224 x 224
Use Sheduler	ya
Freeze Features	ya

F. *Implementasi dan pelatihan model VGG-19*

Penelitian ini memanfaatkan model convolutional neural network (CNN) dengan arsitektur VGG-19 *pre-trained*.



Gbr. 6 Arsitektur VGG-19

G. *Proses pelatihan*

Iterasi training melibatkan proses *forward pass* utuk kalkulasi loss menggunakan fungsi *CrossEntropyLoss*, dan *backward pass* untuk memperbarui bobot algoritma. Di akhir setiap epoch, model akan divalidasi dan performa *loss* serta akurasi divualisasikan, kemudian konfigurasi model terbaik akan otomatis disimpan di format *.pth* dan *.json*.

H. *Pengujian dan Evaluasi*

*Skenario Pengujian* : terdapat dua metode pengujian, yaitu secara otomatis pada set data testing dan pengujian secara masual menggunakan *graphical user interface* (GUI) mandiri dimana gambar di uji baru diunggah dan diprediksi probabilitas klasifikasinya (*confidence score*).

I. *Metrik evaluasi*

Kinerja sistem dianalisis menggunakan *confusion matrix* yang terdiri dari *true positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN).

		Actual Values	
		Positive (1)	Negative (0)
Predictive Values	Negative (0)	TP	FP
	Positive (1)	FN	TN

Gbr. 7 Tabel Confusion Matrix

1. Accuracy

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

2. Precision

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

3. Recall

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

4. F1-Score

$$F1\ Score = 2 \times \frac{Recall \times Precision}{Recall + Precision} \quad (4)$$

Keterangan :


- TP (*Trough positif*) : jumlah data aktual yang sebenarnya benar dan diprediksi.
- TN (*Through Negatif*) : jumlah data aktual yang sebenarnya salah dan diprediksi salah.
- FP (*False Positif*) : jumlah data aktual yang sebenarnya benar dan di prediksi salah.
- FN (*False Negatif*) : jumlah data aktual yang sebenarnya salah diprediksi benar.

III. HASIL DAN PEMBAHASAN

A. Hasil pelatihan Model (Training)

1) Grafik Hasil training

Proses pelatihan model VGG-19 dilakukan menggunakan dataset yang telah melalui tahap augmentasi, dengan total 15.750 gambar untuk data latih (*Training*) dan 5.216 gambar untuk data validasi.

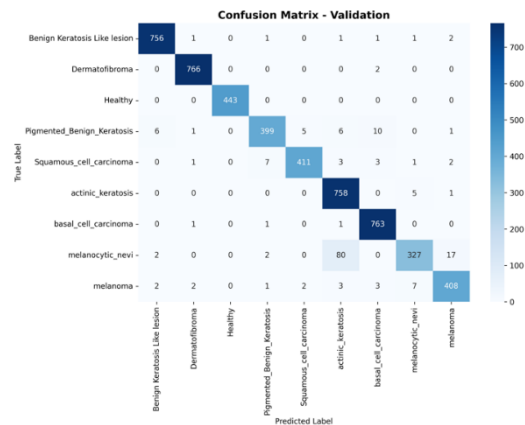


Gbr 8. Hasil Grafik training

Setelah melakukan proses training, model berhasil mencapai konvergensi yang baik tanpa menunjukkan *overfitting* yang signifikan. Hasil akhir pelatihan menunjukkan akurasi training mencapai 97.41% dengan nilai loss sebesar 0,0759. Pada data validasi, model mencapai akurasi sebesar 96.45% dengan nilai loss 0,011. Nilai loss yang rendah dan stabil di bawah 0.1 setelah epoch ke-50 menandakan bahwa prediksi model sudah sangat baik.

