

# Detection Skin Disease using Convolutional Neural Network Model

**Dinda Putri Ramadani**

Department of Informatics, Dinamika Bangsa University, Jambi, Indonesia

E-mail: [dindaputriramadani2@gmail.com](mailto:dindaputriramadani2@gmail.com)

\*Corresponding Author

**Praditya Oktanza Djaduk Wibisono**

Department of Informatics, Dinamika Bangsa University, Jambi, Indonesia

E-mail: [pradityaadit95@gmail.com](mailto:pradityaadit95@gmail.com)

**Prayitno**

Department of Informatics, Dinamika Bangsa University, Jambi, Indonesia

E-mail: [prayitno4704@gmail.com](mailto:prayitno4704@gmail.com)

Received: 9 January, 2025; Accepted: 16 June, 2025; Published: 30 June, 2025

**Abstract:** Skin diseases are one of the most important global health problems; thus, early and correct diagnosis is very critical for effective treatment. The following research introduces a Convolutional Neural Network model developed in TensorFlow for classifying skin diseases based on the Skin Cancer MNIST: HAM10000 dataset, a rich collection of dermatoscopic images of pigmented lesions. The goal is to improve diagnostic accuracy and efficiency through automated image classification. The dataset undergoes preprocessing in order to improve the model's generalization ability. Design a CNN model and train it on a large number of images to distinguish different lesion types. Measure its performance based on various metrics, including accuracy, precision, recall, and F1-score. Preliminary results achieved very high accuracy in the classification task, which is an indicative capability for the support model. Future research will be targeted at real-time applications, including the addition of more data to increase coverage. The present study emphasizes the potential role of deep learning in medical diagnostics and provides a useful tool for the automatic recognition of skin diseases, thereby contributing to improved health outcomes

**Keywords:** Skin Disease, CNN, Tensorflow, HAM10000, Image Classification, Dermatology, Deep Learning, Diagnosis.

## I. Introduction

Kulit adalah lapisan terluar yang berfungsi melindungi seluruh organ tubuh manusia. Selain itu, kulit juga berperan sebagai pengatur suhu tubuh dan organ ekskresi, serta menjadi salah satu indra manusia untuk merasakan sentuhan. Kondisi kulit setiap individu dapat berbeda-beda [10] 1. Faktor-faktor yang memengaruhi munculnya penyakit kulit meliputi kebersihan, sistem imun, kebiasaan sehari-hari, pola hubungan sosial, lingkungan pergaulan, jenis makanan, aktivitas seksual, paparan mikroorganisme, faktor fisik, bahan kimia, serta kondisi lingkungan [1] 2.

Penyakit kulit merupakan salah satu masalah kesehatan yang banyak ditemui di seluruh dunia. Deteksi dini dan diagnosis yang akurat menjadi kunci penting untuk memastikan pengobatan yang tepat dan mencegah komplikasi lebih lanjut. Namun, proses diagnosis penyakit kulit secara tradisional sering kali memerlukan keahlian dermatologis yang tidak selalu mudah diakses, terutama di daerah terpencil [2] 3.

Kemajuan dalam bidang kecerdasan buatan (Artificial Intelligence/AI) dan pembelajaran mendalam (Deep Learning) membuka peluang baru dalam mengatasi tantangan ini. Salah satu pendekatan yang menjanjikan adalah penggunaan Convolutional Neural Network (CNN), sebuah metode deep learning yang sangat efektif dalam analisis data berbasis citra. CNN memungkinkan klasifikasi citra secara otomatis, sehingga dapat membantu mempercepat proses diagnosis dan meningkatkan akurasi [3] 4.

Penelitian ini bertujuan untuk mengembangkan model CNN menggunakan TensorFlow untuk mengidentifikasi penyakit kulit berdasarkan dataset Skin Cancer MNIST: HAM10000, yang merupakan kumpulan besar citra dermatoskopi lesi kulit [4] 5. Dengan memanfaatkan dataset ini, diharapkan model yang dikembangkan mampu mengklasifikasikan berbagai jenis penyakit kulit secara efektif dan efisien. Penelitian ini diharapkan dapat memberikan kontribusi nyata dalam bidang analisis citra medis dan mendukung peningkatan kualitas layanan kesehatan

## 2. Method

### 2.1. Experiment Setup

Penelitian ini bertujuan untuk mengembangkan model CNN menggunakan TensorFlow untuk mengidentifikasi penyakit kulit. Untuk mencapai tujuan dari penelitian ini, perlu dirancang alur penelitian yang ditampilkan pada Fig 1




Fig.1. Experiment setup

Fig 1 adalah diagram eksperimen yang dirancang untuk penelitian ini. Proses penelitian dibagi menjadi beberapa tahap terpisah.

