

# Klasifikasi Kanker Kulit menggunakan Convolutional Neural Network dengan Optimasi Arsitektur VGG16

Jesica Trivena Sinaga<sup>1\*</sup>, Haniifa Aliila Faudyta<sup>1</sup>, Egia Rosi Subhiyakt<sup>2</sup>

<sup>1</sup>Fakultas Ilmu Komputer, Teknik Informatika, Universitas Dian Nuswantoro, Semarang, Indonesia

<sup>2</sup>Research Center for Intelligent Distributed Surveillance and Security (IDSS), Universitas Dian Nuswantoro, Semarang, Indonesia

Email: <sup>1\*</sup>111202113808@mhs.dinus.ac.id, <sup>2</sup>111202113820@mhs.dinus.ac.id, <sup>3</sup>egia@dsn.dinus.ac.id

Email Penulis Korespondensi: 111202113808@mhs.dinus.ac.id

Submitted: 28/10/2024; Accepted: 01/12/2024; Published: 03/12/2024

**Abstrak**—Kanker kulit merupakan kondisi serius yang ditandai oleh pertumbuhan sel-sel kulit abnormal, sering kali dipicu oleh paparan sinar ultraviolet dan faktor genetik. Deteksi dini kanker kulit sangat penting untuk meningkatkan tingkat kesembuhan pasien, mengingat tingginya angka kejadian dan dampaknya yang signifikan. Penelitian ini bertujuan mengembangkan sistem klasifikasi kanker kulit menggunakan metode Convolutional Neural Network (CNN) dengan arsitektur VGG-16, yang terkenal efektif dalam analisis citra medis. Metode CNN dipilih karena kemampuannya dalam mengekstraksi fitur yang kompleks dari citra, sementara arsitektur VGG-16 dipilih karena kedalaman dan kemampuannya dalam menangkap detail halus dalam gambar, yang penting untuk membedakan antara jenis kanker kulit. Dataset yang digunakan diambil dari platform ISIC dan dioptimalkan melalui teknik augmentasi data untuk menangani masalah ketidakseimbangan data. Hasil penelitian menunjukkan bahwa meskipun CNN dasar dapat memberikan akurasi yang baik, penerapan arsitektur VGG-16 menghasilkan peningkatan akurasi yang signifikan. Model CNN dasar mencapai akurasi pelatihan sebesar 95,68% dan akurasi validasi 89,83%, sedangkan CNN dengan VGG-16 mencapai akurasi pelatihan 96,21% dan akurasi validasi 90,89%. Temuan ini mengindikasikan bahwa kombinasi CNN dengan VGG-16 efektif dalam mendeteksi kanker kulit, dengan VGG-16 memberikan sedikit peningkatan akurasi, menunjukkan potensi arsitektur ini sebagai alat pendukung diagnosis kanker kulit yang lebih akurat.

**Kata Kunci:** Kanker Kulit; Convolutional Neural Network; VGG16; Augmentasi Data; Klasifikasi Lesi

**Abstract**—Skin cancer is a severe condition characterized by the abnormal growth of skin cells, often triggered by ultraviolet exposure and genetic factors. Early detection of skin cancer is essential for improving patient recovery rates, given the high incidence and significant impact of the disease. This study aims to develop a skin cancer classification system using the Convolutional Neural Network (CNN) method with the VGG-16 architecture, known for its effectiveness in medical image analysis. The CNN method was chosen because it can extract complex features from images. At the same time, the VGG-16 architecture was selected for its depth and ability to capture fine details in images—critical for distinguishing between types of skin cancer. The dataset was sourced from the ISIC platform and optimized through data augmentation techniques to address data imbalance issues. The research results indicate that while a basic CNN can provide good accuracy, implementing the VGG-16 architecture significantly increases accuracy. The basic CNN model achieved a training accuracy of 95.68% and a validation accuracy of 89.83%, whereas the CNN with VGG-16 reached a training accuracy of 96.21% and a validation accuracy of 90.89%. These findings suggest that combining CNN with VGG-16 effectively detects skin cancer, with VGG-16 providing a slight accuracy improvement, highlighting this architecture's potential as a more accurate tool to support skin cancer diagnosis.

**Keywords:** Skin Cancer; Convolutional Neural Network; VGG16; Data Augmentation; Lesion Classification

## 1. PENDAHULUAN

Kulit merupakan organ terbesar dalam tubuh manusia yang bertanggung jawab untuk melindungi organ-organ internal. Terletak di seluruh permukaan tubuh, kulit berfungsi sebagai penghalang utama dari berbagai bahaya eksternal. Selain berperan sebagai pembungkus tubuh, kulit juga menjadi sistem pertahanan terdepan dalam menghadapi berbagai patogen berbahaya seperti virus, bakteri, dan zat-zat beracun yang dapat mengancam kesehatan tubuh [1]. Mengingat posisinya sebagai lapisan terluar tubuh, kulit sangat rentan terhadap berbagai gangguan kesehatan. Salah satu kondisi serius yang dapat menyerang kulit adalah kanker kulit.

Kanker kulit adalah kondisi medis yang serius yang ditandai dengan pertumbuhan sel-sel kulit yang tidak terkendali dan tidak normal [2], yang terutama disebabkan oleh paparan berlebihan terhadap radiasi sinar ultraviolet (UV-R) yang berdampak lebih parah pada individu dengan kadar melanin rendah di kulit, serta predisposisi genetik yang diwariskan dalam keluarga [3]. Berdasarkan data WHO tahun 2018, kasus kanker global mencapai 14 juta kasus baru dengan angka kematian melebihi 9,6 juta jiwa, di mana kanker kulit tercatat sebagai salah satu penyebab kematian tertinggi [4], sementara di Indonesia sendiri, data GLOBOCAN 2020 menunjukkan terdapat 1.609 kasus baru melanoma kulit dengan 699 kasus kematian[5].

Deteksi dini kanker kulit menjadi faktor krusial dalam meningkatkan tingkat kesembuhan pasien. Penelitian menunjukkan bahwa tingkat kesembuhan kanker kulit bisa mencapai lebih dari 90% jika terdiagnosis pada tahap awal. Sebaliknya, keterlambatan diagnosis secara signifikan menurunkan tingkat kesembuhan hingga kurang dari 50% [6]. Kondisi ini menunjukkan pentingnya upaya deteksi dini sebagai langkah penting dalam menangani kanker kulit. Namun, ada beberapa tantangan yang menghambat proses diagnosis dini, seperti keterbatasan akses ke dokter spesialis kulit, terutama di daerah terpencil atau pedesaan, serta biaya konsultasi yang relatif tinggi. Hal ini membuat banyak pasien terlambat mendapatkan penanganan yang tepat, sehingga menurunkan peluang kesembuhan mereka.

