

Pemanfaatan Deep Learning untuk Klasifikasi Kanker Kulit Menggunakan Few-shot Learning Berbasis Prototypical Networks dan Backbone EfficientNet-B0

Wahyu Setianingsih*, Putry Wahyu Setyaningsih

Program Studi Sistem Informasi, Fakultas Teknologi Informasi, Universitas Mercu Buana Yogyakarta, Yogyakarta, Indonesia

Email: ^{1,*}211210051@student.mercubuana-yogya.ac.id, ²putryws@mercubuana-yogya.ac.id

Email Penulis Korespondensi: 211210051@student.mercubuana-yogya.ac.id

Submitted: 30/04/2025; Accepted: 31/05/2025; Published: 01/06/2025

Abstrak—Pemanfaatan *Artificial Intelligence* di era perkembangan teknologi saat ini semakin populer, khususnya di bidang kesehatan. Meningkatnya jumlah kasus kanker kulit secara global, menjadi perhatian khusus saat ini. Oleh karena itu, dikembangkanlah model klasifikasi dengan memanfaatkan *deep learning* untuk membantu proses diagnosis yang efektif. Namun, keterbatasan dan ketidakseimbangan data seringkali menjadi persoalan dalam pelatihan model klasifikasi kanker kulit. Penelitian ini mengembangkan model klasifikasi kanker kulit menggunakan pendekatan *Few-shot Learning* dengan arsitektur *Prototypical Networks* dan *backbone EfficientNet-B0*. Penelitian ini bertujuan untuk mengembangkan model klasifikasi kanker kulit berbasis citra dan mengevaluasi seberapa efektif performa model dalam mengklasifikasikan berbagai jenis lesi kulit. Hasil percobaan menunjukkan bahwa peningkatan k-shot berdampak positif terhadap akurasi model. Hasil terbaik didapat pada skema 10-shot 15-query dengan nilai akurasi 86,73% dan didukung oleh nilai ROC AUC sebesar 94%. Penelitian ini membuktikan bahwa pendekatan *Few-shot Learning* dengan arsitektur *Prototypical Networks* dan *backbone EfficientNet-B0* efektif untuk klasifikasi kanker kulit pada kondisi dataset terbatas. Model ini juga berpotensi menjadi alat bantu diagnosis dini.

Kata Kunci: Few-Shot Learning; Prototypical Networks; EfficientNet-B0; Kanker Kulit; Klasifikasi Citra Medis

Abstract—The utilization of Artificial Intelligence in the current era of technological development is increasingly popular, especially in the field of health. The increasing number of skin cancer cases globally is of particular concern today. Therefore, a classification model utilizing deep learning was developed to assist in the effective diagnosis process. However, data limitations and imbalances are often an issue in training skin cancer classification models. This research develops a skin cancer classification model using the Few-shot Learning approach with Prototypical Networks architecture and EfficientNet-B0 backbone. The research aims to develop an image-based skin cancer classification model and evaluate how effectively the model performs in classifying various types of skin lesions. Experimental results show that increasing k-shots has a positive impact on model accuracy. The best results were obtained in the 10-shot 15-query scheme with an accuracy value of 86.73% and supported by an ROC AUC value of 94%. This study proves that the few-shot learning approach with Prototypical Networks architecture and EfficientNet-B0 backbone is effective for skin cancer classification under limited dataset conditions. This model also has the potential to be an early diagnosis tool.

Keywords: Few-Shot Learning, Prototypical Networks, EfficientNet-B0, Skin Cancer, Medical Image Classification

1. PENDAHULUAN

Pemanfaatan kecerdasan buatan (*Artificial Intelligence*) di era perkembangan teknologi saat ini semakin populer dan menjadi pendorong utama transformasi digital di berbagai bidang. *Machine learning* dan *deep learning* merupakan dua bidang *Artificial Intelligence* yang berkembang pesat beberapa tahun terakhir. Keduanya melibatkan penggunaan algoritma untuk belajar data, dengan tujuan meningkatkan akurasi dan efisiensi prediksi atau pengambil keputusan [1]. Keunggulan utamanya adalah mengenali pola kompleks dalam data secara otomatis yang sulit dilakukan dengan metode konvensional. *Artificial Intelligence* sudah banyak diaplikasikan di bidang kesehatan, terutama dalam mendukung proses deteksi penyakit [1], [2], [3].

Meningkatnya jumlah kasus kanker kulit secara global, menjadi perhatian khusus saat ini. Berdasarkan data WHO pada tahun 2020, ada sekitar 1,2 juta kasus kematian akibat kanker kulit [4]. Kanker kulit merupakan kondisi di mana sel-sel pada lapisan luar kulit mengalami pertumbuhan yang tidak terkendali. Kondisi ini biasanya ditandai dengan perubahan dalam struktur kulit. Kanker kulit umumnya disebabkan oleh paparan sinar matahari atau sumber radiasi UV lainnya [2]. Kanker kulit dikelompokkan menjadi dua, yaitu jinak (*benign*) dan ganas (*malignant*) [5], [6]. Jenis kanker kulit yang dikelompokkan sebagai *benign*, yaitu *Melanocytic Nevus*, *Benign Keratosis* dan *Dermatofibroma*. Sementara itu, jenis kanker kulit yang dikelompokkan sebagai *malignant*, yaitu *Melanoma*, *Vascular Lesion*, *Basal Cell Carcinoma*, *Actinic Keratosis*, dan *Squamous Cell Carcinoma* [6].

Kanker kulit biasanya didiagnosis menggunakan metode biopsi dengan mengumpulkan sampel kecil pada jaringan kulit yang kemudian diuji di laboratorium. Namun, metode ini memiliki beberapa kekurangan seperti biaya yang mahal dan membutuhkan waktu yang lama untuk diagnosis, serta memungkinkan munculnya rasa tidak nyaman pada pasien [7], [8], [9]. Oleh karena itu, pengembangan sistem berbasis *Artificial Intelligence* di bidang medis menjadi solusi potensial untuk meningkatkan kecepatan dan ketepatan diagnosis oleh tenaga medis [5], [9], [10].

