

# Interpretasi XAI untuk Meningkatkan Transparansi pada Klasifikasi Kanker Kulit Menggunakan CNN

## *XAI Interpretation to Enhance Transparency in Skin Cancer Classification Using CNN*

<sup>1</sup>Muhammad Abdul Ghofur\*, <sup>2</sup>Maria Ulfah Siregar, <sup>3</sup>Ahmad Bahrul Ulum

<sup>1</sup>Program Studi Sistem Informasi, Fakultas Sains dan Teknologi, Universitas Nahdlatul Ulama Sunan Giri, Bojonegoro

<sup>2,3</sup>Magister Informatika, Fakultas Sains dan Teknologi, UIN Sunan Kalijaga Yogyakarta

<sup>1</sup>Jl. Ahmad Yani No.10, Jamban, Sukorejo, Kec. Bojonegoro, Kabupaten Bojonegoro, Jawa Timur 62115, Indonesia

<sup>2,3</sup>Jl. Marsda Adisucipto, Catur Tunggal, Yogyakarta, Daerah Istimewa Yogyakarta 55281, Indonesia

\*e-mail: [ghofur@unugiri.ac.id](mailto:ghofur@unugiri.ac.id)

(received: 10 July 2026, revised: 25 August 2026, accepted: 26 August 2026)

### Abstrak

Kesehatan kulit merupakan aspek penting dalam menjaga kualitas hidup, sementara kanker kulit memerlukan deteksi dini untuk mendukung penanganan yang tepat. Penelitian ini mengeksplorasi penerapan Explainable Artificial Intelligence (XAI), khususnya LIME dan Eigen-CAM, untuk menginterpretasikan hasil klasifikasi biner kanker kulit, yaitu benign (jinak) dan malignant (ganas). Klasifikasi dilakukan menggunakan pendekatan transfer learning dengan arsitektur ResNet50, VGG16, EfficientNetB0, dan MobileNetV2 pada dataset sebanyak 2.000 citra kulit dengan jumlah data yang seimbang pada kedua kelas. Evaluasi model dilakukan menggunakan 5-fold cross-validation untuk memperoleh estimasi kinerja yang lebih konsisten pada data pengujian. Hasil pengujian menunjukkan bahwa ResNet50 memperoleh akurasi tertinggi sebesar 86,90%, diikuti VGG16 sebesar 85,90%, MobileNetV2 sebesar 84,90%, dan EfficientNetB0 sebesar 84,85%. Visualisasi menggunakan LIME dan Eigen-CAM menunjukkan bagian citra yang berkontribusi terhadap prediksi model, sehingga memberikan informasi tambahan untuk memahami dasar keputusan klasifikasi. Hasil tersebut menunjukkan bahwa XAI dapat digunakan sebagai pendekatan interpretatif untuk membantu memahami prediksi model dalam klasifikasi biner kanker kulit.

**Kata kunci:** CNN, Eigen-CAM, explainable AI, LIME, transfer learning

### Abstract

Skin health is a crucial aspect of maintaining quality of life, and skin cancer requires early detection to ensure appropriate treatment. This study explores the application of Explainable Artificial Intelligence (XAI)—specifically LIME and Eigen-CAM—to interpret binary skin cancer classification results (benign vs. malignant). Classification was performed using a transfer learning approach with ResNet50, VGG16, EfficientNetB0, and MobileNetV2 architectures on a dataset of 2,000 skin images, featuring a balanced distribution between the two classes. Model evaluation utilized 5-fold cross-validation to obtain more consistent performance estimates on the test data. Test results indicate that ResNet50 achieved the highest accuracy at 86.90%, followed by VGG16 (85.90%), MobileNetV2 (84.90%), and EfficientNetB0 (84.85%). Visualizations using LIME and Eigen-CAM highlighted the image regions contributing to model predictions, thereby providing additional insight into the basis of the classification decisions. These results demonstrate that XAI can serve as an interpretive approach to help understand model predictions in binary skin cancer classification.

**Keywords:** CNN, Eigen-CAM, explainable AI, LIME, transfer learning

## 1 Pendahuluan

Kulit merupakan salah satu organ tubuh manusia yang sangat penting karena kulit merupakan lapisan luar yang menutupi tubuh manusia. Kulit memiliki tiga lapisan yang terdiri dari lapisan kulit paling luar (*Epidermis*), lapisan kulit di bawah *Epidermis* (*Dermis*) dan lapisan kulit dalam

<http://sistemasi.ftik.unisi.ac.id>

(*Hipodermis*). Kulit merupakan bagian organ tubuh manusia yang terpapar langsung dengan matahari. Terpapar matahari berlebihan juga tidak baik untuk kulit karena dapat menyebabkan penyakit kanker kulit [1]. Infeksi *mikroorganisme*, lemahnya sistem kekebalan tubuh, reaksi alergi, dan kesehatan diri serta lingkungan yang buruk adalah beberapa faktor yang dapat menyebabkan penyakit dan gangguan kulit. Kanker kulit adalah salah satu penyakit berbahaya yang dapat menyerang kulit. Ini terjadi ketika karakteristik sel penyusun kulit berubah dari normal menjadi ganas, hal ini dapat menyebabkan sel membelah secara tidak terkendali dan merusak *Deoxyribonucleic Acid* (DNA) [2].

Menurut WHO, pada tahun 2020 tercatat 1,5 juta kasus kanker kulit, termasuk 325.000 kasus melanoma yang menyebabkan 57.000 kematian [3]. Umumnya, diagnosis dilakukan dengan dermatoskop dan dilanjutkan biopsi jika terindikasi kanker. Namun, biopsi bersifat invasif dan mahal, sehingga dibutuhkan alternatif diagnosis berbasis komputer yang lebih efisien dan non-invasif [3].

Diagnosis penyakit kulit harus dilakukan dengan hati-hati, karena kesalahan dalam penanganan dapat berakibat fatal [4]. Maka melalui fakta tersebut, deteksi dini merupakan salah satu cara untuk mengatasi penyakit kanker kulit. Akan tetapi, pakar dermatologis mengatakan bahwa adanya kesulitan dalam membedakan antara luka bakar dan tahi lalat [5]. Dokter dermatologis dapat mendiagnosis kanker kulit dengan melalui proses biopsi. Biopsi adalah pengambilan sejumlah kecil jaringan tubuh manusia untuk pemeriksaan laboratorium yang bertujuan untuk mendeteksi adanya suatu penyakit. Masalah ini menimbulkan ketertarikan dalam mengklasifikasikan citra kanker kulit untuk memudahkan diagnosis secara klinis [6]. Metode *deep learning* yang saat ini memiliki hasil paling signifikan dalam pengenalan citra adalah *convolutional neural network* (CNN) [7]. Hal tersebut dikarenakan CNN berusaha meniru sistem pengenalan citra pada *visual cortex* manusia sehingga memiliki kemampuan mengolah [5].