Perkembangan teknologi dalam mendeteksi kanker kulit telah mendorong berbagai penelitian, khususnya dalam penerapan kecerdasan buatan dan teknik *deep learning* untuk analisis citra medis, di mana teknik ini menunjukkan kemampuan luar biasa dalam mengelola gambar dengan detail halus serta memberikan hasil yang sangat akurat, dengan salah satu implementasinya adalah *Convolutional Neural Network (CNN)* [7]. *CNN* telah memperlihatkan performa yang sangat baik dalam aplikasi diagnosis medis berbasis citra, termasuk untuk mendeteksi kanker kulit [8]. Penelitian sebelumnya oleh Musthafa dkk pada tahun 2024, yang menunjukkan bahwa *CNN* yang dilatih dengan dataset HAM10000 mampu mencapai akurasi hingga 97,858% dalam mendiagnosis kanker kulit dan memiliki kemampuan luar biasa dalam membedakan berbagai jenis lesi kulit termasuk melanoma dengan menggunakan strategi augmentasi data yang optimal untuk meningkatkan representasi setiap kategori lesi selama pelatihan model [9].

Beberapa penelitian sebelumnya juga mendukung efektivitas penggunaan *deep learning* dalam deteksi kanker kulit. Sebagai contoh, penelitian yang dilakukan oleh Lailis Syafa'ah dkk pada tahun 2021, berhasil mengembangkan model *CNN* yang mencapai akurasi 94% dalam klasifikasi melanoma dan nevus melanocytic [10]. Sementara itu, penelitian yang dilakukan oleh Regita dkk pada tahun 2022, menggunakan arsitektur VGG-16 dengan dataset 4000 gambar, berhasil mencapai akurasi 99,70% dan f1-score 0,9950 tanpa menggunakan pre-processing tambahan [11]. Dalam penelitian lain, Findriyani dkk pada tahun 2024, mengimplementasikan *CNN* untuk klasifikasi kanker kulit jinak dan ganas menggunakan 2637 gambar dari Kaggle, yang mencapai akurasi 99,01% pada *epoch* ke-50 [12]. Penelitian komprehensif lainnya yang dilakukan oleh Dian dkk pada tahun 2022, menggunakan arsitektur AlexNet dengan dataset *ISIC* yang terdiri dari 4000 gambar (3200 untuk pelatihan, 800 untuk validasi), mencapai akurasi 99,50%, dengan presisi dan recall 99,75%, yang menunjukkan potensi sistem ini sebagai alat bantu diagnosis yang efektif bagi dokter spesialis kulit [13]. Penelitian oleh Rahardian dkk pada tahun 2024, menggunakan dataset yang sama menunjukkan bahwa metode *CNN* dengan augmentasi data mampu meningkatkan akurasi deteksi melanoma hingga 0.85301 pada data training, meskipun penggunaan Gaussian filter justru menurunkan akurasi pada pengujian, menunjukkan bahwa manipulasi dataset tidak selalu memberikan hasil yang lebih baik [14].

Dengan perkembangan teknologi, metode berbasis kecerdasan buatan seperti *deep learning*, khususnya *CNN*, menjadi sangat menjanjikan dalam klasifikasi penyakit kulit, terutama dalam konteks dataset yang tidak seimbang. *CNN* terbukti efektif dalam mengklasifikasikan gambar lesi kulit dan memiliki potensi besar dalam meningkatkan akurasi deteksi otomatis berbagai penyakit kulit, termasuk kanker kulit. Dalam penelitian ini, dilakukan percobaan untuk membandingkan performa *CNN* tanpa arsitektur khusus dan *CNN* dengan arsitektur *VGG-16*. Tujuannya adalah mengembangkan sistem klasifikasi penyakit kulit yang dioptimalkan menggunakan teknik augmentasi data guna mengatasi ketidakseimbangan dataset sekaligus meningkatkan akurasi model. Augmentasi seperti rotasi, flipping, dan *zooming* diterapkan pada dataset *Skin Cancer ISIC* dari *Kaggle* untuk membantu model mengenali variasi pola visual dari lesi kulit. Pendekatan ini tidak hanya berfokus pada peningkatan akurasi, tetapi juga pada penciptaan solusi yang lebih efektif untuk klasifikasi penyakit kulit dengan dataset yang tidak seimbang.


## 2. METODOLOGI PENELITIAN

### 2.1 Kajian Pustaka

Convolutional Neural Network (CNN) adalah jaringan saraf tiruan yang dirancang untuk analisis visual, khususnya dalam mendeteksi pola dan fitur dalam gambar, terinspirasi oleh sistem penglihatan manusia. CNN menggunakan lapisan konvolusi dan pooling untuk mengekstrak elemen penting dari citra, meningkatkan akurasi klasifikasi dan deteksi [15]. Salah satu arsitektur yang paling terkenal adalah Visual Geometry Group 16 (VGG-16), pengembangan dari AlexNet, yang menggunakan kernel kecil (3 x 3) dan terdiri dari 16 lapisan, termasuk 13 lapisan konvolusional dan 3 lapisan fully connected, dengan total 138 juta parameter [16]. Penelitian menunjukkan bahwa VGG-16 efektif dalam pengolahan citra dan memiliki potensi besar untuk klasifikasi penyakit kulit, menjadikannya pilihan yang relevan dalam pengembangan sistem klasifikasi berbasis CNN.

### 2.2 Tahapan Penelitian

Berdasarkan Gambar 1, alur penelitian ini mencakup pengumpulan data gambar kanker kulit, preprocessing, pembagian data menjadi training, validation, dan test set, serta data augmentation. Model kemudian dilatih menggunakan arsitektur CNN umum dan VGG-16, sebelum dievaluasi untuk mengukur performanya dalam klasifikasi kanker kulit.