2) Confusion matrix hasil training secara otomatis

Performa model VGG-19 sudah cukup baik dalam mengklasifikasikan citra kanker kulit. Kemudian, performa terbaik model VGG-19 ada pada kelas *benign keratosis like lesion* dengan 756 (TP), 7 (FN) dan 10 (FP), *dermatofibroma* dengan 766 (TP), 2 (FN), 6 (FP), *healthy* dengan 443 (TP) 0 FN dan 0 (FP), *basal cell carcinoma* dengan 763 (TP), 3 (FN) dan 19 (FP). *Pigmented benign keratosis* dengan 399 (TP), 29 (FN) dan 12 (FP), *squamous cell carcinoma* dengan 411 (TP), 17(FN) dan 7 (FP), dan *melanoma* dengan 408 (TP) , 20 (FN) dan 23 (FP).



Gbr. 9 Confusion matrix hasil training

Performa terendah pada kelas *melanocytic nevi* dengan kelas *actinic keratosis* yang mana *melanocytic nevi* berhasil mengklasifikasi prediksi benar (TP) sebanyak 327 sampel, namun model salah mengklasifikasi (FN) 101 sampel, dan model juga salah, mengira data positif padahal aslinya negatif (FP) sebanyak 14 sampel. Lalu pada kelas *actinic*

keratosis model berhasil memprediksi benar (TP) sebanyak 758 sampel, namun model salah mengklasifikasi (FN) sebanyak 6 sampel, dan model juga juga salah, mengira data positif padahal aslinya negatif (FP) sebanyak 94 sampel.

3) Perhitungan metriks evaluasi pengujian secara otomatis

TABEL III  
PERCOBAAN TRAINING

Class	Precision	Recall	F1-Score
Benign keratosis like lesion	0.99	0.99	0.99
Dermatofibroma	1.00	1.00	1.00
Healthy	1.00	1.00	1.00
Pigmented Benign keratosis	0.97	0.93	0.95
Squamous cell carcinoma	0.98	0.96	0.97
Actinic keratosis	0.89	0.99	0.94
Basal cell carcinoma	0.98	1.00	0.99
Melanocytic nevi	0.96	0.76	0.85
Melanoma	0.95	0.95	0.95

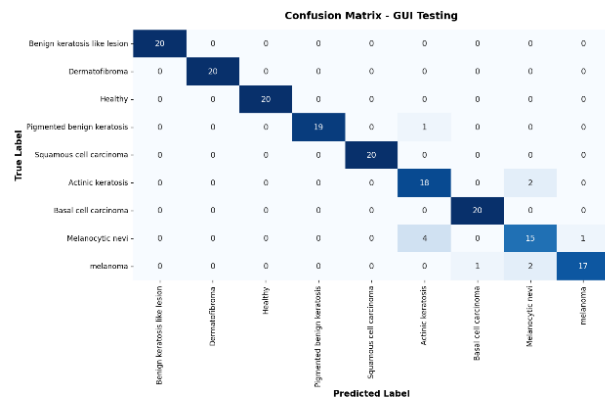
Berdasarkan hasil evaluasi pehitungan precision recall dan f1-score yang tunjukkan pada tabel, beberapa kelas seperti dermatofibroma dan healthy menunjukkan performa sempurna dengan nilai precision, recall dan f1-score mencapai 1.00, yang menandakan bahwa model mampu mengenali kedua kelas ini dengan akurasi penuh.

Kelas benign keratosis like lesion, squamous cell carcinoma, pigmented benign keratosis dan basal cell carcinoma juga memperoleh skor sangat tinggi, baik pada precision, recall, maupun f1-score, yang menunjukkan stabilitas model dalam mengenali kelas-kelas tersebut. Namun, performa model sedikit menurun pada kelas actinic keratosis dengan precision 0.89, recall 0.99 dan f-1 score 0.94. Hal ini menunjukkan bahwa model cenderung lebih banyak menghasilkan false positive dibanding kelas lainnya.