Penggunaan teknologi *deep learning*, khususnya *Convolutional Neural Network* (CNN), telah menjadi fokus penelitian yang sangat relevan karena kemampuan CNN untuk secara otomatis mengenali fitur-fitur yang penting dalam klasifikasi citra medis, membawa pengembangan dari diagnosis tradisional hingga diagnosis otomatis dengan tingkat kinerja yang sangat baik [8]. *Deep learning* memiliki kemampuan untuk membantu kehidupan manusia dengan memberikan akurasi tambahan dalam diagnosis penyakit kanker [1]. *Convolutional Neural Network* adalah bagian dari *deep learning* yang efektif digunakan untuk analisa gambar visual, deteksi objek atau *image*. *Convolutional Neural Network* terdiri atas sekumpulan lapisan yang dapat dikelompokkan berdasarkan fungsinya [9].

Dalam beberapa tahun terakhir, *deep learning* (DL) telah menunjukkan efektivitas yang tinggi dalam menganalisis citra medis [10], [11], [12], [13]. Model *Convolutional Neural Networks* (CNN), khususnya ResNet50, VGG16, EfficientNetB0, dan MobileNetV2, telah banyak diterapkan dalam berbagai tugas pengolahan dan klasifikasi citra medis, termasuk deteksi dan klasifikasi kanker kulit. Ketiga arsitektur tersebut memiliki karakteristik dan kompleksitas jaringan yang berbeda, sehingga dapat memengaruhi kemampuan model dalam mengekstraksi fitur serta performanya dalam mengklasifikasikan citra kanker kulit. ResNet50 [10] merupakan arsitektur CNN yang menerapkan konsep residual learning melalui residual connection untuk mempermudah proses pelatihan jaringan yang memiliki banyak lapisan. Mekanisme tersebut membantu mengurangi risiko vanishing gradient, sehingga proses pembelajaran fitur dapat berlangsung lebih efektif. Dengan kemampuan ekstraksi fitur yang baik, ResNet50 mampu menangani citra dengan karakteristik kompleks dan sesuai digunakan pada klasifikasi citra dengan dataset berskala besar. Arsitektur VGG-19 (Visual Geometry Group-19) merupakan salah satu tipe CNN dengan 19 lapisan, yang terdiri dari 16 lapisan konvolusi dan 3 lapisan fully connected, serta cocok digunakan untuk klasifikasi gambar medis yang kompleks karena struktur jaringannya yang dalam dan kemampuannya dalam mengekstraksi informasi visual secara detail [11]. MobileNetV2 merupakan arsitektur CNN yang dirancang untuk menghasilkan komputasi yang efisien dengan ukuran model yang relatif kecil. Arsitektur ini menggunakan depthwise separable convolution, linear bottleneck, dan shortcut connection untuk mengurangi kompleksitas komputasi tanpa mengurangi kemampuan model dalam mengekstraksi fitur secara signifikan. Karakteristik tersebut menjadikan MobileNetV2 sesuai untuk aplikasi klasifikasi citra yang membutuhkan keseimbangan antara akurasi, ukuran model, dan efisiensi komputasi [12]. Penelitian oleh [13] membandingkan ketiga arsitektur tersebut dan menunjukkan bahwa EfficientNet-B0 memberikan kinerja yang baik dari segi akurasi dan efisiensi.

Namun demikian, salah satu tantangan utama dalam penerapan CNN di bidang medis adalah sifatnya yang cenderung black box, yaitu sulit untuk dipahami oleh pengguna akhir, khususnya dokter

<http://sistemasi.ftik.unisi.ac.id>

atau pasien. Kurangnya transparansi dalam pengambilan keputusan model dapat menimbulkan keraguan dalam adopsi teknologi ini dalam praktik klinis [14]. Untuk mengatasi tantangan ini, pendekatan *Explainable AI* (XAI) mulai banyak digunakan untuk memberikan penjelasan yang dapat dimengerti oleh manusia mengenai bagaimana dan mengapa suatu prediksi dihasilkan oleh model.

Kebutuhan akan Artificial Intelligence yang Dapat Dijelaskan (XAI) telah muncul sebagai area penelitian dan pengembangan yang penting untuk mengatasi tantangan ini. Teknik XAI bertujuan untuk menjelaskan proses pengambilan keputusan sistem Artificial Intelligence, membuatnya lebih transparan, dapat ditafsirkan, dan pada akhirnya dapat dipercaya. Dengan memberikan penjelasan untuk keputusan yang dihasilkan Artificial Intelligence dengan cara yang dapat dipahami oleh manusia, XAI menjembatani kesenjangan antara algoritma Artificial Intelligence yang kompleks dan kebutuhan akan penalaran yang dapat dipahami [15]. Pendekatan Explainable Artificial Intelligence (XAI) digunakan sebagai penghubung antara hasil prediksi model dan penilaian klinis. Teknik XAI yang umum digunakan adalah LIME dan Eigen-CAM, yang dapat membantu memberikan interpretasi terhadap dasar pengambilan keputusan model. Makalah ini [16] memperkenalkan Eigen-CAM sebagai metode untuk meningkatkan interpretabilitas prediksi CNN dengan memvisualisasikan komponen utama dari representasi yang dipelajari pada lapisan konvolusional. Selain itu, metode Local Interpretable Model-Agnostic Explanations (LIME) digunakan untuk memberikan penjelasan lokal terhadap prediksi model dengan memanfaatkan model surrogate sederhana, seperti regresi linier, sehingga dapat mengidentifikasi kontribusi fitur input terhadap hasil prediksi [17].

Integrasi CNN dengan XAI memungkinkan pengembangan sistem klasifikasi kanker kulit yang tidak hanya akurat, tetapi juga transparan dan dapat dipercaya. Dengan memberikan visualisasi seperti heatmaps atau penjelasan berbasis fitur, XAI dapat meningkatkan interpretabilitas dan kepercayaan terhadap model, serta membantu dalam validasi klinis hasil diagnosis otomatis [18].