Gambar 1. Metode Penelitian

Berdasarkan metode penelitian yang ditunjukkan pada gambar di atas, masing-masing tahap dalam penelitian ini dapat dijelaskan sebagai berikut :

- Pengumpulan Data, sebagai langkah awal yang sangat penting dalam proses penelitian dan pengembangan model machine learning, pengumpulan data untuk penelitian ini memanfaatkan platform *Kaggle* yang merupakan sumber daya terkemuka yang menyediakan beragam dataset dari berbagai sumber, mencakup kompetisi data, proyek penelitian, hingga kontribusi dari komunitas.
- Preprocessing* Data, dimana proses ini bertujuan untuk meningkatkan kualitas visual, mengurangi noise, dan menyesuaikan karakteristik gambar agar sesuai dengan kebutuhan analisis lebih lanjut, seperti yang diterapkan dalam pengolahan data citra kanker kulit [16]. Dimulai dengan memuat dataset dan menginisialisasi parameter pelatihan 25 epoch, learning rate 0,001, batch size 32. Gambar distandarisasi menjadi 224×224×3 piksel, diubah menjadi array numerik, dan dinormalisasi dari 0-255 ke 0-1 untuk mempercepat pelatihan model. Data yang telah dipreproses siap untuk analisis lebih lanjut, seperti klasifikasi atau segmentasi citra kanker kulit.
- Augmentasi citra adalah teknik dasar dalam pembelajaran mesin yang digunakan untuk memperluas variasi data pelatihan, terutama dalam penelitian dengan data terbatas seperti klasifikasi kanker kulit. Teknik ini mencakup transformasi seperti rotasi, pemotongan, perubahan skala, pergeseran, flipping, dan penambahan noise, sehingga dapat mengurangi risiko overfitting dan meningkatkan kemampuan generalisasi model pada data baru [17], [18]. Penelitian [19] menunjukkan bahwa augmentasi data pada model CNN meningkatkan akurasi klasifikasi kanker kulit hingga 90% melalui penggunaan dataset yang lebih besar dan teknik augmentasi yang beragam. Hal ini terjadi karena model menjadi lebih tangguh dalam mengenali objek di berbagai kondisi citra, sehingga augmentasi tidak hanya meningkatkan kemampuan model dalam mengklasifikasikan citra, tetapi juga menghasilkan prediksi yang lebih akurat dan andal.
- Training Model, dimana dataset yang telah diproses dengan teknik augmentasi dibagi menjadi data pelatihan dan validasi. Model CNN dilatih menggunakan algoritma optimasi Adam untuk mempercepat konvergensi dengan menyesuaikan bobot berdasarkan gradien dari loss function. Data pelatihan dibagi menjadi batch kecil untuk mempercepat pembaruan parameter. Model dilatih selama beberapa epoch, dengan evaluasi berkala untuk memantau kinerja pada data validasi.
- Pengujian Akurasi adalah metrik penting dalam evaluasi model pembelajaran mesin yang mengukur sejauh mana model mampu mengidentifikasi data dengan benar, yaitu dengan membandingkan jumlah prediksi yang benar terhadap total keseluruhan data yang diuji [20]. Perhitungan akurasi dilakukan menggunakan persamaan (1), yang menghitung proporsi prediksi yang tepat termasuk jumlah true positive (TP) dan true negative (TN) dibandingkan dengan keseluruhan data, yang juga mencakup false positive (FP) dan false negative (FN) [21].

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (1)$$

Seperti yang dijelaskan pada persamaan (2), precision adalah ukuran akurasi dari prediksi positif yang menunjukkan persentase prediksi positif yang benar, atau proporsi instance positif yang diprediksi dengan benar, dibandingkan dengan total prediksi positif yang dibuat oleh model.

$$precision = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

Recall mengukur seberapa baik model mendeteksi semua kasus positif. Ini memberikan proporsi kasus positif yang berhasil diprediksi dari keseluruhan kasus positif sebenarnya, seperti terlihat pada persamaan (3).

$$recall = \frac{TP}{TP+FN} \times 100\% \quad (3)$$

F1-Score adalah rata-rata harmonis dari precision dan recall, yang digunakan untuk mengatasi ketidakseimbangan kelas, terutama ketika ada perbedaan besar antara jumlah kelas positif dan negatif. Persamaannya ditunjukkan dalam persamaan (4):

$$F1 - score = 2 \times \frac{precision \times recall}{precision + recall} \quad (4)$$

### 3. HASIL DAN PEMBAHASAN

Bagian ini akan menjelaskan hasil penelitian yang dilakukan dan analisis terhadap berbagai eksperimen yang telah dilaksanakan. Penelitian ini fokus pada pengembangan model klasifikasi citra menggunakan Convolutional Neural Network (CNN) untuk mendeteksi penyakit kulit berdasarkan dataset dari ISIC. Dengan kemajuan teknologi pengolahan citra digital dan pembelajaran mendalam, penerapan metode CNN menjadi relevan dalam mendukung diagnosis penyakit kulit secara cepat dan akurat.

Model klasifikasi berbasis CNN ini bertujuan untuk mendeteksi penyakit kulit secara otomatis dari gambar dengan presisi tinggi. Dataset yang digunakan terdiri dari gambar penyakit kulit yang kompleks, sehingga memerlukan teknik pemrosesan data yang baik, termasuk preprocessing, augmentasi data, dan arsitektur jaringan yang optimal. Proses penelitian mencakup pengumpulan data, pengolahan awal, augmentasi, hingga pelatihan model menggunakan arsitektur CNN yang disesuaikan untuk klasifikasi.

Hasil penelitian menunjukkan bahwa model yang dikembangkan mampu mendeteksi penyakit kulit dengan baik berdasarkan gambar yang disediakan. Tingginya akurasi pelatihan dan konsistensi akurasi pada data validasi mengindikasikan performa model yang baik. Selama pelatihan, setiap epoch dievaluasi untuk melacak kinerja model dengan metrik seperti akurasi, ketepatan, recall, skor F1, serta visualisasi akurasi pelatihan dan validasi. Evaluasi ini memastikan bahwa model tidak hanya berfungsi dengan baik pada data pelatihan, tetapi juga mampu menggeneralisasi dengan baik pada data yang belum pernah dilihat sebelumnya.

### 3.1 Pengumpulan Data

Penelitian ini menggunakan dataset yang diambil dari *Kaggle Skin Cancer ISIC* dengan 2.239 citra dari sembilan kelas lesi kulit. Untuk rincian jumlah dan jenis lesi kulit dalam dataset ini, dapat dilihat pada Tabel 1.