Kelas dengan performa terendah adalah melanocytic nevi dengan precision 0.96, recall 0.76 dan f-1 score 0.85. Nilai recall yang rendah menunjukkan bahwa cukup banyak sampel kelas ini yang tidak berhasil dikenali dengan benar (false negatif nya tinggi). Untuk kelas melanoma, model masih menunjukkan performa baik dengan precision 0.95, recall 0.95 dan f-1 score 0.95.

4) Confusion Matrix hasil training secara manual menggunakan GUI

Hasil pengujian pada tabel confusion matrix klasifikasi kanker kulit menggunakan metode vgg-19 pada data uji 20 gambar menunjukkan kinerja yang baik. Data menunjukkan bahwa 169 kanker kulit (True Positive) diprediksi dengan benar di sepanjang diagonal utama dari 180 data. Ini menghasilkan 11 kesalahan, termasuk 11 False negative (FN) dan 11 False positive (FP).



Gbr. 10 Confusion matrix data testing menggunakan GUI

Hasil pengujian pada kelas benign keratosis like lesion, dermatofibroma, healthy, squamous cell carcinoma, dan basal cell carcinoma menunjukkan 20 data uji dari kelas tersebut diklasifikasikan dengan benar. Kelas pigmented benign keratosis dan melanoma terjadi kesalahan minor, kelas pigmented benign keratosis mengklasifikasikan 19 dari 20 data uji. Hanya 1 gambar yang salah diklasifikasikan, yaitu sebagai actinic keratosis. Kelas melanoma berhasil mengklasifikasikan 17 dari 20 data uji. 3 gambar kelas melanoma salah di prediksi sebagai kelas lain. Kelas actinic keratosis dan melanocytic nevi menjadi kesalahan klasifikasi tertinggi. Kelas melanocytic nevi berhasil mengklasifikasi 15 dari 20 data uji, model mengklasifikasikan 5 gambar ke kelas lain dan 4 gambar diprediksi model sebagai kelas melanocytic nevi. Kelas actinic keratosis berhasil mengklasifikasi 18 dari 20 data uji, model salah mengklasifikasikan 2 gambar ke kelas lain dan 5 gambar di prediksi model menjadi kelas actinic keratosis.

5) Perhitungan metriks evaluasi pengujian secara manual menggunakan GUI

Tabel III menyajikan evaluasi performa klasifikasi yang diuji secara langsung melalui implementasi Graphical User Interface (GUI). Secara keseluruhan, pengujian berbasis antarmuka ini membuktikan keandalan model dengan pencapaian akurasi sebesar 93,89%.

TABEL IIIII  
Percobaan Training


Kelas	Presisi	Recall	F-1 Score
Benign Keratosis Like lesion	100%	100%	100%
Healthy	100%	100%	100%
Pigmented_Benign_Keratosis	100%	0,95%	97,4%
Squamous_cell_carcinoma	100%	100%	100%
actinic_keratosis	90%	79,1%	84,1 %
basal_cell_carcinoma	95,2%	100%	97,5%
melanocytic_nevi	79%	75,9%	76,9%
melanoma	94%	85%	89,2%
dermatofibroma	100%	100%	100%

Model menunjukkan performa identifikasi yang sempurna (Presisi, Recall, dan *F1-Score* mencapai 100%) pada kelas *Benign Keratosis Like lesion*, *Healthy*, *Squamous cell carcinoma*, dan *Dermatofibroma*. Sebaliknya, batasan performa model teridentifikasi pada kelas dengan karakteristik visual yang sangat mirip, di mana *Melanocytic nevi* dan *Actinic keratosis* mencatatkan nilai *F1-Score* terendah, yakni 76,9% dan 84,1%.


Hasil pengujian ini menegaskan bahwa sistem GUI yang dikembangkan sangat efektif dan siap digunakan untuk mendeteksi mayoritas jenis lesi kulit, meskipun masih memerlukan optimalisasi klinis untuk membedakan kelas-lesi tertentu yang identik secara visual.