Oleh karena itu, penelitian ini bertujuan untuk membangun sistem klasifikasi kanker kulit menggunakan arsitektur CNN seperti ResNet50, VGG16, MobileNetV2, dan EfficientNetB0 yang dikombinasikan dengan metode XAI yaitu Eigen-CAM dan LIME, sehingga tidak hanya dapat mengidentifikasi jenis kanker kulit secara otomatis dan akurat, tetapi juga memberikan interpretasi yang dapat dipahami oleh manusia terhadap hasil klasifikasi yang dihasilkan. Dengan demikian, sistem ini diharapkan dapat berkontribusi dalam mendukung proses diagnosa medis yang lebih efektif, efisien, dan terpercaya.

## 2 Tinjauan Literatur


Berdasarkan penelitian terdahulu, *Convolutional Neural Network* (CNN) telah banyak digunakan dalam klasifikasi kanker kulit berbasis citra dengan berbagai arsitektur, seperti ResNet50, VGG16, EfficientNet, dan DenseNet, serta menunjukkan tingkat kinerja yang beragam. Beberapa penelitian juga mulai menerapkan *Explainable Artificial Intelligence* (XAI), seperti Grad-CAM, SHAP, dan LIME, untuk meningkatkan interpretabilitas dan membantu memahami dasar pengambilan keputusan model [19]. Meskipun demikian, penelitian terdahulu masih menunjukkan perbedaan dalam pemilihan arsitektur, skenario eksperimen, serta metode XAI yang digunakan, sehingga hasil performa dan interpretasi antarpenelitian belum dapat dibandingkan secara langsung. Selain itu, belum banyak penelitian yang melakukan evaluasi secara terpadu terhadap beberapa arsitektur CNN dengan menggunakan pendekatan XAI yang sama pada dataset klasifikasi kanker kulit. Oleh karena itu, penelitian ini melakukan perbandingan empat arsitektur CNN, yaitu ResNet50, VGG16, EfficientNetB0, dan MobileNetV2, untuk mengetahui kemampuan masing-masing model dalam mengenali citra kanker kulit. Evaluasi dilakukan menggunakan accuracy, precision, recall, F1-score, dan confusion matrix untuk memperoleh gambaran menyeluruh mengenai kemampuan klasifikasi setiap arsitektur, termasuk dalam membedakan kelas *Benign* dan *Malignant*. Selanjutnya, Eigen-CAM dan LIME diterapkan pada model untuk memberikan visualisasi dan interpretasi terhadap bagian citra yang berkontribusi terhadap hasil prediksi. Eigen-CAM digunakan untuk menunjukkan area visual yang memiliki pengaruh dominan terhadap keputusan model, sedangkan LIME memberikan penjelasan lokal mengenai bagian citra yang mendukung prediksi suatu kelas. Hasil visualisasi tersebut kemudian dianalisis untuk mengetahui apakah model lebih berfokus pada area lesi atau karakteristik kulit yang relevan dalam proses klasifikasi. Dengan demikian, penelitian ini tidak hanya berfokus pada pencapaian akurasi klasifikasi yang tinggi, tetapi juga mengevaluasi konsistensi dan keterjelasan keputusan model. Kontribusi penelitian terletak pada penyajian analisis komparatif terhadap performa dan

<http://sistemasi.ftik.unisi.ac.id>

interpretabilitas empat arsitektur CNN dengan dua pendekatan XAI, sehingga dapat memberikan informasi mengenai arsitektur yang memiliki keseimbangan terbaik antara kemampuan klasifikasi dan interpretabilitas dalam mendukung pengembangan sistem klasifikasi kanker kulit berbasis citra yang lebih transparan dan dapat dipercaya.

### 3 Metode Penelitian

Penelitian ini menggunakan desain eksperimental untuk mengevaluasi kinerja model klasifikasi dalam konteks klasifikasi kanker kulit. Penelitian ini melibatkan pelatihan beberapa model klasifikasi, yaitu ResNet50, VGG16, EfficientNetB0, dan MobileNetV2 dengan beberapa konfigurasi parameter untuk menentukan kombinasi yang optimal dalam klasifikasi kanker kulit pada citra medis. Selain itu, interpretasi hasil model dilakukan dengan menggunakan metode *Explainable AI* (XAI) untuk meningkatkan transparansi dan pemahaman terhadap keputusan model. Tahapan penelitian ini mencakup beberapa langkah utama seperti pengumpulan data, praproses data, model *deep learning*, split data, *training* model, evaluasi model, dan interpretasi XAI. Adapun tahapan dalam penelitian ini dapat dilihat pada Gambar 1.



Gambar 1 Metode penelitian

#### 3.1. Pengumpulan Data

Penelitian ini menggunakan dataset publik dari Kaggle berjudul Skin Cancer: Malignant vs. Benign (<https://www.kaggle.com/datasets/fanconic/skin-cancer-malignant-vs-benign>) yang terdiri atas citra RGB berukuran  $224 \times 224 \times 3$  piksel. Dataset awal berjumlah 3.297 citra, yang terdiri atas 1.800 citra kelas Benign (54,60%) dan 1.497 citra kelas Malignant (45,40%). Perbedaan jumlah antar kelas relatif kecil, dengan selisih 303 citra. Untuk memperoleh distribusi kelas yang lebih seimbang dalam proses eksperimen, penelitian ini menggunakan 2.000 citra, masing-masing 1.000 citra Benign dan 1.000 citra Malignant. Pemilihan sampel dilakukan secara acak dari masing-masing kelas dengan mempertahankan keterwakilan kedua kelas, bukan berdasarkan karakteristik atau tingkat keparahan lesi. Dengan demikian, proses seleksi tidak diarahkan untuk memilih citra dengan karakteristik tertentu yang dapat memengaruhi hasil klasifikasi. Data yang tidak terpilih tidak dihapus dari dataset asli, tetapi tidak digunakan dalam eksperimen penelitian ini. Rincian distribusi dataset sebelum dan setelah seleksi disajikan pada Tabel 1.