Pada kemajuan teknologi saat ini, berbagai penelitian telah mengembangkan model *deep learning* menggunakan arsitektur *Convolutional Neural Network* (CNN) untuk mendeteksi kanker kulit berbasis citra medis. Pada penelitian yang dilakukan di tahun 2024 [9], model seperti ResNet-50 menunjukkan akurasi yang cukup tinggi sekitar 94,88% untuk klasifikasi kanker kulit menjadi kategori jinak (*benign*) dan ganas (*malignant*). Ada pun model

lain yang juga telah diuji di tahun 2022, GoogLeNet menunjukkan hasil akurasi 97,73% [5]. Beberapa penelitian sebelumnya juga telah menerapkan *transfer learning* untuk meningkatkan akurasi dalam klasifikasi kanker kulit [4], [10]. Penelitian di tahun 2022 [4] menunjukkan bahwa model VGG-16 dan ResNet-50 dapat meningkatkan akurasi hingga 94%. Penelitian lainnya di tahun 2023 [6], memperoleh akurasi 90,63% menggunakan DenseNet121.

Penelitian sebelumnya menunjukkan nilai akurasi yang tinggi dalam klasifikasi kanker kulit berbasis citra medis. Namun, model-model tersebut membutuhkan dataset besar untuk dilatih, sedangkan dataset yang ada sering kali terbatas dan tidak seimbang. Data yang tidak seimbang dapat menyebabkan bias dalam model, di mana akan membuat model lebih cenderung mengenali kelas dengan jumlah yang lebih banyak, sehingga dapat mengurangi akurasi [3], [11]. Untuk mengatasi permasalahan ini, pendekatan *Few-shot Learning* dikembangkan sebagai solusi alternatif. Pendekatan *Few-shot Learning* memungkinkan model belajar dengan data yang terbatas [12], [13]. Klasifikasi menggunakan *few-shot* adalah tugas di mana pengklasifikasi harus disesuaikan untuk mengakomodasi kelas baru yang tidak terlihat dalam pelatihan dan hanya diberikan beberapa contoh dari masing-masing kelas [12].

Salah satu arsitektur pada pendekatan *Few-shot Learning* adalah *Prototypical Networks* (PNs). Penelitian di tahun 2023 dan 2024 [3], [11] menunjukkan bahwa *Prototypical Networks* mampu menghasilkan akurasi tinggi bahkan dalam skenario pelatihan terbatas. Skenario pelatihan yang umum dipakai yaitu 2-way 10-shot atau 5-way 5-shot. Penelitian lain di tahun 2024 dan 2025 [14], [15] juga menunjukkan jika integrasi *Prototypical Networks* dengan pendekatan *meta-learning* lain dapat meningkatkan kualitas representasi citra medis secara signifikan.

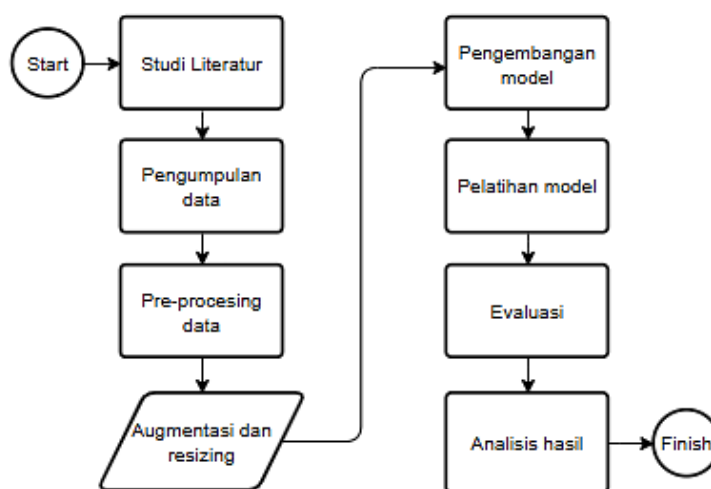
Pendekatan *Few-shot learning* dengan arsitektur *Prototypical Networks* digunakan sebagai pendekatan utama karena diharapkan dapat menjadi solusi alternatif untuk mengatasi keterbatasan dan ketidakseimbangan dataset [3], [11], [16]. Penelitian ini juga memanfaatkan *backbone EfficientNet-B0*, yaitu arsitektur ringan namun efisien dalam akurasi dan kompleksitas model [17], [18], [19]. *EfficientNet-B0* sudah banyak digunakan dalam berbagai kondisi, khususnya dalam klasifikasi citra medis dan hasil yang ditunjukkan cukup kompetitif dengan model lainnya [19]. Penerapan *Prototypical Networks* dan *backbone EfficientNet-B0*, diharapkan tidak hanya akurat, tetapi juga efisien dan dapat diimplementasikan secara luas.

Penelitian ini bertujuan untuk mengembangkan model klasifikasi kanker kulit berbasis citra dan mengevaluasi seberapa efektif performa model dalam mengklasifikasikan berbagai jenis lesi kulit pada dataset terbatas. Pengembangan model ini diharapkan bisa menjadi alat bantu untuk tenaga medis dalam mempercepat diagnosis dini kanker kulit dan meningkatkan kualitas diagnosis. Hasil penelitian ini juga diharapkan dapat berkontribusi dalam pengembangan sistem cerdas berbasis citra untuk deteksi kanker kulit dan memperkuat peran *Artificial Intelligence*.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menerapkan *deep learning* dengan pendekatan *Few-shot Learning* untuk klasifikasi kanker kulit menggunakan model *Prototypical Networks* dan *EfficientNet-B0* sebagai *backbone*. Alur sistematis yang digunakan dalam penelitian ini digambarkan pada Gambar 1. yang menunjukkan tahapan mulai dari studi literatur, pengumpulan data, *pre-processing* data, *Augmentasi dan resizing*, *Pengembangan model*, *Pelatihan model*, *Evaluasi*, *Analisis hasil*, hingga analisis hasil.



Gambar 1. Alur Penelitian

2.2 Studi Literatur

Studi literatur dilakukan untuk mengumpulkan informasi mengenai kanker kulit dan *deep learning* sebagai bahan referensi dalam implementasi *deep learning* pada klasifikasi kanker kulit. Selain itu, studi literatur digunakan untuk

mencari tahu lebih lanjut mengenai kelebihan dan kekurangan penelitian sebelumnya, sehingga harapannya penelitian ini dapat menyempurnakan apa yang menjadi celah dalam penelitian sebelumnya.


2.3 Pengumpulan Dataset

Penelitian ini akan menggunakan dataset dari Kaggle (Skin Cancer: Malignant vs. Benign) dengan total data train sebesar 2637 dan data test sebesar 660. Dataset ini terdiri dari gambar-gambar kanker kulit yang dikelompokkan ke dalam dua kelompok, yaitu jinak (benign) dan ganas (malignant). Distribusi data disajikan seperti pada Tabel 1, sedangkan untuk contoh data citra yang digunakan ditampilkan pada Gambar 2.