- Tahap pengumpulan data, yaitu tahap dimana peneliti mengumpulkan data. Data yang digunakan peneliti adalah dataset Skin Cancer MNIST: HAM10000 berjumlah kurang lebih 10 ribu data gambar penyakit kulit.
- Tahap preprocessing data, yaitu tahap dimana peneliti mulai menyiapkan data sebelum di training, prosesnya terdiri dari pengecekan data, pemeriksaan dan penghapusan data duplikasi, dan sebagainya.
- Tahap argumentasi data, yaitu tahap dimana data diperbesar variasi data dengan cara memodifikasi data seperti rotasi, flip, dan zoom gambar.
- Tahap membangun model, yaitu tahap dimana peneliti membangun model untuk training menggunakan CNN berbasis tensorflow.
- Tahap melatih model, yaitu tahap dimana dataset akan ditraining menggunakan model dari tensorflow yang sudah di bangun, kemudian hasilnya akan dicatat. Jika eksperimen berhasil maka selesai, jika gagal ulang lagi dari awal.

## 2.2 Dataset

Penelitian ini menggunakan dataset HAM10000, yaitu kumpulan 10.015 gambar dermatoskopi dengan berbagai jenis lesi kulit berpigmen yang dikategorikan ke dalam tujuh kelas diagnostik. Dataset ini dikembangkan dari berbagai sumber, termasuk ViDIR Group di Department of Dermatology, Medical University of Vienna, Austria, dan praktik perawatan kanker kulit Cliff Rosendahl di Queensland, Australia. Data dikumpulkan menggunakan berbagai perangkat dan metode selama lebih dari 20 tahun, mencerminkan populasi yang beragam. Dataset ini dirilis secara publik melalui arsip ISIC untuk tujuan penelitian akademik dan pelatihan algoritma pembelajaran mesin [9] 6.




Fig.2. Dataset HAM 10000

Didalam dataset tersebut terdapat 7 label penyakit kulit yang masing-masing mewakili jenis lesi atau kondisi kulit tertentu. Berikut adalah penjelasannya dibawah ini:

- Melanocytic Nevi (nv): lesi jinak berupa tahi lalat yang berasal dari melanosit, sel-sel yang memproduksi melanin.
- Melanoma (mel): jenis kanker kulit yang paling serius, melanoma berkembang dari melanosit dan dapat menyebar ke bagian tubuh lain jika tidak diobati. Diagnosis dini sangat penting untuk meningkatkan Tingkat keberhasilan pengobatan.
- Benign Keratosis-like Lesions (bkl): lesi jinak yang menyerupai keratosis, biasanya tidak berbahaya.
- Basal Cell Carcinoma (bcc): jenis kanker kulit yang paling umum tetapi kurang agresif dibanding melanoma.
- Actinic Keratoses and Intraepithelial Carcinoma (akeic): merupakan kondisi prakanker yang sering disebabkan oleh paparan sinar matahari jangka Panjang
- Vascular Lesions (vasc): lesi yang melibatkan pembuluh darah dan biasanya jinak.
- Dermatofibroma (df): lesi jinak berupa nodul kecil, padat dan keras yang sering muncul di kulit akibat reaksi terhadap trauma atau gigitan serangga dan biasanya tidak berbahaya.




Fig.3. Jenis- jenis penyakit kulit didalam dataset HAM 10000

## 2.3 Proposed Method

MobileNet V1 adalah arsitektur Convolutional Neural Network (CNN) yang dirancang untuk perangkat dengan sumber daya terbatas dengan menggunakan Depthwise Separable Convolution. sebagai komponen utamanya [7] 7. Arsitektur ini dimulai dengan konvolusi standar berukuran 3 x 3 untuk mengekstraksi fitur dasar dari input gambar