Tabel 1 Rincian jumlah dataset

| No | Kelas        | Jumlah |
|----|--------------|--------|
| 1  | Benign       | 1000   |
| 2  | Malignant    | 1000   |
|    | <b>Total</b> | 2000   |

#### 3.2. Praproses Data

Tahap praproses data dilakukan untuk menyiapkan citra sebelum digunakan dalam proses pelatihan model. Seluruh citra pada dataset diubah ukurannya menjadi  $224 \times 224$  piksel agar sesuai dengan kebutuhan arsitektur CNN yang digunakan. Selain itu, dilakukan normalisasi nilai piksel agar data lebih seragam dan mudah diproses oleh model. Proses praproses ini bertujuan untuk menjaga konsistensi ukuran dan kualitas data citra sehingga model dapat belajar secara optimal.

#### 3.3. Model Deep Learning

*Convolutional Neural Network* (CNN) adalah salah satu algoritma paling populer digunakan untuk *Deep Learning*, sebuah *machine learning* yang model pembelajarannya dikhususkan untuk melakukan klasifikasi langsung pada media dua dimensi seperti gambar, video, teks, atau suara. Algoritma CNN

akan sangat berguna khususnya ketika digunakan untuk mencari pola pada suatu gambar kemudian mengenali objek pada gambar tersebut [5]. Adapun arsitektur CNN yang digunakan pada penelitian ini sebagai berikut.

#### A. ResNet50

Microsoft Research Asia (MRA) pada tahun 2015 mengusulkan model jaringan saraf dalam dengan jaringan yang sangat dalam yang disebut ResNet, yang bertujuan untuk memastikan bahwa kinerja lapisan atas sama baiknya dengan lapisan di bawahnya tanpa gradien yang menghilang dan masalah optimasi. ResNet memenangkan kompetisi ILSVRC 2015 dengan arsitektur pada ResNet50, yang merupakan ResNet yang terdiri dari 50 lapisan. Seperti namanya, jaringan ini menggunakan pembelajaran residual. Secara sederhana, residual adalah proses pengurangan fitur yang telah dipelajari dari lapisan input [20].

#### B. Visual Geometry Group (VGG)

Visual Geometry Group (VGG) merupakan salah satu model arsitektur CNN yang diusul oleh K. Simonyan dan A. Zisserman dari Universitas Oxford pada kompetisi ILSVRC-2014. Arsitektur VGG16 berarti memiliki 16 kedalaman layer pada konfigurasi [21]. “Klasifikasi Kanker Kulit menggunakan Metode *Convolutional Neural Network* dengan Arsitektur VGG16” yang dilakukan oleh [22]. Penelitian ini menggunakan arsitektur VGG16 untuk klasifikasi 4 jenis penyakit kanker kulit yaitu *melanoma*, *karsinoma sel skuamosa*, *dermatofibroma* dan *nevus pigmentosus* yang berdasarkan dari jaringan kanker mendapatkan nilai akurasi diperoleh sebesar 99,70%.

#### C. EfficientNetB0

EfficientNetB0 merupakan varian dasar dari arsitektur EfficientNet yang dikembangkan oleh Google AI untuk menghasilkan model jaringan saraf yang efisien secara komputasi namun tetap memiliki kinerja tinggi. Arsitektur ini mengusung konsep smart scaling, yaitu peningkatan kedalaman, lebar, dan resolusi model secara proporsional guna mengoptimalkan efisiensi dan performa. Meskipun memiliki jumlah parameter paling sedikit dalam seri EfficientNet, EfficientNetB0 tetap efektif untuk tugas klasifikasi gambar. Model ini menggunakan blok berulang yang terdiri dari depthwise separable convolution dan fungsi aktivasi Swish untuk meningkatkan non-linearitas jaringan [23].

#### D. MobileNetV2

MobileNetV2 adalah salah satu arsitektur dari algoritma CNN yang biasa digunakan dalam mengatasi kebutuhan *resource* yang berlebih pada proses komputasi. Karena penggunaan *deep learning* sangat membutuhkan perangkat yang mempunyai untuk menjalankannya. Perbedaan umum antara arsitektur *MobileNet* dan algoritma CNN adalah penggunaan layer konvolusi. Versi kedua dari *MobileNet* dirilis pada april 2017 dan diberi nama MobileNetV2. Pada versi ini terdapat 2 fitur tambahan yang terdiri dari *Linear Bottleneck* dan *Shortcut Connecions* antar *Bottlenecks* [24]

### 3.4. Split Data

Pada tahapan ini, Pembagian data yang tepat antara pelatihan, validasi, dan pengujian (*train*, *validation*, dan *test sets*) memiliki dampak besar pada performa model [25]. Pada seluruh arsitektur yang digunakan, yaitu ResNet50, VGG16, MobileNetV2, dan EfficientNetB0, pembagian dataset dilakukan menggunakan metode K-Fold Cross Validation untuk memperoleh evaluasi kinerja model yang lebih konsisten dan mengurangi ketergantungan hasil terhadap satu pembagian data tertentu. Teknik ini merupakan metode statistik yang digunakan untuk mengevaluasi performa model secara menyeluruh. Selain itu, *K-Fold Cross Validation* juga efektif untuk mengoptimalkan atribut dan pengaturan parameter dalam proses pelatihan, sehingga menghasilkan model prediksi yang lebih akurat dan andal [26]. *K fold cross validation* digunakan untuk mengestimasi kesalahan prediksi dalam mengevaluasi kinerja model. Data dibagi menjadi himpunan bagian k berjumlah hampir sama. Model dalam klasifikasi dilatih dan diuji sebanyak k. Disetiap pengulangan, salah satu himpunan bagian akan digunakan sebagai data training dan data testing [27]. Langkah-langkah dari *k fold cross validation* yaitu:

A. Total data dibagi menjadi k bagian.

B. *Fold* ke-1 adalah ketika bagian ke-1 menjadi data uji (*testing data*) dan sisanya menjadi data latih (*training data*). kemudian, hitung akurasi atau kesamaan atau kedekatan suatu hasil pengukuran dengan angka atau data yang sebenarnya berdasarkan porsi data tersebut. Perhitungan akurasi tersebut menggunakan persamaan (1).

$$Akurasi = \frac{\sum datauji \text{ benar} \text{ klasifikasi}}{\sum total \text{ datauji}} \times 100 \quad (1)$$

- C. *Fold* ke-2 adalah ketika bagian ke-2 menjadi data uji (*testing data*) dan sisanya menjadi data latih (*training data*). kemudian hitung akurasi berdasarkan porsi data tersebut.
- D. Demikian seterusnya hingga mencapai *fold* ke-k. Hitung rata-rata akurasi dari k buah akurasi diatas. Rata-rata akurasi ini menjadi akurasi final.