Tabel 1. Data Citra Kanker Kulit

Jenis Kanker	Train	Test
Jinak (Benign)	1440	360
Ganas (Malignant)	1197	300

Tabel 1 menjelaskan terkait distribusi dataset, dimana pada data train terdapat 1440 data citra *benign* dan 1197 data citra *malignant*. Sedangkan untuk data test terdapat 360 data citra *benign* dan 300 data citra *malignant*.



Gambar 2. Data Citra Kanker Kulit

Gambar 2 memperlihatkan beberapa contoh data yang akan digunakan dalam penelitian ini, di mana baris atas memperlihatkan data *benign* dan baris bawah memperlihatkan data *malignant*.

2.4 Pre-processing Data


Pada tahap *pre-processing* data, data yang telah dikumpulkan akan di proses untuk dipersiapkan ke tahap permodelan arsitektur. Hal ini bertujuan agar data gambar sesuai dengan kebutuhan arsitektur model yang digunakan. Proses *pre-processing* mencakup normalisasi data, augmentasi data dan *resizing*. Format data gambar diubah menjadi RGB untuk menyamakan kanal warna dan di-resize menjadi ukuran 224x224 piksel sesuai dengan ukuran input standar *EfficientNet* [17]. Augmentasi data dilakukan untuk meningkatkan variasi data, proses ini memanfaatkan *library albumentations*. Beberapa transformasi yang diterapkan adalah rotasi, *flip*, *brightness & contrast adjustment*, *HSV shift*, dan normalisasi [6], [10].

2.5 Permodelan Arsitektur

Pada tahap permodelan arsitektur ini menggunakan *Prototypical Networks* dan *EfficientNet-B0* sebagai *backbone* untuk mengekstraksi fitur gambar.

2.5.1 Prototypical Networks

Prototypical Networks adalah arsitektur *Few-shot Learning* yang digunakan untuk mengatasi tantangan klasifikasi dengan jumlah data terbatas [12]. *Prototypical Networks* termasuk ke dalam *meta-learning* berbasis metrik, yang di mana proses pengenalannya membandingkan jarak antara prototipe kelas yang telah dipelajari dengan representasi data [12], [20]. Arsitektur ini terbukti efektif dalam skenario data terbatas [3], [11], [13]. Penjelasan lebih lanjut mengenai cara kerja *Prototypical Networks* digambarkan seperti pada Gambar 3.



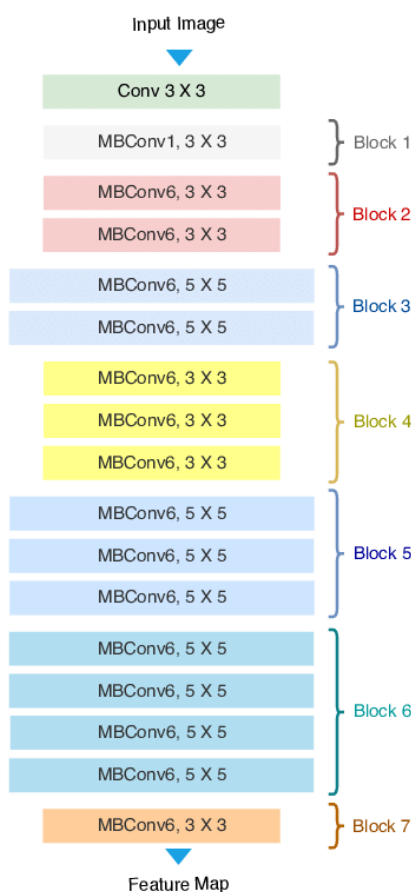
Gambar 3. Prototypical Networks Few-shot

Gambar 3 menggambarkan ruang *embedding* atau *feature space* yang di mana memperlihatkan representasi vektor dari suatu sampel gambar setelah diproses oleh *embedding function*. Titik c_1, c_2, c_3 adalah prototipe dari masing-masing kelas yang dihitung sebagai rata-rata *vector embedding* dari *support set*. Titik kecil disekitar c_1, c_2, c_3 adalah representasi vektor gambar dalam *support set*. Titik X adalah query sampel. Sementara garis putus-putus menunjukkan jarak antara query sampel X dan masing-masing prototipe.

Laenen dan Bertinetto menyebutkan bahwa struktur *episodic* dalam *Prototypical Networks* meniru kondisi *few-shot* secara langsung yang menjadikan model dapat dilatih dengan beberapa contoh saja tanpa kehilangan generalisasi [13]. Penerapan arsitektur ini tidak hanya efektif pada klasifikasi umum, tetapi juga telah berhasil diimplementasikan di bidang medis dan teknis [3].

2.5.2 EfficientNet-B0

EfficientNet-B0 adalah jaringan saraf konvolusional yang digunakan dalam klasifikasi gambar. *EfficientNet-B0* menggunakan pendekatan *compound scaling* yang mengatur kedalaman, lebar, dan resolusi jaringan secara bersamaan. Hal ini diperuntukkan agar tercapai keseimbangan yang ideal antara akurasi dan efisiensi komputasi [18]. *EfficientNet-B0* menunjukkan performa yang cukup baik dalam tugas klasifikasi medis karena kemampuannya dalam menyeimbangkan akurasi tinggi dengan beban komputasi yang ringan [21]. Model ini sudah beberapa kali diterapkan dalam studi citra medis seperti klasifikasi kanker otak [19], prediksi malaria [21], dan klasifikasi kanker kulit [18]. Dari beberapa studi yang telah ada, model ini terbukti memberikan hasil yang baik [19]. Arsitektur *EfficientNet-B0* digambarkan pada Gambar 4.



Gambar 4. Arsitektur EfficientNet-B0

Gambar 4. menggambarkan arsitektur model *EfficientNet-B0*. Arsitektur ini menggunakan MBConv dan terdiri dari beberapa blok bertingkat dari *block 1* hingga *block 7*. Model dimulai dengan inputan gambar berukuran 224x224 piksel, yang kemudian diproses melalui lapisan konvolusional awal dengan kernel 3x3, normalisasi batch, hingga ke *block* akhir untuk konsolidasi fitur sebelum menghasilkan *feature map*.