**Tabel 1.** Dataset Kanker Kulit

No	Jenis	Jumlah Citra
1	<i>Vaskular Lesion</i>	139
2	<i>Melanoma</i>	438
3	<i>Basal Cell Carcinoma</i>	376
4	<i>Actinic Keratosis</i>	114
5	<i>Dermatofibroma</i>	95
6	<i>Squamous Cell Carcinoma</i>	181
7	<i>Pigmented Benign Keratosis</i>	462
8	<i>Nevus</i>	357
9	<i>Seborrheic Keratosis</i>	77

Pada Tabel 1, disajikan sembilan jenis kelas lesi kulit yang ada dalam dataset *Skin Cancer ISIC*, meliputi *Vascular Lesion*, *Melanoma*, *Basal Cell Carcinoma*, *Actinic Keratosis*, *Dermatofibroma*, *Squamous Cell Carcinoma*, *Pigmented Benign Keratosis*, *Nevus*, dan *Seborrheic Keratosis*.

### 3.2 Preprocessing Data

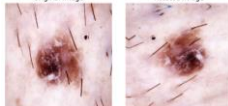
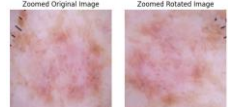
Proses *preprocessing* dimulai dengan menyesuaikan ukuran gambar menjadi  $224 \times 224$  piksel. Selama tahap pelatihan, digunakan *batch size* sebesar 32. Dataset kemudian dibagi menjadi dua bagian: data pelatihan dan data validasi, dengan perbandingan 80:20. Sebanyak 80% data digunakan untuk melatih model, sedangkan 20% sisanya digunakan untuk memvalidasi kinerja model selama proses pelatihan.

Langkah penting berikutnya adalah normalisasi data menggunakan *layer Rescaling*, yang membagi setiap nilai piksel dengan 255. Proses ini mengubah rentang nilai piksel dari 0-255 menjadi 0-1, yang bertujuan untuk mempercepat pelatihan dan memastikan model bekerja lebih efisien. Selain itu, normalisasi membantu mengurangi risiko gradien yang terlalu besar, yang dapat memperlambat konvergensi model selama pelatihan.

### 3.3 Augmentasi Data

Untuk mengatasi masalah ketidakseimbangan data antar kelas, dilakukan augmentasi data menggunakan pustaka *Augmentor*. Augmentasi ini penting karena ketidakseimbangan data dapat menyebabkan model cenderung bias terhadap kelas yang memiliki jumlah data lebih banyak, dan mengabaikan kelas dengan jumlah data yang lebih sedikit.

**Tabel 2.** Hasil Augmentasi Citra

Nama Layer	Deskripsi	Hasil Augmentasi
<code>layers.RandomRotation(0.2)</code>	Layer ini akan merotasi gambar secara acak hingga 20% dari 360°, yaitu sekitar $\pm 72$ derajat dari posisi aslinya.	
<code>layers.RandomZoom(0.2)</code>	Layer ini memperbesar atau memperkecil gambar hingga 20%, membuat objek terlihat lebih besar atau lebih kecil.	

Setelah dilakukan augmentasi untuk meningkatkan akurasi sebagaimana terlihat pada tabel 2, kemudian untuk masalah ketidakseimbangan data agar menghindari *overfitting* dilakukan rotasi hingga 10 derajat ke kiri atau ke kanan dengan probabilitas 70%. Proses ini menghasilkan 1.000 gambar per kelas dan meningkatkan kemampuan model dalam mengenali pola baru.

### 3.4 Training Model

Pada tabel 3 ditampilkan perbandingan dua arsitektur *CNN* untuk klasifikasi gambar. Pada tabel 3(a) *CNN tanpa arsitektur* menggunakan lapisan *rescaling* untuk menstandarkan input gambar, diikuti beberapa lapisan *Conv2D* dan

*MaxPooling2D* untuk ekstraksi fitur, serta *dropout* untuk mengurangi risiko *overfitting*. Model ini diakhiri dengan lapisan *flatten* dan *dense* untuk mengklasifikasikan gambar ke dalam 9 kelas. Optimizer *Adam* dengan *learning rate* sebesar 0,001 digunakan untuk memastikan pelatihan berjalan stabil dan cepat. Model ini dikompilasi menggunakan fungsi kerugian *SparseCategoricalCrossentropy* untuk klasifikasi multi-kelas, dengan metrik '*accuracy*' untuk memantau kinerjanya.

**Tabel 3.** Arsitektur Model CNN

Lapisan	Output Shape	Lapisan	Output Shape
<i>rescaling</i>	None, 224, 224, 3	<i>Inputlayer</i>	None, 224, 224, 3
<i>Conv2D</i>	None, 224, 224, 32	<i>Conv2D</i>	None, 224, 224, 64
<i>MaxPooling2D</i>	None, 112, 112, 32	<i>Conv2D</i>	None, 224, 224, 64
<i>Conv2D</i>	None, 112, 112, 64	<i>MaxPooling2D</i>	None, 112, 112, 64
<i>MaxPooling2D</i>	None, 56, 56, 64	<i>Conv2D</i>	None, 112, 112, 128
<i>Conv2D</i>	None, 56, 56, 128	<i>Conv2D</i>	None, 112, 112, 128
<i>MaxPooling2D</i>	None, 28, 28, 128	<i>MaxPooling2D</i>	None, 56, 56, 128
<i>Dropout</i>	None, 28, 28, 128	<i>Conv2D</i>	None, 56, 56, 256
<i>Conv2D</i>	None, 28, 28, 256	<i>Conv2D</i>	None, 56, 56, 256
<i>MaxPooling2D</i>	None, 14, 14, 256	<i>Conv2D</i>	None, 56, 56, 256
<i>Dropout</i>	None, 14, 14, 256	<i>MaxPooling2D</i>	None, 28, 28, 256
<i>Conv2D</i>	None, 14, 14, 512	<i>Conv2D</i>	None, 28, 28, 512
<i>MaxPooling2D</i>	None, 7, 7, 512	<i>Conv2D</i>	None, 28, 28, 512
<i>Dropout</i>	None, 7, 7, 512	<i>Conv2D</i>	None, 28, 28, 512
<i>Flatten</i>	None, 25088	<i>MaxPooling2D</i>	None, 14, 14, 512
<i>Dense</i>	None, 1024	<i>Conv2D</i>	None, 14, 14, 512
<i>Dense</i>	None, 9	<i>Conv2D</i>	None, 14, 14, 512
		<i>Conv2D</i>	None, 14, 14, 512
		<i>MaxPooling2D</i>	None, 7, 7, 512
		<i>GlobalAveragePooling2D</i>	None, 512
		<i>Dense</i>	None, 1024
		<i>Dropout</i>	None, 1024
		<i>Dense</i>	None, 9