### 3.5. Training Model

Pada tahap pelatihan (*training*), dilakukan pengaturan berbagai hyperparameter yang bertujuan untuk memastikan proses pelatihan model berjalan secara stabil, efektif, dan efisien. Beberapa jenis *optimizer* yang digunakan dalam penelitian ini meliputi *Adam*, *Adamax*, *Stochastic Gradient Descent* (*SGD*), dan *RMSprop*, yang masing-masing memiliki cara kerja berbeda dalam memperbarui bobot model selama proses pelatihan. Selain itu, digunakan variasi *batch size* sebesar 16, 32, 64, dan 128, yang menentukan jumlah sampel data yang diproses sebelum model melakukan pembaruan bobot. Jumlah *epoch* atau iterasi pelatihan juga divariasikan, yaitu sebanyak 10, 30, 50, dan 100 kali, untuk melihat bagaimana pengaruh durasi pelatihan terhadap kinerja model.

### 3.6. Evaluasi Model

Pada tahap ini, pengujian sistem dievaluasi menggunakan *Confusion Matrix* untuk menghitung nilai Akurasi, Presisi, *Recall*, dan *F-1 score* [3]. Adapun persamaan untuk menghitung nilai *accuracy*, *precision*, *recall*, dan *F-1 score* dapat dilihat pada persamaan (2), (3), (4), dan (5).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

$$F - 1score = 2X \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

True Positive (TP): Jumlah data positif yang diidentifikasi dengan benar oleh sistem. True Negative (TN): Jumlah data negatif yang diidentifikasi dengan benar oleh sistem. False Positive (FP): Jumlah data yang seharusnya negatif tetapi diklasifikasikan sebagai positif oleh sistem. False Negative (FN): Jumlah data yang seharusnya positif tetapi diklasifikasikan sebagai negatif oleh sistem.

### 3.7. Interpretasi XAI

Interpretasi Explainable Artificial Intelligence (XAI) pada penelitian ini difokuskan untuk menjelaskan proses pengambilan keputusan model CNN dalam klasifikasi kanker kulit. Explainable Artificial Intelligence (XAI) merupakan cabang dari Artificial Intelligence (AI) yang bertujuan meningkatkan transparansi dengan menjadikan hasil prediksi dan keputusan model lebih mudah dipahami manusia. Banyak model AI bekerja sebagai "black box", sehingga proses pengambilan keputusan sulit dimengerti pengguna. XAI hadir untuk mengembangkan metode yang memungkinkan pengguna memahami cara model menghasilkan prediksi dan keputusan [28]. Beberapa metode yang umum digunakan dalam XAI untuk meningkatkan pemahaman terhadap model meliputi:

#### A. LIME (Local Interpretable Model-agnostic Explanations)

Menurut penelitian dari [29] Teknik *Explainable AI* (XAI) menggunakan LIME (*Local Interpretable Model-agnostic Explanations*) dipilih karena mampu memberikan penjelasan yang lebih transparan dan mudah dipahami terkait rekomendasi yang dihasilkan oleh sistem. LIME bekerja dengan menghitung probabilitas kontribusi setiap fitur terhadap hasil prediksi. Selanjutnya, metode LIME akan diintegrasikan ke dalam model yang telah dibangun sebelumnya, yang menggunakan pendekatan *Collaborative Filtering* berbasis pengguna. Adapun rumus LIME dapat dilihat pada Persamaan (6).

$$\xi(x) = \underset{g \in G}{\operatorname{argmin}} \left( L^{\text{lime}}(f, g, \pi x^{\text{LIME}}) + \Omega(g) \right) \quad (6)$$

$f$  adalah model yang kompleks (seperti CNN).  $g \in G$  adalah model interpretable (seperti regresi linear atau pohon keputusan).  $\pi x$  adalah distribusi lokal di sekitar  $x$  yang digunakan untuk pembobotan sampel.  $\Omega(g)$  adalah fungsi regularisasi yang mengontrol kompleksitas model  $g$ , agar tetap mudah dipahami.  $L^{lim E}(f, g, \pi x^{LIME})$  adalah fungsi kuadrat kerugian yang mengukur jarak antara  $f$  dan  $g$  dengan  $G$  mewakili kelas penjelasan model ( $g \in G$ ).  $\pi x^{LIME}$  mewakili ukuran kedekatan di sekitar data input  $x$  yang akan dijelaskan.

## B. Eigen-CAM

Eigen-CAM mengembangkan teknik visualisasi dengan menggunakan komponen utama untuk menghasilkan peta aktivasi yang lebih efisien dan terperinci, memperkenalkan cara baru untuk mengeksplorasi area yang relevan dalam citra [30]. Penerapan metode visualisasi seperti Eigen-CAM pada citra melanoma juga dapat digunakan untuk menganalisis kesesuaian area yang disorot model dengan karakteristik klinis lesi kulit [31].

## 4 Hasil dan Pembahasan

### 4.1. Hasil Hyperparameter

Tabel 2 menunjukkan konfigurasi parameter pelatihan yang digunakan pada empat arsitektur Convolutional Neural Network (CNN), yaitu ResNet50, EfficientNetB0, VGG16, dan MobileNetV2. Seluruh model dilatih menggunakan optimizer Adam dengan batch size 64, ukuran citra masukan  $224 \times 224$  piksel, dan 50 epoch. Penggunaan konfigurasi yang seragam bertujuan untuk menjaga konsistensi proses eksperimen sehingga perbedaan performa yang dihasilkan lebih merepresentasikan karakteristik masing-masing arsitektur. Ukuran citra  $224 \times 224$  piksel dipilih karena sesuai dengan konfigurasi input umum pada model CNN berbasis transfer learning yang digunakan. Optimizer Adam digunakan untuk mengoptimalkan pembaruan bobot selama proses pelatihan, sedangkan batch size 64 menentukan jumlah citra yang diproses dalam satu iterasi pembaruan parameter. Selanjutnya, 50 epoch digunakan untuk memberikan kesempatan yang memadai bagi setiap model dalam mempelajari pola dan karakteristik citra pada dataset. Dengan konfigurasi tersebut, keempat arsitektur dapat dibandingkan secara lebih objektif berdasarkan metrik evaluasi yang diperoleh pada tahap pengujian.