2.6 Pelatihan Model

Episodic training adalah prinsip utama dalam kerangka kerja *Few-shot Learning*. Proses training ini menggabungkan episode dengan *support set* dan *query set* untuk simulasi *few-shot* [3], [11], [13]. Untuk setiap episode akan terdiri dari N kelas dengan K gambar per kelas sebagai pelatihan (*support set*) dan Q gambar per kelas sebagai pengujian (*query set*). Menurut penelitian [13], *episodic training* memungkinkan model membentuk representasi prototipe yang konsisten sehingga mampu meningkatkan akurasi klasifikasi. Pada *support set* dilakukan augmentasi data untuk

meningkatkan generalisasi model. Teknik yang digunakan merujuk pada penelitian [7]. Proses ini dilakukan agar model tidak *overfitting* dan mampu mengenali pola baru dari sampel yang terbatas.

2.7 Evaluasi

Evaluasi model merupakan tahapan menentukan apakah model yang telah ditraining menunjukkan hasil yang baik menggunakan data pengujian yang berbeda dengan data training. Pada tahap evaluasi ini, digunakan 50 episode untuk menilai konsistensi model dalam menghadapi kelas-kelas baru mengikuti prinsip pengujian *few-shot* yang disebut *episodic testing* [3]. Hasil evaluasi ditampilkan ke dalam tiga jenis metrik berbeda yaitu, *confusion matrix*, *classification report*, dan *ROC AUC score*.

Confusion matrix adalah salah satu parameter yang sering digunakan untuk mengukur kinerja metode klasifikasi pada deep learning. Pengujian ini dilakukan untuk mengukur kinerja dari model klasifikasi dengan benar maupun salah. Ada empat parameter pengujian, yaitu *True Positive (TP)*, *False Positive (FP)*, *True Negatif (TN)*, dan *False Negatif (FN)* [21]. Evaluasi *classification report* terdiri dari presisi, *recall*, *f1-score*, dan akurasi [22]. Metrik ini menggambarkan tentang keseimbangan performa model dalam mendeteksi kelas.

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

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

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

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

ROC AUC score digunakan untuk mengukur kemampuan model dalam membedakan kedua kelas secara menyeluruh di berbagai ambang batas. Metrik ini relevan dengan aplikasi medis karena pentingnya sensitivitas dan spesifisitas dalam diagnosis [11], [15].

3. HASIL DAN PEMBAHASAN

Pada penelitian ini dilakukan percobaan klasifikasi kanker kulit dengan pendekatan *few-shot learning* menggunakan arsitektur *Prototypical Networks* dan *backbone EfficientNet-B0*. Tujuan penerapan ini adalah untuk mengatasi persoalan mengenai keterbatasan dan ketidakseimbangan data pada klasifikasi citra medis yang dapat mengganggu performa model dalam mendeteksi gambar secara akurat. Dataset yang digunakan dalam penelitian ini terdiri dari dua kelas, yaitu jinak (benign) dan ganas (malignant). Percobaan ini juga menerapkan *library albumentation* untuk proses *augmentasi* data pada tahap *pre-processing* demi meningkatkan generalisasi model terhadap data baru. Beberapa teknik *augmentasi* yang digunakan, meliputi rotasi, *flip*, *brightness & contrast adjustment*, *HSV shift*, dan normalisasi. Model dilatih dengan 100 *episodic training* dan diuji dengan 50 *episodic testing* untuk mengikuti cara kerja *Few-shot Learning* dalam tugas klasifikasi terbatas. Performa model dievaluasi dengan mengukur beberapa metrik, yaitu *confusion matrix*, *classification report*, dan *ROC AUC Score*. Metrik-metrik ini digunakan untuk menilai kemampuan prediksi, ketepatan klasifikasi, serta keseimbangan antara sensitivitas dan spesifisitas model pada berbagai skenario.

Pengujian dilakukan dengan konfigurasi *few-shot learning* pada skema 2-way, dengan variasi jumlah *k-shot* sebanyak 1, 5, dan 10 serta jumlah *query* sebanyak 5, 10, dan 15. Hasil akurasi yang didapat seperti yang dipaparkan pada Tabel 2.

Tabel 2. Hasil Akurasi Model

n-way	k-shot	5-query	10-query	15-query
2	1	67%	69,6%	71,67%
2	5	82,8%	83,5%	83,87%
2	10	84,2%	85,2%	86,73%

Hasil akurasi pada Tabel 2 menunjukkan bahwa model *Prototypical Networks* dan *backbone EfficientNet-B0* memberikan perubahan yang konsisten terhadap jumlah *k-shot* dan *query*. Peningkatan jumlah *k-shot* memberikan kontribusi positif terhadap akurasi model. Hal ini dikarenakan semakin banyak contoh yang tersedia maka semakin kuat representasi prototipe fitur yang dapat dibentuk oleh model pada setiap kelasnya. Pada percobaan ini, skema 1-shot 5-query memiliki nilai akurasi 67%, jauh lebih kecil jika dibandingkan dengan skema 10-shot 15-query yang nilai akurasinya 86,73%. Perbedaan ini membuktikan jika jumlah contoh yang terbatas dapat membuat model kesulitan dalam membentuk *centroid* yang stabil dan representatif untuk membedakan kelas secara akurat. Selain itu, jumlah *query* juga mempengaruhi performa model, meskipun pergerakannya tidak signifikan *k-shot*. Semakin banyaknya *query* memungkinkan model untuk diuji dalam bermacam variasi pola citra yang menekankan seberapa baik prototipe dalam melakukan generalisasi. Hasil ini sesuai dengan penelitian sebelumnya yang menunjukkan bahwa *Prototypical Networks* lebih efektif ketika didukung oleh representasi fitur yang kuat dan jumlah contoh yang cukup untuk masing-masing kelas.

3.1 Analisis Classification Report

Hasil evaluasi diperjelas dalam *classification report* untuk setiap skema konfigurasi seperti pada Tabel 3. *Classification report* ini memuat nilai *precision*, *recall*, dan *f1-score* untuk masing-masing kelas. Selain itu, tabel ini juga memuat nilai *macro avg* dan *weighted avg*.