(a) CNN tanpa arsitektur

(b) VGG-16

Sedangkan arsitektur pada tabel 3(b) menggunakan *VGG-16*, model CNN pra-terlatih yang dioptimalkan untuk ekstraksi fitur visual. *VGG-16* dimuat tanpa lapisan atas (fully connected layers) dan bobotnya dibekukan untuk mempertahankan nilai awal. Setelah itu, ditambahkan lapisan *GlobalAveragePooling2D*, lapisan *dense* dengan 1.024 neuron, dan *dropout* untuk mengurangi risiko *overfitting*. Di akhir arsitektur, digunakan lapisan *softmax* untuk menghasilkan probabilitas bagi setiap kelas.

Setelah tahap pelatihan awal dengan *learning rate* sebesar 0,0001, beberapa lapisan terakhir dibuka untuk proses *fine-tuning* menggunakan *learning rate* sebesar 0,00001. Langkah ini berhasil meningkatkan akurasi model dalam mengklasifikasikan dataset baru ke dalam 9 kelas.

**Tabel 4.** Hasil Pelatihan Model

Percobaan	Train Accuracy	Train Loss	Validation Accuracy	Validation Loss
CNN tanpa arsitektur	0.9568	0.1067	0.8983	0.4245
CNN dan VGG-16	<b>0.9621</b>	0.1106	0.9089	0.3472

Berdasarkan tabel 4 tersebut menunjukkan perbandingan performa antara CNN tanpa arsitektur dan CNN dengan VGG-16 dalam klasifikasi penyakit kulit. CNN dengan VGG-16 menunjukkan performa yang lebih baik dengan train accuracy 0.9621 dan validation accuracy 0.9089, sedangkan train loss 0.1106 dan validation loss 0.3472. Sementara itu, CNN tanpa arsitektur mencapai train accuracy 0.9568 dan validation accuracy 0.8983, dengan train loss 0.1067 dan validation loss 0.4245. Jika dibandingkan dengan penelitian oleh Rahardian dkk pada tahun 2024, yang menggunakan metode Gaussian pada dataset yang sama, dimana setelah dilakukan augmentasi data untuk menyeimbangkan data train hanya mencapai akurasi training 0.84929 dalam 30 epoch dan akurasi testing 0.4237, kedua model CNN dalam penelitian ini menunjukkan peningkatan performa yang signifikan [14]. Hal ini mengindikasikan bahwa pendekatan CNN, terutama dengan arsitektur VGG-16, lebih efektif dalam menangani klasifikasi penyakit kulit dibandingkan metode Gaussian.


### 3.5 Pengujian Model

Tahap pengujian dalam penelitian ini menggunakan dua model CNN yang berbeda untuk mengklasifikasikan penyakit kulit, dengan membandingkan kinerja antara model CNN tanpa arsitektur khusus dan model dengan arsitektur VGG-16. Analisis kinerja kedua model dilakukan secara komprehensif melalui beberapa tahapan evaluasi. Pertama, pengujian dilakukan dengan menganalisis grafik training dan validasi untuk memahami proses pembelajaran model selama 25 epoch. Selanjutnya, evaluasi performa menggunakan confusion matrix digunakan untuk mengidentifikasi

tingkat akurasi prediksi pada setiap kelas penyakit kulit. Selain itu, metrik evaluasi tambahan seperti precision, recall, dan F1-score juga dianalisis untuk mendapatkan pemahaman yang lebih mendalam tentang kemampuan model dalam mengklasifikasikan berbagai jenis lesi kulit. Penggunaan berbagai metrik evaluasi ini bertujuan untuk memastikan penilaian yang obyektif dan menyeluruh terhadap kemampuan kedua model dalam menjalankan tugas klasifikasi penyakit kulit.

### 3.5.1 Akurasi Model

Pada Gambar 2 ditampilkan perbandingan kinerja dua model *CNN* yang berbeda, yakni model *CNN* tanpa arsitektur khusus pada gambar 2(a) dan model dengan arsitektur *VGG-16* pada gambar 2(b), berdasarkan hasil pelatihan dan validasi selama 25 *epoch*. Pada model *CNN* tanpa arsitektur, grafik akurasi menunjukkan bahwa akurasi pelatihan meningkat dengan cepat, mencapai nilai yang cukup tinggi. Namun, akurasi validasi tetap lebih rendah dan cenderung stabil setelah sekitar 10 *epoch*, yang menandakan potensi *overfitting*. Fenomena ini menunjukkan bahwa model terlalu fokus pada data pelatihan dan kurang mampu menggeneralisasi dengan baik pada data baru. *Overfitting* juga terlihat dari grafik *loss*, di mana *loss* pelatihan terus menurun, tetapi *loss* validasi mulai naik setelah beberapa *epoch*, mengindikasikan bahwa performa pada data validasi menurun seiring waktu.