**Tabel 2 Konfigurasi hyperparameter model**

| Model          | Optimizer | Batch Size | Image Size | Epochs |
|----------------|-----------|------------|------------|--------|
| ResNet50       | Adam      | 64         | 224x224    | 50     |
| EfficientNetB0 | Adam      | 64         | 224x224    | 50     |
| VGG16          | Adam      | 64         | 224x224    | 50     |
| MobileNetV2    | Adam      | 64         | 224x224    | 50     |

Tabel 3 menunjukkan hasil evaluasi empat arsitektur CNN menggunakan accuracy, precision, recall, dan F1-score. ResNet50 memperoleh hasil terbaik dengan accuracy 86,90%, precision 87,16%, recall 86,90%, dan F1-score 86,88%. VGG16 menghasilkan masing-masing 85,90%, 86,00%, 85,90%, dan 85,89%, sedangkan EfficientNetB0 memperoleh 84,85%, 84,92%, 84,85%, dan 84,84%. MobileNetV2 menghasilkan 84,90%, 84,91%, 84,90%, dan 84,90%. Selanjutnya, Eigen-CAM dan LIME diterapkan pada seluruh model untuk memberikan interpretasi terhadap area dan fitur citra yang berkontribusi terhadap prediksi benign dan malignant.

**Tabel 3 Hasil pelatihan model**

| Model    | Accuracy | Precision | Recall | F1-score | XAI                |
|----------|----------|-----------|--------|----------|--------------------|
| ResNet50 | 86.90%   | 87.16%    | 86.90% | 86.88%   | Eigen-CAM dan LIME |
| VGG16    | 85.90%   | 86.00%    | 85.90% | 85.89%   | Eigen-CAM dan LIME |


|                |        |        |        |        |                       |
|----------------|--------|--------|--------|--------|-----------------------|
| EfficientNetB0 | 84.85% | 84.92% | 84.85% | 84.84% | Eigen-CAM<br>dan LIME |
| MobileNetV2    | 84.90% | 84.91% | 84.90% | 84.90% |                       |

#### 4.2. Interpretasi Model XAI

Berdasarkan hasil evaluasi, model ResNet50 pada Skenario 3 menunjukkan performa terbaik dibandingkan seluruh kombinasi yang diuji. Model ini mencatat peningkatan signifikan di semua metrik evaluasi, termasuk *Accuracy*, *Precision*, *Recall*, dan *F1-score*, yang masing-masing mencapai 91%. Pencapaian ini menunjukkan bahwa model sangat andal dalam mendeteksi objek dengan tingkat kesalahan yang rendah. Untuk memberikan pemahaman lebih lanjut mengenai cara kerja model dalam mengambil keputusan, digunakan pendekatan *Explainable AI* (XAI) melalui teknik LIME dan Eigen-CAM, yang membantu menjelaskan area citra mana yang paling berpengaruh dalam proses klasifikasi Interpretasi pada ResNet50.

##### A. Visualisasi dengan Eigen-CAM


Visualisasi Eigen-CAM menunjukkan bahwa model paling banyak memusatkan perhatian pada area tengah objek, yang ditandai dengan warna merah sebagai tingkat aktivasi tertinggi. Warna kuning dan hijau menunjukkan aktivasi sedang, sedangkan biru dan ungu menunjukkan aktivasi rendah. Ketiga gambar memiliki pola fokus yang berbeda dalam bentuk dan luas area, tetapi secara umum model menggunakan fitur utama pada bagian tengah objek sebagai informasi penting dalam proses klasifikasi. Visualisasi ini juga membantu menginterpretasikan bagian citra yang paling berpengaruh terhadap keputusan model, yang terlihat pada Gambar 2.



Gambar 2 Hasil interpretasi Eigen-CAM

##### B. Visualisasi dengan LIME

Visualisasi Local Interpretable Model-Agnostic Explanations (LIME) menunjukkan bahwa model memanfaatkan karakteristik visual tertentu pada citra lesi kulit sebagai dasar dalam menghasilkan prediksi. Area yang diberi kontur kuning merepresentasikan wilayah yang dianggap relevan oleh model terhadap keputusan klasifikasi, terutama pada bagian yang memiliki perbedaan warna, tekstur, dan pola dibandingkan jaringan kulit di sekitarnya. Variasi nilai tick pada visualisasi menunjukkan tingkat kontribusi wilayah tersebut terhadap prediksi model. Hasil ini memperlihatkan bahwa LIME mampu mengidentifikasi dan memvisualisasikan fitur lokal yang menjadi pertimbangan model, sehingga proses klasifikasi dapat dianalisis secara lebih transparan dan interpretabel, sebagaimana ditunjukkan pada Gambar 3.



**Gambar 3 Hasil interpretasi LIME**

#### **4.3. Analisis Interpretasi XAI**

Dalam upaya meningkatkan transparansi dan interpretabilitas model klasifikasi kanker kulit berbasis CNN, penelitian ini menerapkan dua metode Explainable AI (XAI), yaitu Eigen-CAM dan LIME (Local Interpretable Model-Agnostic Explanations). Kedua metode digunakan untuk memberikan visualisasi mengenai bagian citra yang berkontribusi terhadap hasil prediksi model.

Hasil visualisasi Eigen-CAM menunjukkan bahwa area dengan aktivasi tinggi pada beberapa sampel cenderung berada di sekitar bagian lesi kulit. Area dengan intensitas warna yang lebih tinggi pada heatmap menunjukkan kontribusi aktivasi fitur yang lebih besar terhadap representasi visual yang dihasilkan model. Visualisasi tersebut digunakan untuk mengamati pola perhatian model terhadap citra pada masing-masing kelas. Pada beberapa citra benign, area aktivasi terlihat lebih menyebar dibandingkan citra malignant. Perbedaan pola tersebut dapat menjadi indikasi adanya variasi karakteristik visual yang dipelajari model, meskipun interpretasi tersebut bersifat visual dan tidak secara langsung membuktikan kesesuaian dengan karakteristik klinis.

Sementara itu, LIME memberikan interpretasi pada tingkat lokal dengan membagi citra menjadi beberapa superpixel dan mengidentifikasi bagian yang berkontribusi terhadap prediksi kelas tertentu. Hasil visualisasi menunjukkan bahwa pada beberapa sampel, superpixel yang berkontribusi terhadap prediksi berada di sekitar area lesi. Sementara itu, beberapa bagian latar belakang menunjukkan kontribusi yang relatif lebih rendah. Temuan tersebut mengindikasikan bahwa model pada sampel yang diamati cenderung menggunakan informasi dari area lesi dalam menghasilkan prediksi. Namun, hasil ini perlu dipahami sebagai interpretasi terhadap perilaku model dan bukan sebagai bukti klinis bahwa area tersebut merupakan indikator diagnostik.