6) Perbandingan dengan penelitian terlebih dahulu


Dalam menentukan model terbaik, dilakukan serangkaian pengujian dengan mengubah beberapa hyperparameter kunci.




Gbr. 11 Grafik pelatihan 1



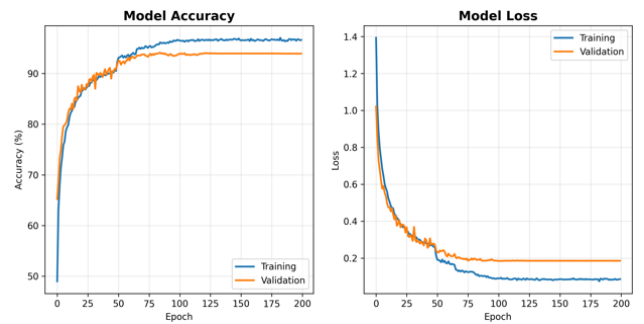
Gbr.12 Grafik pelatihan 2




Gbr. 13 Grafik pelatihan 3



Gbr 14 Grafik pelatihan 4



Gbr.15 Grafik pelatihan 5



Gbr. 16 Grafik Pelatihan 6

Untuk mendapatkan model dengan performa klasifikasi yang paling optimal, dilakukan enam skenario percobaan pelatihan menggunakan arsitektur VGG-19 dengan memvariasikan batas maksimal iterasi (*epoch*), penggunaan metode *early stopping*, serta proporsi distribusi dataset.

Pengamatan pada dataset berimbang (2000 data per kelas) menunjukkan bahwa pelatihan penuh selama 200 *epoch* (Pelatihan 1) Tabel IV menghasilkan akurasi 97,18% dengan *loss* 0,073, sedangkan penerapan *early stopping* (Pelatihan 2) menghentikan iterasi pada *epoch* 97 dan menurunkan akurasi menjadi 96,45% dengan *loss* 0,093. Dinamika yang berbeda terlihat pada distribusi 1500 data per kelas, di mana pelatihan penuh (Pelatihan 5) mencatatkan akurasi 97,04% dengan *loss* yang sangat stabil di angka 0,086. Sebaliknya, saat *early stopping* diterapkan pada distribusi ini (Pelatihan 6), iterasi terhenti sangat cepat di *epoch* 89 dengan lonjakan akurasi *training* hingga 98,40%. Meskipun akurasinya tampak tinggi, nilai *loss* pada skenario ini memburuk secara drastis menjadi 0,347. Lonjakan *loss* ini mengindikasikan ketidakstabilan

model dan adanya gejala *overfitting* pada data validasi, sehingga keandalan prediksinya diragukan untuk implementasi medis.

TABEL IVV  
PERCOBAAN TRAINING

Pelatihan	Epoch	Early stopping	Akurasi train	Loss model	Jumlah data
1	200	tidak	97.18%	0.073	2000/cls
2	97	ya	96.45%	0.093	2000/cls
3	120	ya	97.09%	0.078	Imbalan ce class
4	200	tidak	97.41%	0.11	Imbalan ce class
5	200	tidak	97.04%	0.086	1500/cls
6	89	ya	98.40%	0.347	1500/cls

Distribusi data penyakit kulit secara natural tidak pernah seimbang, pengujian pada dataset *imbalance* (Pelatihan 3 dan 4) menjadi tolak ukur yang paling merepresentasikan kondisi klinis yang sebenarnya. Pada pengujian ini, fitur *early stopping* (Pelatihan 3) memutuskan iterasi pada *epoch* 120 dengan akurasi 97,09% dan *loss* 0,078, yang menunjukkan bahwa model membutuhkan waktu konvergensi yang lebih lama untuk mempelajari pola fitur dari kelas-kelas minoritas. Oleh karena itu, model pada Pelatihan 4 yang dibiarkan berlatih secara penuh selama 200 *epoch* ditetapkan sebagai model final untuk sistem klasifikasi ini. Tanpa intervensi *early stopping*, model mampu mengekstraksi fitur kompleks secara maksimal pada dataset *imbalance* dan berhasil mencapai tingkat akurasi sebesar 97,41% dengan nilai *loss* yang tetap terkendali di 0,11.