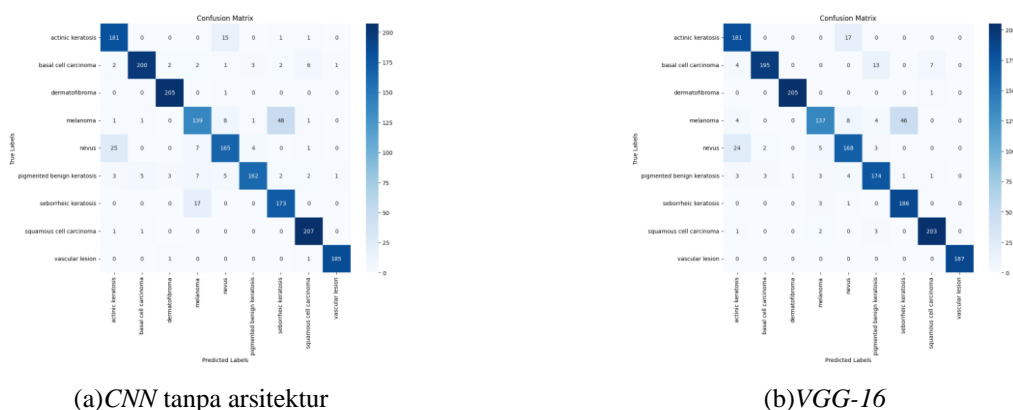


Gambar 2. Grafik training dan validasi

Sebaliknya, model *VGG-16* menunjukkan kinerja yang lebih baik dan stabil dalam hal generalisasi. Grafik akurasi untuk model ini menunjukkan peningkatan yang konsisten, baik pada data pelatihan maupun validasi, dengan kedua akurasi tersebut berdekatan sepanjang 25 *epoch*. Pada akhir pelatihan, akurasi mencapai sekitar 0,9 untuk kedua dataset, yang menandakan bahwa model ini mampu mengadaptasi pola pada data pelatihan tanpa mengorbankan performa pada data validasi. Grafik *loss* pada model *VGG-16* juga menunjukkan penurunan yang berkelanjutan pada *loss* pelatihan dan validasi, tanpa adanya peningkatan signifikan pada *loss* validasi, yang biasanya menjadi tanda *overfitting*. Dengan demikian, arsitektur *VGG-16* secara keseluruhan lebih stabil dan efektif, terutama dalam menjaga keseimbangan antara akurasi dan *loss*, menjadikannya pilihan yang lebih unggul dalam hal generalisasi dibandingkan model *CNN* tanpa arsitektur.

### 3.5.2 Evaluasi Model

Gambar 3 menggambarkan *confusion matrix* dari dua model klasifikasi penyakit kulit: model *CNN* tanpa arsitektur dan model dengan arsitektur *VGG-16*. Pada gambar 3(a), model *CNN* tanpa arsitektur menunjukkan performa yang lebih baik, ditandai dengan tingkat prediksi benar yang lebih tinggi pada diagonal matriks. Model ini berhasil mengidentifikasi *actinic keratosis* dengan benar sebanyak 181 kasus, *basal cell carcinoma* sebanyak 200 kasus, dan *vascular lesion* sebanyak 185 kasus. Namun, model ini juga mengalami beberapa kesalahan klasifikasi, seperti 48 kasus *melanoma* yang salah terdeteksi sebagai *seborrheic keratosis*, dan 25 kasus *nevus* yang salah diidentifikasi sebagai *actinic keratosis*.



Gambar 3. Confusion matrix klasifikasi kanker kulit

Sebaliknya, pada gambar 3(b), model dengan arsitektur *VGG-16* memiliki jumlah prediksi yang benar lebih rendah, tetapi masih mencapai akurasi yang cukup baik secara keseluruhan. *VGG-16* mampu mengidentifikasi *actinic keratosis* dengan benar pada 181 kasus, *basal cell carcinoma* pada 195 kasus, dan *vascular lesion* pada 187 kasus. Meski begitu, *VGG-16* juga memperlihatkan beberapa kesalahan klasifikasi yang serupa, seperti 46 kasus melanoma yang salah teridentifikasi sebagai *seborrheic keratosis*, dan 24 kasus *nevus* yang salah diidentifikasi sebagai *actinic keratosis*. Kedua model menunjukkan pola kesalahan yang serupa, tetapi model *CNN* tanpa arsitektur tampak lebih unggul dalam jumlah prediksi benar.

Pada Gambar 4 ditampilkan perbandingan hasil klasifikasi antara dua model yang digunakan untuk mendeteksi jenis-jenis lesi kulit. Model pertama, yang digambarkan pada gambar 4(a), adalah *CNN* tanpa arsitektur spesifik, sedangkan model kedua pada gambar 4(b) menggunakan arsitektur *VGG-16*. Kedua tabel ini menampilkan metrik evaluasi seperti *precision*, *recall*, *F1-score*, dan *support* untuk setiap kategori lesi kulit, memberikan gambaran detail tentang kemampuan masing-masing model dalam mengklasifikasikan data dengan benar. Model *CNN* tanpa arsitektur memiliki *F1-score* keseluruhan sebesar 0,90, meskipun ada variasi pada performa di setiap kelas. Misalnya, kelas melanoma menunjukkan *F1-score* yang relatif lebih rendah, yaitu 0,75, yang menunjukkan bahwa model ini kurang efektif dalam mengidentifikasi jenis lesi ini. Sebaliknya, kelas dermatofibroma menunjukkan performa yang sangat tinggi dengan *F1-score* mencapai 0,98. Rata-rata akurasi makro dan rata-rata tertimbang pada model ini adalah 0,90, yang mencerminkan performa yang seimbang di seluruh kelas.

	precision	recall	f1-score	support		precision	recall	f1-score	support
actinic keratosis	0.85	0.91	0.88	198	actinic keratosis	0.83	0.91	0.87	198
basal cell carcinoma	0.97	0.91	0.94	219	basal cell carcinoma	0.97	0.89	0.93	219
dermatofibroma	0.97	1.00	0.98	206	dermatofibroma	1.00	1.00	1.00	206
melanoma	0.81	0.70	0.75	199	melanoma	0.91	0.69	0.79	199
nevus	0.85	0.82	0.83	202	nevus	0.85	0.83	0.84	202
pigmented benign keratosis	0.95	0.85	0.90	190	pigmented benign keratosis	0.88	0.92	0.90	190
seborrheic keratosis	0.77	0.91	0.83	190	seborrheic keratosis	0.80	0.98	0.88	190
squamous cell carcinoma	0.95	0.99	0.97	209	squamous cell carcinoma	0.96	0.97	0.96	209
vascular lesion	0.99	0.99	0.99	187	vascular lesion	1.00	1.00	1.00	187
accuracy			0.90	1800	accuracy			0.91	1800
macro avg	0.90	0.90	0.90	1800	macro avg	0.91	0.91	0.91	1800
weighted avg	0.90	0.90	0.90	1800	weighted avg	0.91	0.91	0.91	1800