Secara keseluruhan, Eigen-CAM dan LIME memberikan perspektif tambahan untuk memahami perilaku model selain metrik evaluasi klasifikasi. Visualisasi XAI memungkinkan identifikasi pola area citra yang menjadi perhatian model serta membantu menganalisis kasus prediksi yang benar maupun salah. Dengan demikian, XAI dalam penelitian ini berfungsi sebagai alat interpretasi dan analisis model, bukan sebagai bukti validitas klinis. Penggunaan kedua metode tersebut diharapkan dapat meningkatkan transparansi terhadap proses prediksi dan memberikan informasi tambahan mengenai karakteristik visual yang dimanfaatkan model dalam membedakan kelas benign dan malignant.

### **5 Kesimpulan**

Penelitian ini bertujuan meningkatkan transparansi model klasifikasi kanker kulit berbasis Convolutional Neural Network (CNN) melalui penerapan *Explainable AI* (XAI), yakni Eigen-CAM dan LIME. Eigen-CAM memvisualisasikan area inti citra yang paling memengaruhi prediksi, sedangkan LIME menyoroti segmen lokal yang berkontribusi terhadap kelas tertentu, sehingga membantu tenaga medis memahami dasar keputusan model. Hasil eksperimen menunjukkan ResNet50 memiliki performa terbaik dengan akurasi 86.90%, diikuti VGG16 85.90%, EfficientNetB0 84.85%, dan MobileNetV2 84.90%. Validasi silang 5-fold turut meningkatkan generalisasi model serta mengurangi risiko overfitting, menjadikan pendekatan ini andal dan transparan dalam mendukung diagnosis klinis. Pengembangan sistem klasifikasi kanker kulit disarankan menggunakan arsitektur ResNet50 atau VGG16 karena terbukti memberikan akurasi tinggi dan kinerja stabil, sementara EfficientNetB0 dan MobileNetV2 dapat menjadi alternatif efisien untuk perangkat dengan sumber daya

<http://sistemasi.ftik.unisi.ac.id>

terbatas. Penerapan teknik Explainable AI (XAI) sangat direkomendasikan agar hasil prediksi lebih transparan dan mudah dipahami tenaga medis, sehingga meningkatkan kepercayaan dalam keputusan klinis. Penelitian berikutnya dapat memperluas cakupan data dan mengeksplorasi arsitektur lain agar sistem lebih adaptif dan akurat di berbagai kondisi nyata.

## Referensi

- [1] M. Cnn-svm, "Klasifikasi Jenis Kanker Kulit Menggunakan CNN-SVM," vol. 2, no. 2, pp. 133–144, 2022.
- [2] I. Algoritma, C. Neural, K. Benign, and D. A. N. Malignant, "KULIT BENIGN DAN MALIGNANT," 2024.
- [3] U. Multi, D. Palembang, J. Rajawali, and N. Palembang, "Klasifikasi Kanker Kulit Pada Citra Dermatoskopi Menggunakan CNN 1,2," vol. 5, no. 1, 2024, <https://doi.org/10.35957/algoritme.v5i1.9034>.
- [4] F. Rhohman, D. Hariani, and A. P. Handoko, "Diagnosa Penyakit Kulit Dengan Sistem Pakar Berbasis Certainly Factor 1\*," *Inotek*, vol. 9, p. 2265, 2025.
- [5] D. P. Mawardi, M. Novita, N. D. Saputro, F. Teknik, and U. Pgri, "Deteksi Awal Klasifikasi Jenis Penyakit Kanker Kulit Dengan Algoritma Convolutional Neural Network ( CNN ) Berbasis Mobile Apps," vol. 3, no. 2, pp. 1–6, 2024.
- [6] A. Ajrana, A. Lawi, and A. M. A. Siddik, "... Dengan Pemilihan Model Transfer Learning Convolutional Neural Network Dalam Mengklasifikasikan Penyakit Kanker Kulit," *Semin. Nas. Tek. Elektro ...*, pp. 292–297, 2023, [Online]. Available: <https://share.google/9S4eXUh2DrpEGgVbz>
- [7] Nurlatifa, Nurhaeni, A. Hidayat, and M. R. A. Prasetya, "Metode Convolutional Neural Network (CNN) Untuk Klasifikasi Tingkat Kesehatan Tanaman Lidah Buaya Berbasis Web," *J. Tek. Inform. dan Sist. Inf.*, vol. 11, no. 4, pp. 392–406, 2024.
- [8] H. Galih Anggoro, Y. Fatma, Y. Rizki, and R. Firdaus, "Klasifikasi Citra Covid-19 Menggunakan Metode Deep Learning," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 5, pp. 11049–11054, 2024, doi: 10.36040/jati.v8i5.11990.
- [9] D. A. Nurlitasari *et al.*, "Performance Analysis of Skin Cancer Classification System Using Convolutional Neural Network," vol. 5, no. 2, 2022.
- [10] M. B. Kurniawan and E. Utami, "Perbandingan Kinerja ResNet50, VGG16, dan MobileNetV2 untuk Klasifikasi Tumor Otak pada Citra MRI Performance Comparison of ResNet50, VGG16, and MobileNetV2 for Brain Tumor Classification on MRI Images," *Sist. J. Sist. Inf.*, vol. 14, pp. 767–777, 2025.
- [11] A. Sani, E. Twins, R. Jannah, and B. Budiana, "Klasifikasi Kanker Kulit Menggunakan Metode VGG-19," pp. 176–183.
- [12] F. A. A. Harahap, A. N. Nafisa, E. N. D. B. Purba, and N. A. Putri, "Implementasi Algoritma Convolutional Neural Network Arsitektur Model Mobilenetv2 Dalam Klasifikasi Penyakit Tumor Otak Glioma, Pituitary Dan Meningioma," *J. Teknol. Informasi, Komputer, dan Apl. (JTika)*, vol. 5, no. 1, pp. 53–61, 2023, doi: 10.29303/jtika.v5i1.234.
- [13] H. M. Sani and A. K. Wardhana, "Addition of Non-Skin Classes in Skin Type Classification Using EfficientNet-B0 Architecture," *J. Appl. Informatics Comput.*, vol. 9, no. 5, pp. 2814–2821, 2025, doi: 10.30871/jaic.v9i5.10335.
- [14] W. Reinaldy, B. S. Negara, M. Irsyad, M. Affandes, and S. Agustian, "Penerapan Saliency Maps dalam Explainable AI Untuk Deteksi Penyakit Paru-Paru pada Citra X-Ray Dada dengan Deep Learning," vol. 7, no. 1, pp. 1–10, 2026, doi: 10.47065/tin.v7i1.9962.
- [15] J. Teknik, I. Cit, D. Kurniawan, and L. Pujiastuti, "Jurnal Teknik Informatika CIT Medicom yang dapat dipercaya Machine Translated by Google," vol. 15, no. 5, pp. 240–246, 2023.
- [16] M. Muhammad and M. Yeasin, "Eigen-CAM: Visual Explanations for Deep Convolutional Neural Networks," *SN Comput. Sci.*, vol. 2, Feb. 2021, doi: 10.1007/s42979-021-00449-3.
- [17] A. Gramegna and P. Giudici, "SHAP and LIME: An Evaluation of Discriminative Power in Credit Risk," *Front. Artif. Intell.*, vol. 4, no. September, pp. 1–6, 2021, doi: 10.3389/frai.2021.752558.
- [18] M. E. Ramadhan and J. Zeniarja, "Implementasi Deep Transfer Learning dan Explainable AI dalam Klasifikasi Kanker Kulit Implementation of Deep Transfer Learning and Explainable AI