Pemilihan Pelatihan 4 didasarkan pada pergerakan kurva *loss* yang konsisten menurun tanpa fluktuasi ekstrem, serta kemampuannya memanfaatkan seluruh alokasi 200 *epoch* untuk menajamkan pemahaman pada fitur-fitur visual yang sulit dibedakan, sehingga menghasilkan model dengan kemampuan generalisasi yang paling tangguh untuk kondisi nyata.

7) *Perbandingan dengan penelitian terlebih dahulu*

Tinjauan terhadap penelitian terdahulu menunjukkan adanya perkembangan yang signifikan dalam metode klasifikasi citra kanker kulit, mulai dari pendekatan *machine learning* konvensional hingga penggunaan *deep learning*.

Penelitian yang dilakukan oleh Faruk dan Nafi'yah (2020) mengawali perbandingan ini dengan menggunakan algoritma tradisional seperti SVM, KNN, dan Naive Bayes, di mana hasil akurasi tertinggi hanya mencapai 70,61% melalui metode KNN[13]. Keterbatasan ini kemudian mulai diatasi melalui integrasi teknik *preprocessing* dan penggunaan arsitektur berbasis *Convolutional Neural Network* (CNN).

TABEL V  
PERBANDINGAN PENELITIAN TERDAHULU

Judul	Metode	Dataset	Akurasi
Klasifikasi Jenis Kanker Kulit Menggunakan CNN-SVM	VGG-19, ResNet-50	-	VGG-19 = 65.33% ResNet-50 = 63,67%
Klasifikasi Kanker Kulit Berbasis CNN dengan Metode Hybrid Preprocessing	Hybrid Preprocessing	1530	78,19%
Klasifikasi Kanker Kulit Berdasarkan Fitur Tekstur, Fitur Warna Citra Menggunakan SVM dan KNN	SVM dan KNN	-	SVM = 69.85% KNN untuk K=5 69,55%
Segmentasi dan klasifikasi Gambar Citra pada Kanker Kulit Menggunakan Metode Convolutional Neural Network(CNN) dengan Arsitektu	ResNet-50	9605	92%
Klasifikasi Kanker Kulit menggunakan Metode Convolutional Neural Network dengan Arsitektur VGG-16	VGG-16	4000	99.70%
Klasifikasi Kanker Kulit Menggunakan metode VGG-19	VGG-19	23.688	97.41%

IV. KESIMPULAN DAN SARAN

Berdasarkan penelitian yang telah dilakukan, penelitian ini telah berhasil mengembangkan dan mengevaluasi model *deep learning* berbasis arsitektur vgg-19 untuk klasifikasi 9 jenis lesi kulit menggunakan dataset berskala besar yang terdiri dari 23.688 citra. Hasil pengujian menunjukkan bahwa arsitektur yang diusulkan memiliki performa yang sangat baik dengan tingkat akurasi pelatihan mencapai 97.41%. Evaluasi lebih lanjut membuktikan keunggulan model dalam menangani kondisi data yang tidak seimbang (*imbalanced data*), dibuktikan dengan akurasi pengujian berbasis antarmuka pengguna (GUI) menggunakan data uji seimbang menghasilkan akurasi sebesar 93.89%. Namun, model memiliki keterbatasan dalam melakukan klasifikasi/identifikasi antara kelas melanocytic nevi dan actinic keratosis secara konsisten. Berdasarkan hal tersebut, penelitian di masa mendatang akan memiliki potensi yang sangat baik jika melakukan kajian secara intensif terkait dengan klasifikasi/identifikasi antara kelas melanocytic nevi dan actinic keratosis secara konsisten.