(a)*CNN* tanpa arsitektur

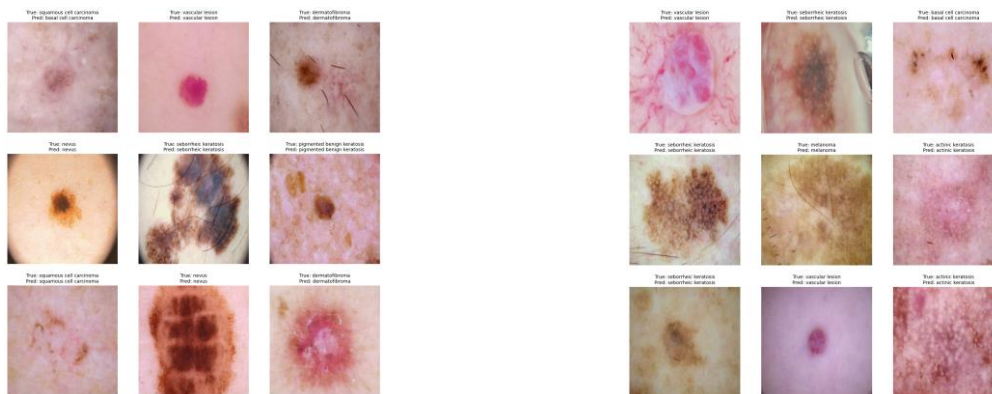
(b)*VGG16*

Gambar 4. Hasil Pengujian Model

Sebaliknya, model *VGG-16* menunjukkan performa yang lebih baik secara keseluruhan, dengan *F1-score* rata-rata sedikit lebih tinggi yaitu 0,91. Peningkatan performa terlihat pada kelas melanoma, yang *F1-score*-nya meningkat menjadi 0,79, menunjukkan perbaikan dalam mendeteksi jenis lesi yang lebih kompleks. Selain itu, kelas pigmented benign keratosis juga menunjukkan peningkatan *F1-score* menjadi 0,90, dibandingkan 0,83 pada model *CNN* tanpa arsitektur. Akurasi keseluruhan dan rata-rata tertimbang pada *VGG-16* adalah 0,91, sedikit lebih baik dibandingkan model tanpa arsitektur. Meskipun perbedaan performanya tidak terlalu besar, *VGG-16* secara konsisten lebih unggul dalam hal *F1-score* dan akurasi, terutama pada kelas yang lebih sulit diklasifikasikan. Hal ini menjadikan *VGG-16* sebagai arsitektur yang lebih efektif untuk tugas klasifikasi lesi kulit dalam skenario ini

### 3.5.3 Hasil Prediksi

Pada gambar 5 menunjukkan hasil klasifikasi citra lesi kulit menggunakan dua metode pembelajaran mendalam *CNN* tanpa arsitektur pada gambar 5(a) dan pada gambar 5(b) *VGG-16*. Pada gambar gambar 5(a), model *CNN* mendeteksi berbagai jenis lesi kulit seperti *nevus*, *basal cell carcinoma*, *vascular lesion*, dan lain-lain. Beberapa prediksi berhasil sesuai dengan diagnosis sebenarnya, namun ada juga yang salah, seperti pada baris pertama kolom pertama di mana model memprediksi *basal cell carcinoma* yang sebenarnya adalah *squamous cell carcinoma*.



(b)*CNN* tanpa arsitektur

(b)*VGG16*

Gambar 5. Hasil Prediksi Kanker

Dapat dilihat pada gambar 5(b), model *VGG-16* digunakan untuk tugas yang sama. *VGG-16* menunjukkan performa yang lebih konsisten dalam mengidentifikasi jenis lesi yang sesuai dengan label aslinya, misalnya pada prediksi *actinic keratosis* dan *seborrheic keratosis* yang benar pada beberapa kasus. Berdasarkan gambar keempat, terlihat bahwa model *VGG-16* lebih berhasil mendeteksi lesi kulit jenis *melanoma*, yang juga terkonfirmasi dengan prediksi yang benar dibandingkan model *CNN* tanpa arsitektur khusus.

#### 4. KESIMPULAN

Penelitian ini menunjukkan efektivitas penggunaan metode *CNN*, khususnya arsitektur *VGG-16*, dalam klasifikasi kanker kulit berbasis gambar dengan tingkat akurasi yang tinggi. Hasil eksperimen memperlihatkan bahwa model *CNN* dengan *VGG-16* lebih unggul dalam aspek generalisasi dibandingkan model *CNN* tanpa arsitektur khusus, terutama dalam mempertahankan akurasi yang konsisten pada data validasi. Teknik augmentasi data seperti rotasi, zooming, dan modifikasi lain turut memperkaya variasi visual pada dataset lesi kulit, yang berdampak positif pada peningkatan kemampuan model untuk mengenali pola lesi yang beragam dan mengurangi risiko *overfitting*. Penerapan arsitektur *CNN* yang optimal ini terbukti mampu mencapai akurasi pelatihan yang tinggi serta menjaga kestabilan loss model selama proses pelatihan, mencerminkan kapasitas model dalam mengenali dan mengklasifikasikan lesi kulit dengan akurat. Meskipun hasilnya menjanjikan, penelitian ini masih menghadapi keterbatasan, terutama pada keterbatasan jumlah data dan ketidakseimbangan kelas antar jenis lesi kulit, yang dapat memengaruhi performa model pada data baru. Dalam penelitian mendatang, disarankan untuk meningkatkan jumlah data, memperkaya variasi kelas, serta menggunakan teknik augmentasi lebih lanjut guna memaksimalkan kemampuan model. Selain itu, eksplorasi arsitektur *deep learning* lainnya seperti *ResNet* dan *EfficientNet* dapat dilakukan untuk perbandingan performa dan ketahanan model, sehingga pengembangan sistem klasifikasi kanker kulit dapat lebih optimal dan aplikatif dalam berbagai konteks medis, terutama dalam mendukung diagnosis dini kanker kulit pada masyarakat luas.