Tabel 3. Classification Report

Skema	Kelas	Precision	Recall	F1-score
1-shot 5-query	Benign	0.6680	0.6760	0.6720
	Malignant	0.6721	0.6640	0.6680
	Macro avg	0.6700	0.6700	0.6700
	Weighted avg	0.6700	0.6700	0.6700
1-shot 10-query	Benign	0.7008	0.6840	0.6923
	Malignant	0.6914	0.7080	0.6996
	Macro avg	0.6961	0.6960	0.6960
	Weighted avg	0.6961	0.6960	0.6960
1-shot 15-query	Benign	0.7091	0.7347	0.7217
	Malignant	0.7248	0.6987	0.7115
	Macro avg	0.7169	0.7167	0.7166
	Weighted avg	0.7169	0.7167	0.7166
5-shot 5-query	Benign	0.8254	0.8320	0.8287
	Malignant	0.8306	0.8240	0.8273
	Macro avg	0.8280	0.8280	0.8280
	Weighted avg	0.8280	0.8280	0.8280
5-shot 10-query	Benign	0.8227	0.8540	0.8381
	Malignant	0.8482	0.8160	0.8318
	Macro avg	0.8355	0.8350	0.8349
	Weighted avg	0.8355	0.8350	0.8349
5-shot 15-query	Benign	0.8442	0.8307	0.8374
	Malignant	0.8333	0.8467	0.8399
	Macro avg	0.8388	0.8387	0.8387
	Weighted avg	0.8388	0.8387	0.8387
10-shot 5-query	Benign	0.8379	0.8480	0.8429
	Malignant	0.8462	0.8360	0.8410
	Macro avg	0.8420	0.8420	0.8420
	Weighted avg	0.8420	0.8420	0.8420
10-shot 10-query	Benign	0.8520	0.8520	0.8520
	Malignant	0.8520	0.8520	0.8520
	Macro avg	0.8520	0.8520	0.8520
	Weighted avg	0.8520	0.8520	0.8520
10-shot 15-query	Benign	0.8769	0.8547	0.8656
	Malignant	0.8583	0.8800	0.8690
	Macro avg	0.8676	0.8673	0.8673
	Weighted avg	0.8676	0.8673	0.8673


Pada Tabel 3 terlihat bahwa peningkatan jumlah *k-shot* berpengaruh terhadap nilai *precision*, *recall*, dan *f1-score*. Skema 1-shot memiliki *precision* dan *recall* yang rendah, menunjukkan bahwa model belum mampu membentuk representasi prototipe yang akurat. Sementara itu, peningkatan yang signifikan terjadi saat *k-shot* diubah menjadi 5 dan 10. Nilai *macro avg* dan *weighted avg* juga meningkat mengikuti bertambahnya *k-shot*. Hal ini mencerminkan perbaikan performa pada tingkat antar-kelas maupun keseluruhan sistem

3.2 Analisis Confusion Matrix


Untuk menambah pemahaman terhadap performa model dalam membedakan kelas *benign* dan *malignant*, digunakanlah visualisasi metrik berupa *confusion matrix* seperti yang dipaparkan pada Gambar 5 – 13.




Gambar 5. Confusion Matrix 1-shot 5-query




Gambar 6. Confusion Matrix 1-shot 10-query




Gambar 7. Confusion Matrix 1-shot 15-query




Gambar 8. Confusion Matrix 5-shot 5-query




Gambar 9. Confusion Matrix 5-shot 10-query




Gambar 10. Confusion Matrix 5-shot 15-query



Gambar 11. Confusion Matrix 10-shot 5-query



Gambar 12. Confusion Matrix 10-shot 10-query




Gambar 13. Confusion Matrix 10-shot 15-query


Confusion matrix memberikan gambaran yang komprehensif mengenai seberapa baik model dapat membedakan kelas. Informasinya mencakup jumlah prediksi benar dan salah untuk setiap kelas, serta jenis kesalahan yang dibuat oleh model. Pada hasil yang dipaparkan gambar 5 - 13, konfigurasi 10-shot menunjukkan model memiliki kapabilitas yang seimbang untuk mengenali kedua kelas dengan jumlah kesalahan klasifikasi relatif seimbang. Hal ini juga dapat dikatakan jika tidak ada kecenderungan bias yang signifikan terhadap salah satu kelas. Sedangkan, pada konfigurasi 1-shot, model cenderung mengalami kesulitan membedakan kedua kelas dengan prediksi jumlah salah lebih tinggi. Model dengan bias terhadap kelas tertentu memiliki risiko menyebabkan *false negative*, yang dalam konteks medis dapat berakibat pada kelalaian diagnosis penyakit serius seperti kanker kulit ganas. Oleh karena itu, pengendalian bias dan peningkatan representasi sangat penting.

3.3 Analisis dan Visualisasi ROC AUC


Selain confusion matrix, kurva ROC juga digunakan untuk visualisasi performa model. Kurva ROC digunakan untuk menggambarkan *trade off* antara *true positive rate* dan *false positive rate* di berbagai ambang batas. Visualisasi ini bukan sekedar menampilkan nilai ROC AUC secara numerik, tetapi juga memperlihatkan distribusi prediksi yang dihasilkan model pada berbagai skema k-shot dan query. Hasil visualisasi seperti pada Gambar 14 – 22.




Gambar 14. ROC Curve 1-shot 5-query




Gambar 15. ROC Curve 1-shot 10-query




Gambar 16. ROC Curve 1-shot 15-query




Gambar 17. ROC Curve 5-shot 5-query




Gambar 18. ROC Curve 5-shot 10-query




Gambar 19. ROC Curve 5-shot 15-query



Gambar 20. ROC Curve 10-shot 5-query



Gambar 21. ROC Curve 10-shot 10-query



Gambar 22. ROC Curve 10-shot 15-query

Berdasarkan Gambar 14 hingga Gambar 22, diketahui nilai akurasi terbesar berada pada skema 10-shot 15 query sebesar 94%. Nilai yang di dapat ini masuk ke dalam kategori *excellent discrimination*, yang dimana dianggap baik untuk kebutuhan prediktif. Nilai AUC yang tinggi menunjukkan bahwa model memiliki sensitivitas dan spesifisitas tinggi dalam klasifikasi kanker kulit. Hal ini menunjukkan jika model mampu dalam menangkap pola visual tanpa banyak membuat kesalahan saat klasifikasi. Pengaruh signifikan dari pembentukan prototipe fitur yang lebih stabil ditegaskan dalam grafik ROC, yang di mana diperlihatkan bahwa area di bawah kurva semakin luas seiring bertambahnya k-shot. Semakin luas area tersebut maka semakin baik performa model dala membedakan antara kelas positif dan negatif pada berbagai ambang batas. Hasil ini memperkuat model untuk dapat diaplikasikan ke dalam sistem pendukung keputusan klinis.