## DAFTAR PUSTAKA

- [1] S. S. Virani, K. S. Ahmed, T. Jaraczewski, and S. N. Zafar, "Cancer research funding in South Asia," *J. Cancer Policy*, vol. 41, p. 100489, Sep. 2024, doi: 10.1016/J.JCPO.2024.100489.
- [2] A. J. Miller and M. C. Mihm, "Melanoma. The new England," *J. Med.*, vol. 355, no. 1, pp. 51–65, Jul. 2006, doi: 10.1056/nejmra052166.
- [3] E. Perera, N. Gnaneswaran, C. Staines, A. K. Win, and R. Sinclair, "Incidence and prevalence of non-melanoma skin cancer in Australia: A systematic review," *Australasian Journal of Dermatology*, vol. 56, no. 4, pp. 258–267, Nov. 2015, doi: 10.1111/AJD.12282.
- [4] N. Alwahaibi and M. Alwahaibi, "Mini review on skin biopsy: traditional and modern techniques," *Front. Med. (Lausanne)*, vol. 12, p. 1476685, 2025, doi: 10.3389/FMED.2025.1476685.
- [5] O. Akinrinade and C. Du, "Skin cancer detection using deep machine learning techniques," *Intell. Based. Med.*, vol. 11, p. 100191, Jan. 2025, doi: 10.1016/J.IBMED.2024.100191.
- [6] A. Esteva *et al.*, "Dermatologist-level classification of skin cancer with deep neural networks," *Nature*, vol. 542, no. 7639, pp. 115–118, Feb. 2017, doi: 10.1038/nature21056.
- [7] M. M. Musthafa, M. T R, V. K. V, and S. Guluwadi, "Enhanced skin cancer diagnosis using optimized CNN architecture and checkpoints for automated dermatological lesion classification," *BMC Med. Imaging*, vol. 24, no. 1, p. 201, Dec. 2024, doi: 10.1186/S12880-024-01356-8.
- [8] A. R. Ajel, A. Q. Al-Dujaili, Z. G. Hadi, and A. J. Humaidi, "Skin cancer classifier based on convolution residual neural network," *International Journal of Electrical and Computer Engineering*, vol. 13, no. 6, pp. 6240–6248, Dec. 2023, doi: 10.11591/IJECE.V13I6.PP6240-6248.
- [9] J. R. H. Lee, M. Pavlova, M. Famouri, and A. Wong, "Cancer-Net SCa: tailored deep neural network designs for detection of skin cancer from dermoscopy images," *BMC Med. Imaging*, vol. 22, no. 1, Dec. 2022, doi: 10.1186/S12880-022-00871-W.
- [10] B. H. Lifindra, D. Herumurti, and A. Yuniarti, "A Comparison of VGG Architecture Convolutional Layers in Migrating Batik Style into Fractal Shape," *2024 International Conference on Smart Computing, IoT and Machine Learning, SIML 2024*, pp. 268–273, 2024, doi: 10.1109/SIML61815.2024.10578183.
- [11] K. Kanwal *et al.*, "Efficient CNN architecture with image sensing and algorithmic channeling for dataset harmonization," *Scientific Reports 2025 15:1*, vol. 15, no. 1, pp. 7552–, Mar. 2025, doi: 10.1038/s41598-025-90616-w.
- [12] "ISIC Archive." Accessed: Jun. 02, 2026. [Online]. Available: <https://gallery.isic-archive.com/#!/topWithHeader/onlyHeaderTop/gallery?filter=%5B%5D&name=>
- [13] M. Yohannes, R., & Al Rivan, "Klasifikasi Jenis Kanker Kulit Menggunakan CNN-SVM," vol. 2, no. 2, pp. 133–144, 2022, doi: doi.org/10.35957/algorithm.v2i2.2363.