berukuran  $224 \times 224 \times 3$ , menghasilkan fitur dengan resolusi yang lebih kecil. Selanjutnya, proses Depthwise Separable Convolution menggantikan konvolusi standar untuk meningkatkan efisiensi komputasi. Proses ini terdiri dari dua tahap, yaitu Depthwise Convolution yang melakukan konvolusi secara terpisah pada setiap channel input dan Pointwise Convolution dengan kernel  $1 \times 1$  untuk menggabungkan informasi antar-channel. Proses ini diulang pada beberapa lapisan dengan pola serupa, di mana resolusi fitur berkurang secara bertahap sementara jumlah channel meningkat hingga mencapai 1024 channel dengan resolusi  $7 \times 7$ . Setelah melalui lapisan konvolusi, fitur akhir diproses menggunakan Global Average Pooling untuk mengubahnya menjadi vektor berukuran  $1 \times 1 \times 1024$ , yang kemudian dihubungkan ke Fully Connected Layer untuk klasifikasi. Fungsi Softmax digunakan pada lapisan output untuk menghasilkan probabilitas dari setiap kelas [6] 8. Keunggulan utama MobileNet V1 terletak pada efisiensi komputasinya yang signifikan dibandingkan CNN konvensional, menjadikannya cocok untuk aplikasi berbasis perangkat mobile atau edge computing. Dengan ukuran model yang kecil namun kinerja akurasi yang kompetitif, MobileNet V1 mampu menyelesaikan berbagai tugas klasifikasi gambar dengan efisien [8] 9.

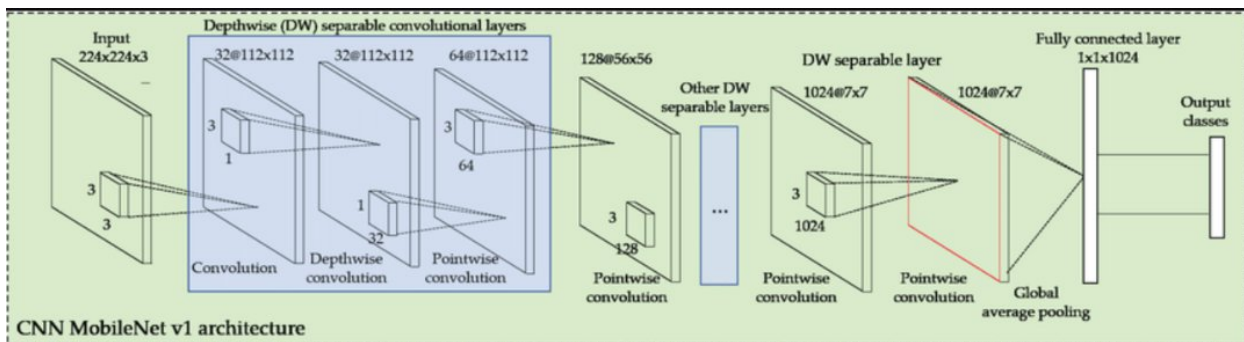


Fig.4. CNN Mobilenet v1

## 2.4. Environment Setup

Eksperimen dalam penelitian ini dilaksanakan pada sebuah laptop dengan spesifikasi windows 11 64-bit, AMD Ryzen 5 5000 series, dengan RAM berkapasitas 8 GB, untuk training machine nya menggunakan Google Colab milik Perusahaan Google dengan GPU nya. Selain itu tools lainnya meliputi python, tensorflow, scikit-learn, pandas dan numpy


## 3. Result and Discussion

Bagian ini mencakup hasil eksperimen yang telah dilaksanakan dari beberapa tahapan diatas, termasuk laporan hasil dari training dataset yang dilakukan dengan metode CNN menggunakan tensorflow.

### 3.1. Hasil Training Dataset

Dataset yang telah ditraining oleh tensorflow akan menghasilkan sebuah file bernama “model.h5”. File “model.h5” adalah file yang berisi model yang telah ditraining menggunakan framework Keras Mobilenet versi 1 yang menerapkan algoritma CNN. file ini digunakan untuk menyimpan model yang sudah ditraining, melakukan prediksi, transfer learning, dan distribusi model.

Hasil dari training model.h5 dapat dilihat dari fig 5 dibawah ini, terdapat gambar Training and Validation loss, training and validation cat accuracy, training and validation top2 accuracy serta training and validation top 3 accuracy.