3.4 Perbandingan dengan Penelitian Sebelumnya

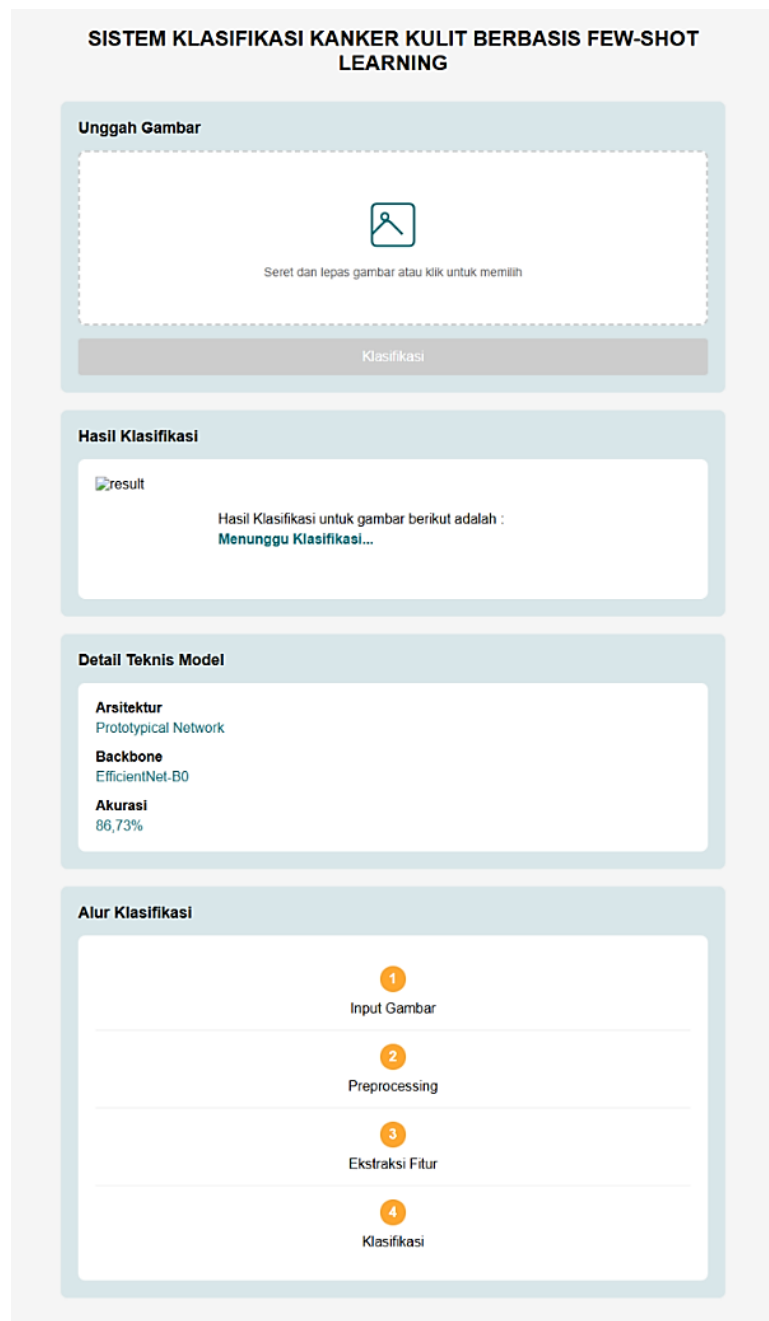
Penggunaan *Prototypical Networks* dan *EfficientNet-B0* terbukti efektif dalam klasifikasi kanker kulit dengan data terbatas dan tidak seimbang. Penggunaan arsitektur ini juga memungkinkan untuk diterapkan pada perangkat dengan sumber daya terbatas, seperti sistem *embedded* pada perangkat dermatoskopi atau aplikasi mobile untuk pemeriksaan mandiri. Jika dibandingkan dengan studi lain, seperti [11] yang mendapatkan akurasi 92% pada dataset lesi kulit

dengan pendekatan *Few-shot Learning*, model yang diusulkan dalam penelitian ini memiliki kinerja yang sebanding. Nilai akurasi tertinggi 86,73% dan AUC 94%, menunjukkan kemampuan klasifikasi yang sangat baik untuk sistem dengan data terbatas.

Salah satu kelebihan penelitian ini adalah kemampuannya mengatasi masalah *class imbalance* dan keterbatasan data pelatihan. Hasil penelitian ini menunjukkan potensi besar dalam implementasi sistem klasifikasi kanker kulit berbasis *Artificial Intelligence*. Namun, beberapa keterbatasan juga perlu diperhatikan. Saat ini model masih bekerja optimal hanya pada skenario biner. Untuk pengembangan sistem selanjutnya, sistem dapat ditingkatkan ke dalam skema *n-way classification* dengan kelas yang beragam seperti *Melanoma*, *Vascular Lesion*, atau *Basal Cell Carcinoma* untuk implementasi yang lebih nyata di dunia medis. Selain itu, percobaan pengujian pada dataset *real-world* dan penggabungan fitur metadata pasien juga dapat meningkatkan akurasi dan personalisasi sistem.

3.5 Implementasi Sistem

Hasil penelitian diimplementasikan dan dikembangkan ke dalam antarmuka pengguna berbasis web yang interaktif dan sederhana seperti pada Gambar 23. Antarmuka dirancang untuk memperlihatkan bagaimana penerapan secara nyata dari model *Few-shot Learning* dalam sistem klasifikasi kanker kulit. Antarmuka ini dirancang sesederhana mungkin agar memudahkan pengguna tanpa memerlukan pemahaman teknis yang mendalam.



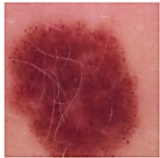
Gambar 23. UI Design

Pada Gambar 23 terlihat beberapa elemen UI yang ada pada website klasifikasi kanker kulit dengan pendekatan *Few-shot Learning*, meliputi fitur Unggah Gambar, Hasil Klasifikasi, Detail Teknis Model, dan Alur Klasifikasi. Fitur ini bertujuan untuk menyajikan informasi yang komprehensif tetapi tetap ringkas agar menjamin aksesibilitas dan pengalaman pengguna yang optimal.