#### REFERENCES

- [1] Sofia Saidah, I. P. Y. N. Suparta, and E. Suhartono, "Modifikasi Convolutional Neural Network Arsitektur GoogLeNet dengan Dull Razor Filtering untuk Klasifikasi Kanker Kulit," *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, vol. 11, no. 2, pp. 148–153, May 2022, doi: 10.22146/jnteti.v11i2.2739.
- [2] R. R. Saputro, A. Junaidi, and W. A. Saputra, "Klasifikasi Penyakit Kanker Kulit Menggunakan Metode Convolutional Neural Network (Studi Kasus: Melanoma)," *Journal of Dinda : Data Science, Information Technology, and Data Analytics*, vol. 2, no. 1, pp. 52–57, Feb. 2022, doi: 10.20895/dinda.v2i1.349.
- [3] T. Saputra and M. E. Al-Rivan, "Analisis Performa ResNet-152 dan AlexNet dalam Klasifikasi Jenis Kanker Kulit," *STRING (Satuan Tulisan Riset dan Inovasi Teknologi)*, vol. 8, no. 1, p. 75, Aug. 2023, doi: 10.30998/string.v8i1.16464.
- [4] M. A. Kassem, K. M. Hosny, and M. M. Fouad, "Skin Lesions Classification Into Eight Classes for ISIC 2019 Using Deep Convolutional Neural Network and Transfer Learning," *IEEE Access*, vol. 8, pp. 114822–114832, 2020, doi: 10.1109/ACCESS.2020.3003890.
- [5] P. Muhammad, A. A. Lestari, K. Adistri, R. S. Amalia, and L. P. Wibawa, "Kriteria ABCDE untuk Deteksi Dini Keganasan Kulit," *Cermin Dunia Kedokteran*, vol. 49, no. 11, pp. 651–654, Nov. 2022, doi: 10.55175/cdk.v49i11.322.
- [6] D. A. Nurlitasari, R. Magdalena, and R. Y. N. Fu'adah, "ANALISIS PERFORMANSI SISTEM KLASIFIKASI KANKER KULIT MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK," *JOURNAL OF ELECTRICAL AND SYSTEM CONTROL ENGINEERING*, vol. 5, no. 2, pp. 91–99, Feb. 2022, doi: 10.31289/jesce.v5i2.5691.
- [7] R. Yohannes and M. E. Al Rivan, "Klasifikasi Jenis Kanker Kulit Menggunakan CNN-SVM," *Jurnal Algoritme*, vol. 2, no. 2, pp. 133–144, Apr. 2022, doi: 10.35957/algoritme.v2i2.2363.
- [8] F. Dartiko, R. J. Pradana, R. E. Sari, W. Syahputra, and W. K. Oktoeberza, "Klasifikasi Kanker Kulit Berbasis CNN dengan Metode Hybrid Preprocessing," *Medika Teknika : Jurnal Teknik Elektromedik Indonesia*, vol. 5, no. 2, pp. 124–132, Apr. 2024, doi: 10.18196/mt.v5i2.22675.
- [9] 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, Aug. 2024, doi: 10.1186/s12880-024-01356-8.
- [10] L. Syafa'ah, I. Hanami, I. Rusdia Sofiani, and M. Chasrun, "Skin Lesion Image Classification using Convolutional Neural Network," *Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control*, Nov. 2021, doi: 10.22219/kinetik.v6i4.1353.
- [11] R. AGUSTINA, R. MAGDALENA, and N. K. C. PRATIWI, "Klasifikasi Kanker Kulit menggunakan Metode Convolutional Neural Network dengan Arsitektur VGG-16," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 10, no. 2, p. 446, Apr. 2022, doi: 10.26760/elkomika.v10i2.446.
- [12] F. Findry and Rizal Adi Saputra, "Klasifikasi Kanker Kulit Berdasarkan Data Citra Benign Dan Malignant Menggunakan Convolutional Neural Network," *Jurnal Mahasiswa Teknik Informatika*, vol. 3, no. 1, pp. 1–9, Apr. 2024, doi: 10.35473/jamastika.v3i1.2417.
- [13] D. A. Nurlitasari, R. Magdalena, and R. Y. N. Fu'adah, "ANALISIS PERFORMANSI SISTEM KLASIFIKASI KANKER KULIT MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK," *JOURNAL OF ELECTRICAL AND SYSTEM CONTROL ENGINEERING*, vol. 5, no. 2, pp. 91–99, Feb. 2022, doi: 10.31289/jesce.v5i2.5691.
- [14] R. Yusuf, A. Rahman, F. Sthevanie, and G. Kosala, "Deteksi Kanker Kulit Melanoma Menggunakan Derivative of Gaussian dan Convolutional Neural Network," *Jurnal Penelitian Informatika*, vol. 2, pp. 1–5, 2024, doi: 10.25124/logic.v2i1.7529.



- [15] I. R. Muslem and T. M. Johan, “KLIK: Kajian Ilmiah Informatika dan Komputer Klasifikasi Citra Ikan Menggunakan Algoritma Convolutional Neural Network dengan Arsitektur VGG-16,” *Media Online*, vol. 4, no. 2, pp. 978–985, 2023, doi: 10.30865/klik.v4i2.1209.
- [16] A. E. Putra, M. F. Naufal, and V. R. Prasetyo, “Klasifikasi Jenis Rempah Menggunakan Convolutional Neural Network dan Transfer Learning,” *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, vol. 9, no. 1, p. 12, Apr. 2023, doi: 10.26418/jp.v9i1.58186.
- [17] D. A. Iskandar and A. Salam, “Evaluasi Performa Oversampling dan Augmentasi pada Klasifikasi Penyakit Kulit Menerapkan Convolutional Neural Network,” *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 8, no. 1, p. 240, Jan. 2024, doi: 10.30865/mib.v8i1.7119.
- [18] G. P. H. P. Gusti, E. Haerani, F. Syafria, F. Yanto, and S. K. Gusti, “Implementasi Algoritma Convolutional Neural Network (Resnet-50) untuk Klasifikasi Kanker Kulit Benign dan Malignant,” *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 3, pp. 984–992, Jun. 2024, doi: 10.57152/malcom.v4i3.1398.
- [19] A. Budhiman, S. Suyanto, and A. Arifianto, “Melanoma Cancer Classification Using ResNet with Data Augmentation,” in *2019 International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, IEEE, Dec. 2019, pp. 17–20. doi: 10.1109/ISRITI48646.2019.9034624.
- [20] M. Lestandy, “Deteksi Dini Kanker Payudara Menggunakan Metode Convolution Neural Network (CNN),” *Inspiration: Jurnal Teknologi Informasi dan Komunikasi*, vol. 12, no. 1, p. 65, Jun. 2022, doi: 10.35585/inspir.v12i1.2667.
- [21] M. F. Naufal, J. Siswanto, and M. G. K. Wicaksono, “Klasifikasi Tulisan Tangan Pada Resep Obat Menggunakan Convolutional Neural Network,” *Techno.Com*, vol. 22, no. 2, pp. 508–526, May 2023, doi: 10.33633/tc.v22i2.8075.