<http://sistemasi.ftik.unisi.ac.id>

- in Skin Cancer Classification,” *Sist. J. Sist. Inf.*, vol. 14, no. 5, pp. 2266–2279, 2025, [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [19] D. K. Buatan, “(1) , 2),” pp. 622–627.
- [20] Q. A. Fitroh and S. Uyun, “Pembelajaran Transfer Mendalam untuk Meningkatkan Klasifikasi Akurasi Gambar Dermoskopi Kanker Kulit,” vol. 12, pp. 78–84, 2023.
- [21] S. Supirman, C. Lubis, D. Yulianto, and N. J. Perdana, “Klasifikasi Penyakit Kulit Menggunakan Convolutional Neural Network (Cnn) Dengan Arsitektur Vgg16,” *Simtek J. Sist. Inf. dan Tek. Komput.*, vol. 8, no. 1, pp. 135–140, 2023, doi: 10.51876/simtek.v8i1.217.
- [22] R. Agustina, R. Magdalena, and N. K. C. Pratiwi, “Klasifikasi Kanker Kulit menggunakan Metode Convolutional Neural Network dengan Arsitektur VGG-16,” *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 10, no. 2, p. 446, 2022, doi: 10.26760/elkomika.v10i2.446.
- [23] A. N. Fajrina, Z. H. Pradana, S. I. Purnama, and S. Romadhona, “Penerapan Arsitektur EfficientNet-B0 Pada Klasifikasi Leukimia Tipe Acute Lymphoblastik Leukimia,” *J. Ris. Rekayasa Elektro*, vol. 6, no. 1, p. 59, 2024, doi: 10.30595/jrre.v6i1.22090.
- [24] I. Mudzakir and T. Arifin, “Klasifikasi Penggunaan Masker dengan Convolutional Neural Network Menggunakan Arsitektur MobileNetv2,” *Expert J. Manaj. Sist. Inf. dan Teknol.*, vol. 12, no. 1, p. 76, 2022, doi: 10.36448/expert.v12i1.2466.
- [25] H. A. Wahyudi, D., Soesanti, I., & Nugroho, “Optimizing Hyperparameters of YOLO to Improve Performance of Brain Tumor Detection in MRI Images,” *2023 6th Int. Conf. Inf. Commun. Technol. (ICOIACT)*, pp. 413–418, 2023, [Online]. Available: <https://doi.org/10.1109/ICOIACT59844.2023.10455813>
- [26] W. Wijiyanto, A. I. Pradana, S. Sopingi, and V. Atina, “Teknik K-Fold Cross Validation untuk Mengevaluasi Kinerja Mahasiswa,” *J. Algoritma*, vol. 21, no. 1, pp. 239–248, 2024, doi: 10.33364/algoritma/v.21-1.1618.
- [27] L. Mardiana, D. Kusnandar, and N. Satyahadewi, “Analisis Diskriminan Dengan K Fold Cross Validation Untuk Klasifikasi Kualitas Air Di Kota Pontianak,” *Bul. Ilm. Mat. Stat. dan Ter.*, vol. 11, no. 1, pp. 97–102, 2022, [Online]. Available: <https://jurnal.untan.ac.id/index.php/jbmstr/article/view/51608>
- [28] L. Gilpin, L. H., Bau, D., Yuan, B. Z., Bajwa, A., Specter, M., & Kagal, “Explaining explanations: An overview of interpretability of machine learning,” *Proc. - 2018 IEEE 5th Int. Conf. Data Sci. Adv. Anal. DSAA 2018*, pp. 80–89, 2018, [Online]. Available: <https://doi.org/10.1109/DSAA.2018.00018>
- [29] M. T. Ribeiro, S. Singh, and C. Guestrin, “‘Why Should I Trust You?’ Explaining the Predictions of Any Classifier,” *NAACL-HLT 2016 - 2016 Conf. North Am. Chapter Assoc. Comput. Linguist. Hum. Lang. Technol. Proc. Demonstr. Sess.*, vol. 2016, no. 1, pp. 97–101, 2016, doi: 10.18653/v1/n16-3020.
- [30] A. Chattopadhyay, A. Sarkar, P. Howlader, and V. N. Balasubramanian, “Grad-CAM++: Generalized gradient-based visual explanations for deep convolutional networks,” *Proc. - 2018 IEEE Winter Conf. Appl. Comput. Vision, WACV 2018*, vol. 2018-Janua, pp. 839–847, 2018, doi: 10.1109/WACV.2018.00097.
- [31] M. Giavina-Bianchi, W. G. Vitor, V. Fornasiero de Paiva, A. L. Okita, R. M. Sousa, and B. Machado, “Explainability agreement between dermatologists and five visual explanations techniques in deep neural networks for melanoma AI classification,” *Front. Med.*, vol. 10, no. 1, 2023, doi: 10.3389/fmed.2023.1241484.