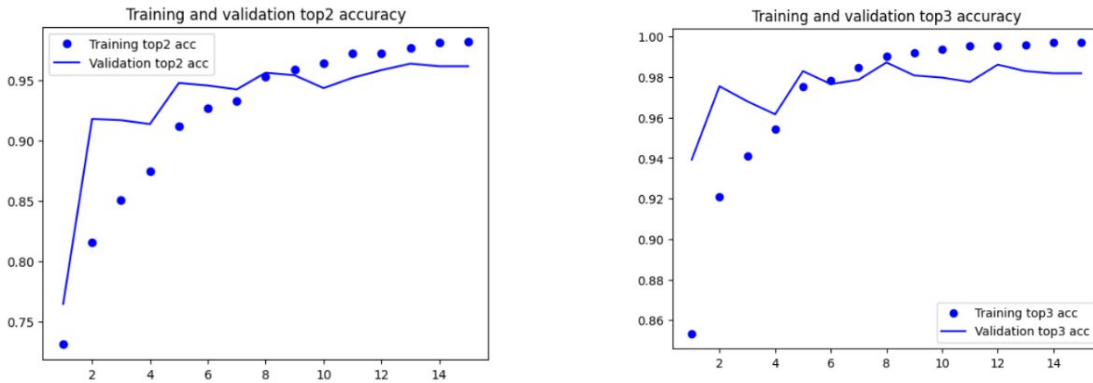


Fig.5. Gambar Hasil Training

Berikut ini adalah detail dari fig 5 gambar hasil training:

- **Training Loss:** Training loss adalah metrik yang digunakan untuk mengukur tingkat kesalahan (error) model selama proses pelatihan. Nilai ini dihitung berdasarkan selisih antara prediksi model dan label sebenarnya pada data pelatihan. Training loss memberikan indikasi seberapa baik model dapat "menghafal" pola dari data yang digunakan untuk melatihnya [10]. Nilai training loss yang lebih kecil menunjukkan bahwa model mampu mempelajari pola data pelatihan dengan lebih baik.
- **Validation Loss:** Validation loss adalah metrik yang digunakan untuk mengukur tingkat kesalahan model pada data validasi, yaitu data yang tidak digunakan selama pelatihan [10]. Metrik ini penting untuk mengevaluasi kemampuan model dalam melakukan generalisasi terhadap data baru yang tidak dikenal. Jika nilai validation loss terlalu tinggi dibandingkan training loss, hal ini dapat mengindikasikan bahwa model mengalami overfitting, yaitu model terlalu menyesuaikan diri dengan data pelatihan sehingga tidak dapat bekerja optimal pada data baru.
- **Categorical Accuracy:** Categorical accuracy adalah metrik evaluasi yang digunakan untuk mengukur tingkat keberhasilan prediksi model dalam klasifikasi multi-kelas [10]. Metrik ini menghitung persentase jumlah prediksi yang benar terhadap total data yang diuji. Dalam klasifikasi, prediksi dianggap benar apabila kelas dengan probabilitas tertinggi dari model sesuai dengan label sebenarnya. Semakin tinggi nilai categorical accuracy, semakin baik kinerja model dalam mengklasifikasikan data.
- **Top-2 Accuracy:** Top-2 accuracy adalah metrik evaluasi yang mengukur kemampuan model untuk memprediksi kelas yang benar di antara dua kelas dengan probabilitas tertinggi [10]. Metrik ini memberikan wawasan tambahan tentang kemampuan model dalam situasi di mana prediksi tunggal dengan probabilitas tertinggi mungkin tidak selalu tepat. Nilai top-2 accuracy yang tinggi menunjukkan bahwa model memiliki kemampuan untuk memberikan prediksi yang mendekati kebenaran meskipun prediksi pertama salah.
- **Top-3 Accuracy:** Top-3 accuracy adalah metrik yang mengukur kemampuan model untuk memprediksi kelas yang benar di antara tiga kelas dengan probabilitas tertinggi [10]. Metrik ini relevan untuk masalah klasifikasi dengan banyak kelas, di mana peluang untuk memprediksi satu kelas secara tepat mungkin rendah. Semakin tinggi nilai top-3 accuracy, semakin baik model dalam memberikan prediksi yang relevan dengan label sebenarnya. Penjelasan di atas dapat digunakan untuk memperkaya deskripsi metrik pada bagian metodologi atau evaluasi hasil dalam sebuah jurnal penelitian.