Fitur "Unggah Gambar" adalah proses awal interaksi pengguna dengan sistem. Pada bagian ini, pengguna dapat mengunggah gambar citra kulit dengan cara klik atau *drag and drop* ke dalam kotak unggah gambar. Sistem nantinya akan secara otomatis memproses gambar untuk klasifikasi. Sistem akan melakukan serangkaian tahapan, yang meliputi *pre-processing* data, ekstraksi fitur, hingga proses klasifikasi menggunakan *Few-shot Learning*. Gambar yang telah diproses, hasilnya akan tampil pada bagian "Hasil Klasifikasi" seperti pada Gambar 24. Sistem akan memberikan label pada gambar citra yang diunggah dengan label klasifikasi *benign* dan *malignant*. Tampilan ini juga memberikan status real-time dari proses klasifikasi. Sistem ini tidak hanya menampilkan kelas gambar tetapi juga memberikan penjelasan singkat seperti tingkat akurasi, karakteristik dan rekomendasi untuk tindakan yang diambil.

SISTEM KLASIFIKASI KANKER KULIT BERBASIS FEW-SHOT LEARNING

Unggah Gambar

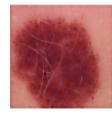


Klasifikasi

Hasil Klasifikasi

Hasil Klasifikasi untuk gambar berikut adalah :
Benign
 Tingkat Kepercayaan: 94.32%

Informasi Detail:



Benign (Jinak)

Lesi kulit yang terdeteksi kemungkinan besar bersifat jinak.

Karakteristik yang terlihat:

- Bentuk teratur dan simetris
- Warna relatif seragam
- Tepi yang jelas dan halus

Rekomendasi: Meskipun hasil menunjukkan lesi jinak, tetap disarankan untuk melakukan pemeriksaan rutin ke dokter kulit untuk pemantauan berkelanjutan.

Detail Teknis Model

Arsitektur
Prototypical Network

Backbone
EfficientNet-B0

Akurasi
86,73%

Alur Klasifikasi

1
Input Gambar

2
Preprocessing

3
Ekstraksi Fitur

4
Klasifikasi

Gambar 24. Hasil Klasifikasi

Adapun fitur "Detail Teknis Model" yang menunjukkan arsitektur algoritma yang digunakan dan akurasi. Arsitektur yang digunakan adalah Prototypical Networks dan backbone EfficientNet-B0 dengan akurasi 86,73%. Selanjutnya ada fitur "Alur Klasifikasi", di mana digambarkan dengan diagram langkah demi langkah untuk memperlihatkan bagaimana proses klasifikasi berjalan. Dengan keseluruhan desain sistem ini, sistem tidak hanya berfungsi sebagai alat bantu klasifikasi, tetapi sebagai platform edukasi visual yang menjelaskan prinsip kerja dari model Few-shot Learning. Hal ini merupakan bentuk inovasi teknologi berbasis *Artificial Intelligence* yang berpotensi untuk diadopsi pada aplikasi medis, khususnya untuk diagnosis dini kanker kulit.

Sistem ini dirancang untuk mendukung integrasi dengan berbagai perangkat input, termasuk kamera dermatoskopi dan tangkapan kamera standar. Hal ini untuk memberikan kemudahan bagi pengguna di berbagai kondisi lapangan, baik di klinik ataupun penggunaan pribadi. Desain sistem ini juga mempertimbangkan aspek keamanan dan privasi data, terutama karena berkaitan dengan informasi kesehatan pribadi. Selain itu, sistem ini juga di desain secara responsif agar dapat diakses dari berbagai perangkat baik desktop maupun seluler. Sistem ini juga tidak hanya sebagai alat klasifikasi pasif tetapi dapat dikembangkan menjadi sistem pendukung keputusan. Dengan ini, sistem membuka peluang untuk diterapkan di wilayah dengan akses terbatas terhadap tenaga medis spesialis. Sistem memungkinkan untuk terus berkembang dan meningkatkan akurasi klasifikasi berdasarkan data yang terkumpul. Dengan demikian, sistem dapat memberikan rekomendasi yang lebih tepat seiring bertambahnya waktu. Inovasi ini menjadi langkah awal dan pandangan ke depannya untuk mengembangkan lebih banyak sistem kesehatan berbasis *Artificial Intelligence* yang inklusif dan adaptif terhadap kebutuhan populasi yang beragam.

4. KESIMPULAN

Berdasarkan hasil dan pembahasan yang telah dipaparkan, dapat ditarik kesimpulan bahwa peningkatan jumlah k-shot berdampak positif terhadap performa model pada klasifikasi kanker kulit dengan pendekatan Few-shot Learning menggunakan arsitektur Prototypical Networks dan backbone EfficientNet-B0. Nilai akurasi terbaik berada pada skema 10-shot 15-query dengan nilai akurasi sebesar 86,73%. Hasil evaluasi diperjelas melalui classification report dan visualisasi confusion matrix serta ROC Curve. Visualisasi ROC Curve memperkuat hasil evaluasi dengan menunjukkan nilai 94%. Nilai ini mengindikasikan tingkat klasifikasi model sangat baik (excellent discrimination), yang berarti model dapat membedakan gambar citra *benign* dan *malignant* dengan tingkat kepercayaan yang tinggi. Hal ini menunjukkan potensi besar pendekatan *Few-shot Learning* untuk aplikasi medis, khususnya pada klasifikasi kanker kulit yang sering kali menghadapi masalah keterbatasan data. Secara keseluruhan, hasil penelitian ini membuktikan bahwa pendekatan few-shot learning dengan arsitektur Prototypical Networks dan backbone EfficientNet-B0 dapat dijadikan solusi alternatif karena efektif dalam menangani tugas klasifikasi kanker kulit, terutama pada kondisi jumlah data terbatas. Model juga dapat digunakan sebagai alat bantu diagnosis dini kanker kulit seperti implementasi sistem yang disarankan pada penelitian ini. Sebagai saran untuk penelitian selanjutnya, disarankan untuk mengeksplorasi penggunaan kolaborasi arsitektur dan backbone lainnya untuk meningkatkan akurasi, serta menguji kemampuan model pada skenario *multi-class* atau dataset dunia nyata yang lebih kompleks.

REFERENCES

- [1] M. Y. Khairi, E. A. M. Sampetoding, and Y. S. Pongtambang, "Studi Literatur Penerapan Deep Learning dalam Analisis Citra Medis di Indonesia," *Heal. J. PUBLIC Heal. Perspect. Vol.*, vol. 01, no. 01, pp. 15–24, 2024, doi: 10.62330/healthsense.v1i1.149.
- [2] N. A. Winanti, D. P. Martiyarningsih, C. A. A. Soemedhy, and U. Athiyah, "Analisis Klasifikasi Citra Kanker Kulit dengan Random Forest," *Remik*, vol. 7, no. 1, pp. 506–515, 2023, doi: 10.33395/remik.v7i1.12102.
- [3] Q. F. Yeo, S. Y. Ooi, Y. H. Pang, and Y. H. Gan, "Facial Skin Type Analysis Using Few-shot Learning with Prototypical Networks," *Int. J. Adv. Sci. Eng. Inf. Technol.*, vol. 13, no. 6, pp. 2249–2266, 2023, doi: 10.18517/ijaseit.13.6.19040.
- [4] Q. A. Fitroh and S. 'Uyun, "Deep Transfer Learning to Improve Classification Accuracy in Dermoscopic Images of Skin Cancer," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 12, no. 2, pp. 78–84, 2022, doi: 10.22146/jnteti.v12i2.6502.
- [5] Sofia Saidah, I. P. Y. N. Suparta, and E. Suhartono, "Modifikasi Convolutional Neural Network Arsitektur GoogLeNet dengan Dull Razor Filtering untuk Klasifikasi Kanker Kulit," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 11, no. 2, pp. 148–153, 2022, doi: 10.22146/jnteti.v11i2.2739.
- [6] O. Orlando and M. E. Al Rivan, "Klasifikasi Jenis kanker Kulit Manusia Menggunakan Convolution Neural Network," *MDP Student Conf.*, vol. 2, no. 1, pp. 144–150, 2023, doi: 10.35957/mdp-sc.v2i1.4335.
- [7] M. R. Ashari, Z. Sari, and D. Rizki, "Klasifikasi Kanker Kulit Menggunakan Metode Deep Learning," *J. Repos.*, vol. 6, no. 1, pp. 11–16, 2024, doi: 10.22219/repositor.v6i1.29358.
- [8] R. Yohannes and M. E. Al Rivan, "Klasifikasi Jenis Kanker Kulit Menggunakan CNN-SVM," *J. Algoritm.*, vol. 2, no. 2, pp. 133–144, 2022, doi: 10.35957/algoritm.v2i2.2363.
- [9] G. P. H. P. Gusti, E. Haerani, F. Syafrina, F. Yanto, and S. K. Gusti, "Implementasi Algoritma Convolutional Neural Network (Resnet-50) untuk Klasifikasi Kanker Kulit Benign dan Malignant," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 3, pp. 984–992, 2024, doi: 10.57152/malcom.v4i3.1398.
- [10] F. Y. Permana, C. Sri, K. Aditya, and D. R. Chandranegara, "Segmentasi dan Klasifikasi Gambar Citra pada Kanker Kulit Menggunakan Metode Convolutional Neural Network (CNN) dengan Arsitektur ResNet-50," *J. Repos.*, vol. 6, no. 4, pp. 391–404, 2024, doi: 10.22219/repositor.v6i4.
- [11] S. Chamarthi, K. Fogelberg, J. Gawlikowski, and T. J. Brinker, "Few-shot learning for skin lesion classification: A



- prototypical networks approach,” *Informatics Med. Unlocked*, vol. 48, 2024, doi: 10.1016/j.imu.2024.101520.
- [12] F. Pahde, M. Puscas, T. Klein, and M. Nabi, “Multimodal prototypical networks for few-shot learning,” *Proc. - 2021 IEEE Winter Conf. Appl. Comput. Vision, WACV 2021*, pp. 2643–2652, 2021, doi: 10.1109/WACV48630.2021.00269.
- [13] S. Laenen and L. Bertinetto, “On Episodes, Prototypical Networks, and Few-Shot Learning,” *Adv. Neural Inf. Process. Syst.*, vol. 29, pp. 24581–24592, 2021, doi: 10.48550/arXiv.2012.09831.
- [14] K. Desingu, M. P., and A. Chandrabose, “Few-Shot Classification of Skin Lesions from Dermoscopic Images by Meta-Learning Representative Embeddings,” *arXiv*, vol. abs/2210.1, 2022, doi: 10.48550/arXiv.2210.16954.
- [15] T. Chen, Q. Liu, and J. Yang, “Few-Shot Classification with Multiscale Feature Fusion for Clinical Skin Disease Diagnosis,” *Clin. Cosmet. Investig. Dermatol.*, vol. 17, pp. 1007–1026, 2024, doi: 10.2147/CCID.S458255.
- [16] M. A. H. Khan, S. M. Boddepalli, S. Bhattacharyya, and D. Mitra, “Few-Shot Classification and Anatomical Localization of Tissues in SPECT Imaging,” *IEEE Trans. Nucl. Sci.*, 2025, doi: 10.48550/arXiv.2502.06632.
- [17] H. S. Risfendra, Gheri Febri Ananda, “Deep Learning-Based Waste Classification with Transfer Learning Using EfficientNet-B0 Model,” *J. RESTI(Rekayasa Sist. dan Teknol. Informasi)*, vol. 8, no. 4, pp. 535–541, 2024, doi: 10.29207/resti.v8i4.5875.
- [18] K. Ali, Z. A. Shaikh, A. A. Khan, and A. A. Laghari, “Multiclass skin cancer classification using EfficientNets – a first step towards preventing skin cancer,” *Neurosci. Informatics*, vol. 2, no. 4, p. 100034, 2022, doi: 10.1016/j.neuri.2021.100034.
- [19] Q. H. Trinh, T. H. N. Mau, R. Zosimov, and M. Van Nguyen, “EfficientNet for Brain-Lesion Classification,” *Int. MICCAI Brainlesion Work.*, vol. 12962, pp. 249–260, 2022, doi: 10.1007/978-3-031-08999-2_20.
- [20] J. Huang, B. Wu, P. Li, X. Li, and J. Wang, “Few-Shot Learning for Radar Emitter Signal Recognition Based on Improved Prototypical Network,” *Remote Sens.*, vol. 14, no. 7, 2022, doi: 10.3390/rs14071681.
- [21] A. Eryana, S. Firmansyah, T. Informatika, I. I. B. Darmajaya, B. Lampung, and D. A. Tenggara, “Prediksi Malaria Menggunakan Metode Pre-Trained Model Algoritma EfficientNet-B0 dan MobileNet-V2,” *J. Ilm. Komputasi*, vol. 22, no. 1, pp. 71–80, 2023, doi: 10.32409/jikstik.22.1.3332.
- [22] Luqman Hakim, Z. Sari, and H. Handhajani, “Klasifikasi Citra Pigmen Kanker Kulit Menggunakan Convolutional Neural Network,” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 2, pp. 379–385, 2021, doi: 10.29207/resti.v5i2.3001.