Berikut ini adalah detail dari fig 5 gambar hasil training:




Fig.6. Confusion Matrix

Dari fig 6 dapat terlihat bahwa model menunjukkan kinerja yang baik dalam mengklasifikasikan kelas mayoritas seperti nva dengan jumlah prediksi benar yang tinggi (694). Hal ini disebabkan oleh ketidakseimbangan jumlah data, di mana kelas nva memiliki jumlah sampel yang jauh lebih banyak dibandingkan kelas lainnya. Sebaliknya, untuk kelas dengan jumlah data yang lebih sedikit seperti mel, model menunjukkan jumlah kesalahan klasifikasi yang lebih tinggi, di mana hanya 29 sampel yang diklasifikasikan dengan benar dari keseluruhan data mel.

Confusion matrix ini menunjukkan bahwa model memiliki akurasi yang baik untuk kelas mayoritas tetapi kurang sensitif terhadap kelas minoritas seperti mel. Berikut merupakan score akhir dari hasil 10 kali testing pada tabel 1:

Tabel.1. Score Akhir 10 kali Testing

Run	val_loss	val_cat_acc	val_top_2_acc	val_top_3_acc
Run 1	0.37375	0.890192	0.95629	0.987207
Run 2	0.37375	0.890192	0.95629	0.987207
Run 3	0.37375	0.890192	0.95629	0.987207
Run 4	0.37375	0.890192	0.95629	0.987207
Run 5	0.37375	0.890192	0.95629	0.987207
Run 6	0.37375	0.890192	0.95629	0.987207
Run 7	0.37375	0.890192	0.95629	0.987207
Run 8	0.37375	0.890192	0.95629	0.987207
Run 9	0.37375	0.890192	0.95629	0.987207
Run 10	0.37375	0.890192	0.95629	0.987207
<b>Mean</b>	0.37375	0.890192	0.95629	0.987207

Tabel 1 menunjukkan hasil pengujian model berdasarkan metrik *validation loss* (val\_loss), akurasi kategori (*validation categorical accuracy* atau val\_cat\_acc), akurasi dua kategori teratas (*validation top-2 accuracy* atau val\_top\_2\_acc), dan akurasi tiga kategori teratas (*validation top-3 accuracy* atau val\_top\_3\_acc). Pengujian dilakukan sebanyak 10 kali (*runs*) untuk memastikan konsistensi performa model.

Berdasarkan hasil pengujian, nilai rata-rata *val\_loss* tercatat sebesar **0.37375**, menunjukkan tingkat kesalahan prediksi model pada data validasi relatif rendah. Sementara itu, nilai rata-rata *val\_cat\_acc* mencapai **0.890192**, mengindikasikan bahwa model mampu mengklasifikasikan data dengan akurasi kategori yang tinggi.

Selain itu, nilai rata-rata *val\_top\_2\_acc* sebesar **0.95629** dan *val\_top\_3\_acc* sebesar **0.987207** menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam memasukkan prediksi yang benar di antara dua hingga tiga kategori teratas. Nilai-nilai ini konsisten di seluruh pengujian, seperti yang terlihat dari identitas nilai metrik pada setiap *run*.

Hasil ini menunjukkan bahwa model memiliki performa yang stabil dan dapat diandalkan untuk melakukan klasifikasi pada data validasi dengan tingkat kesalahan yang minimal dan akurasi yang tinggi. Berikut ini hasil score akhir dari tiap tiap kelas pada Tabel.2.

Tabel.2. Nilai Hasil Akhir Setiap Kelas

Class	Precisi on	Recall	F1- Score	Support
akiec	0.6521 74	0.576 923	0.6122 45	26.000
bcc	0.6571 43	0.766 667	0.7076 92	30.000
bkl	0.7142 86	0.533 333	0.6106 87	75.000
df	0.8000 00	0.666 667	0.7272 73	6.000
mel	0.4509 80	0.589 744	0.5111 11	39.000
nv	0.9523 81	0.958 722	0.9555 41	751.000
vasc	0.8333 33	0.909 091	0.8695 65	11.000
<b>Accuracy</b>	<b>0.8901 92</b>	<b>0.890 192</b>	<b>0.8901 92</b>	<b>0.890192</b>

<b>Macro Avg</b>	0.7229 00	0.714 449	0.7134 45	938.000
<b>Weighted Avg</b>	0.8923 62	0.890 192	0.8895 78	938.000

Tabel 2 di atas menyajikan metrik evaluasi model berdasarkan *precision*, *recall*, *f1-score*, dan jumlah data (*support*) untuk masing-masing kelas. Evaluasi ini bertujuan untuk menilai kinerja model dalam mengklasifikasikan tujuh jenis lesi kulit yang terdapat dalam dataset.

#### 1. Evaluasi per Kelas

- **Kelas akiec** memiliki *precision* sebesar **0.652**, menunjukkan bahwa sekitar 65% prediksi untuk kelas ini benar. Namun, *recall*-nya hanya **0.577**, yang berarti model hanya mampu mengenali 57.7% dari total data kelas ini. *F1-score* sebesar **0.612** mengindikasikan adanya keseimbangan yang moderat antara *precision* dan *recall*.
- **Kelas bcc** menunjukkan *precision* sebesar **0.657** dan *recall* **0.767**, dengan *f1-score* **0.708**, yang menunjukkan performa yang cukup baik dalam mengidentifikasi data kelas ini.
- **Kelas bkl** memiliki *precision* yang cukup tinggi (**0.714**), tetapi *recall*-nya lebih rendah (**0.533**), menghasilkan *f1-score* sebesar **0.611**, yang menunjukkan tantangan dalam mengenali seluruh data dari kelas ini.
- **Kelas df** menunjukkan performa tinggi dengan *f1-score* **0.727**, meskipun *support*-nya kecil (6 data), menandakan model bekerja cukup baik meski dengan data terbatas.
- **Kelas mel** memiliki performa yang lebih rendah dibandingkan kelas lainnya, dengan *f1-score* **0.511**, mengindikasikan bahwa model mengalami kesulitan dalam mengenali kelas ini.
- **Kelas nv**, yang memiliki jumlah data terbesar (*support* = 751), menunjukkan performa yang sangat baik dengan *f1-score* **0.956**, menandakan keakuratan tinggi dalam mengenali data kelas ini.
- **Kelas vasc** juga menunjukkan performa tinggi dengan *f1-score* **0.870**, meskipun jumlah datanya kecil (*support* = 11).

#### 2. Akurasi Keseluruhan

- Model memiliki tingkat akurasi keseluruhan sebesar **0.890**. Ini menunjukkan bahwa model mampu membuat prediksi yang benar untuk hampir 89% dari data validasi.

#### 3. Rata-Rata Evaluasi

- *Macro average* menunjukkan nilai rata-rata metrik di semua kelas tanpa memperhatikan distribusi data, dengan *precision* **0.723**, *recall* **0.714**, dan *f1-score* **0.713**. Hal ini menunjukkan bahwa model cukup konsisten dalam performa untuk setiap kelas.
- *Weighted average*, yang mempertimbangkan jumlah data pada setiap kelas, menunjukkan *precision* **0.892**, *recall* **0.890**, dan *f1-score* **0.890**, mengindikasikan bahwa model memberikan perhatian lebih besar pada kelas dengan jumlah data lebih banyak (misalnya, kelas nv).

#### 4. Conclusion

Berdasarkan hasil evaluasi performa model klasifikasi lesi kulit pada dataset HAM10000, diperoleh akurasi keseluruhan sebesar **89%**. Model menunjukkan performa yang sangat baik pada kelas mayoritas, seperti Melanocytic Nevi (nv), dengan *precision*, *recall*, dan *f1-score* masing-masing sebesar **0.95**, **0.96**, dan **0.96**. Namun, performa pada kelas minoritas, terutama melanoma (mel), masih menunjukkan kekurangan, dengan nilai *precision* sebesar **0.45** dan *f1-score* sebesar **0.51**. Hal ini menandakan bahwa model sering salah memprediksi kelas lain sebagai melanoma (*false positives*), meskipun tingkat deteksi sampel melanoma cukup baik (*recall* = **0.59**). Untuk rata-rata tidak tertimbang (*macro average*), model memiliki nilai *precision*, *recall*, dan *f1-score* masing-masing sebesar **0.72**, **0.71**, dan **0.71**, yang menggambarkan performa rata-rata pada semua kelas tanpa mempertimbangkan distribusi data. Sementara itu, rata-rata tertimbang (*weighted average*) memberikan nilai yang lebih tinggi (*precision* = **0.89**, *recall* = **0.89**, *f1-score* = **0.89**), menunjukkan bahwa kelas mayoritas mendominasi kontribusi performa keseluruhan. Hasil ini mengindikasikan bahwa meskipun model bekerja dengan baik secara keseluruhan, perlu adanya upaya untuk meningkatkan performa pada kelas-kelas minoritas yang memiliki jumlah sampel lebih sedikit.

#### Acknowledgment

Penelitian didukung oleh Universitas Dinamika Bangsa

#### References



- [1] N. Andrini, "Karakteristik Dan Perawatan Kulit Untuk Orang Asia," *PANDU HUSADA*, vol. 4, no. 3, 2023.
- [2] I. W. Prastika and E. Zuliarso, "DETEKSI PENYAKIT KULIT WAJAH MENGGUNAKAN TENSORFLOW DENGAN METODE CONVOLUTIONAL NEURAL NETWORK," *Jurnal Manajemen Informatika dan Sistem Informasi*, vol. 4, no. 2, pp. 84–91, Oct. 2021, doi: <https://doi.org/10.36595/misi.v4i2.418>.
- [3] Q. Aini, N. Lutfiani, H. Kusumah, and M. S. Zahran, "Deteksi dan Pengenalan Objek Dengan Model Machine Learning: Model Yolo," *CESS (Journal of Computer Engineering, System and Science)*, vol. 6, no. 2, p. 192, Jul. 2021, doi: <https://doi.org/10.24114/cess.v6i2.25840>.
- [4] L. Triyono *et al.*, "KLASIFIKASI PENYAKIT KULIT MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK."
- [5] A. Wicaksono, S. Farisa, C. Haviana, and A. Riansyah, "Rancang Bangun Aplikasi Android Deteksi Penggunaan Masker Wajah Menggunakan Tensorflow Mobilenet," *Jurnal Transistor Elektro dan Informatika (TRANSISTOR EI)*, vol. 5, no. 1, pp. 1411–366, 2023.
- [6] P. Tschandl, C. Rosendahl, and H. Kittler, "The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions," *Scientific Data*, vol. 5, no. 1, Aug. 2018, doi: <https://doi.org/10.1038/sdata.2018.161>.
- [7] J. Clerk Maxwell, *A Treatise on Electricity and Magnetism*, 3<sup>rd</sup> ed., vol. 2. Oxford: Clarendon, 1892, pp.68–73.
- [8] A. Howard *et al.*, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," Apr. 2017. Accessed: Jan. 09, 2025. <https://arxiv.org/abs/1704.04861?form=MG0AV3>.
- [9] B. Hartanto, B. W. Yudanto, D. Nugroho, and S. Tomo, "IMPELEMENTASI CONVOLUTIONAL NEURAL NETWORK MENGGUNAKAN MODEL MOBILENET DALAM APLIKASI PRESENSI BERBASIS PENGENALAN WAJAH," *Biner : Jurnal Ilmiah Informatika dan Komputer*, vol. 3, no. 1, pp. 22–26, Jan. 2024, doi: <https://doi.org/10.32699/biner.v3i1.6607>.
- [10] B. Khasoggi, E. Ermatita, and S. Samsuryadi, "Efficient mobilenet architecture as image recognition on mobile and embedded devices," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 16, no. 1, p. 389, Oct. 2019, doi: <https://doi.org/10.11591/ijeecs.v16.i1.pp389-394>.

### Authors' Profiles



**Dinda Putri Ramadani** lahir di Medan, Indonesia, pada 25 Oktober 2004. Saat ini, ia sedang menempuh pendidikan S1 di Fakultas Ilmu Komputer, Universitas Dinamika Bangsa, Jambi, Indonesia. Bidang studi yang ditekuni meliputi bidang Teknik Informatika.



**Prayitno** lahir di Sarolangun, Indonesia, pada 07 April 2004. Saat ini, ia sedang menempuh pendidikan S1 di Fakultas Ilmu Komputer, Universitas Dinamika Bangsa, Jambi, Indonesia. Bidang studi yang ditekuni meliputi bidang Teknik Informatika.



**Praditya Oktanza Djuduk Wibisono** lahir di Batam, Indonesia, pada 01 Oktober 2004. Saat ini, ia sedang menempuh pendidikan S1 di Fakultas Ilmu Komputer, Universitas Dinamika Bangsa, Jambi, Indonesia. Bidang studi yang ditekuni meliputi bidang Teknik Informatika.