

## Klasifikasi Masker Wajah Menggunakan Efficientnet

**Akhmad Maulana Fadil<sup>1</sup>, Aditiya Eka Purnama<sup>1</sup>, Kaka Aditya Akbar Nur<sup>1</sup>, Perani Rosyani<sup>1\*</sup>**

<sup>1</sup>Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pamulang, Kota Tangerang Selatan, Banten, Indonesia, 15310  
Email: <sup>1\*</sup>[dosen00837@unpam.ac.id](mailto:dosen00837@unpam.ac.id)  
(\* : coresponding author)

**Abstrak** - Implementasi protokol kesehatan, khususnya penggunaan masker di ruang publik, menjadi krusial pasca pandemi COVID-19 untuk menekan laju transmisi virus. Namun, pengawasan manual oleh personel keamanan memiliki keterbatasan dalam hal konsentrasi dan efisiensi pada area padat. Penelitian ini bertujuan untuk membangun model klasifikasi citra berbasis *Deep Learning* yang mampu membedakan wajah bermasker dan tidak bermasker secara otomatis dengan presisi tinggi. Metode yang digunakan adalah arsitektur *EfficientNet-B0* dengan pendekatan *Transfer Learning* memanfaatkan bobot pre-trained dari ImageNet. Penggunaan teknik *Compound Scaling* pada *EfficientNet* memungkinkan keseimbangan optimal antara akurasi dan efisiensi komputasi, sehingga cocok diimplementasikan pada perangkat dengan sumber daya terbatas. Hasil eksperimen menunjukkan bahwa model mampu mencapai tingkat akurasi sebesar 99,80% hanya dalam 5 epoch pelatihan. Evaluasi melalui confusion matrix menunjukkan performa yang sangat stabil dengan nilai precision dan recall mencapai 1.00 pada kedua kelas. Penelitian ini menyimpulkan bahwa *EfficientNet-B0* sangat efektif untuk sistem pengawasan kesehatan publik yang ringan namun tangguh.

**Kata Kunci:** Klasifikasi Masker Wajah, *Deep Learning*, *EfficientNet-B0*, *Transfer Learning*, *Computer Vision*.

**Abstract** - Implementing health protocols, particularly mask-wearing in public spaces, has become crucial in the post-COVID-19 pandemic to suppress virus transmission. However, manual monitoring by security personnel has limitations in terms of concentration and efficiency in crowded areas. This study aims to build a Deep Learning-based image classification model capable of automatically distinguishing masked and unmasked faces with high precision. The method used is the EfficientNet-B0 architecture with a Transfer Learning approach utilizing pre-trained weights from ImageNet. The use of the Compound Scaling technique in EfficientNet enables an optimal balance between accuracy and computational efficiency, making it suitable for implementation on devices with limited resources. Experimental results show that the model can achieve an accuracy rate of 99.80% in just 5 training epochs. Evaluation using a confusion matrix demonstrates very stable performance, with precision and recall values reaching 1.00 for both classes. This study concludes that EfficientNet-B0 is highly effective for a lightweight yet robust public health surveillance system.

**Keywords:** Face Mask Classification, *Deep Learning*, *EfficientNet-B0*, *Transfer Learning*, *Computer Vision*.

## 1. PENDAHULUAN

Perkembangan teknologi informasi dan komunikasi di era Revolusi Industri 4.0 telah menciptakan disrupti besar-besaran di berbagai sektor, termasuk kesehatan dan keamanan publik. Inti dari transformasi ini adalah kemampuan mesin untuk memproses data dalam skala besar (*Big Data*) menggunakan algoritma Kecerdasan Buatan (*Artificial Intelligence*). Di tengah dinamika ini, *Deep Learning*, yang merupakan evolusi dari *Machine Learning*, telah menunjukkan performa luar biasa dalam tugas-tugas pengenalan pola visual melalui *Computer Vision*. Teknologi ini menjadi tulang punggung bagi sistem otomatisasi yang mampu menggantikan peran manusia dalam melakukan pengawasan yang repetitif dan memerlukan konsentrasi tinggi.

Urgensi penerapan sistem otomatisasi ini semakin mengemuka pasca munculnya pandemi COVID-19 yang melanda dunia sejak akhir 2019. Pandemi tersebut tidak hanya mengubah tatanan sosial, tetapi juga memperkenalkan standar baru dalam kesehatan masyarakat, yaitu kewajiban penggunaan masker sebagai alat pelindung diri utama. Berdasarkan pedoman dari *World Health Organization* (WHO), penggunaan masker secara konsisten di ruang publik mampu menekan laju transmisi virus secara signifikan. Di Indonesia, kebijakan ini diperkuat melalui berbagai regulasi pemerintah yang mewajibkan penggunaan masker di fasilitas umum seperti transportasi massal, pusat perbelanjaan, dan institusi pendidikan.

Namun, kendala utama dalam penegakan protokol kesehatan ini adalah ketergantungan pada pengawasan manual oleh personel keamanan. Pengawasan manual memiliki kelemahan bawaan, antara lain faktor kelelahan (*fatigue*), penurunan tingkat konsentrasi setelah periode waktu tertentu, serta potensi terjadinya konflik interpersonal saat melakukan teguran secara langsung. Selain itu, pada area dengan arus lalu lintas manusia yang padat, sangat sulit bagi seorang petugas untuk memantau setiap individu secara akurat dan *real-time*. Di sinilah peran sistem klasifikasi wajah bermasker berbasis AI menjadi sangat vital untuk menggantikan fungsi pengawasan manual tersebut dengan tingkat presisi yang lebih stabil.

Dalam ranah teknis *Deep Learning*, algoritma *Convolutional Neural Network* (CNN) telah lama menjadi standar industri untuk klasifikasi gambar. Namun, arsitektur CNN konvensional sering kali menghadapi dilema antara akurasi dan efisiensi. Model yang sangat akurat cenderung memiliki jumlah parameter yang besar, sehingga membutuhkan daya komputasi tinggi (GPU mahal) dan memori yang luas. Hal ini menghambat implementasi sistem pada perangkat yang memiliki sumber daya terbatas (*edge devices*) seperti kamera CCTV pintar atau perangkat *mobile*.

Penelitian ini mengusulkan penggunaan arsitektur *EfficientNet-B0* sebagai solusi atas kendala tersebut. *EfficientNet* memperkenalkan metode *Compound Scaling* yang mampu menyeimbangkan kedalaman jaringan, lebar saluran, dan resolusi gambar secara matematis. Dibandingkan dengan model populer lainnya seperti ResNet atau VGG, *EfficientNet-B0* menawarkan performa yang lebih kompetitif dengan beban komputasi yang jauh lebih ringan. Dengan memanfaatkan teknik *Transfer Learning*, di mana model dibekali pengetahuan awal dari dataset raksasa ImageNet, proses pelatihan dapat dilakukan lebih cepat dengan hasil yang lebih optimal meskipun menggunakan dataset lokal yang terbatas.

Melalui integrasi antara urgensi kesehatan masyarakat dan inovasi dalam bidang *Deep Learning*, penelitian ini diharapkan mampu memberikan kontribusi nyata dalam pengembangan sistem keamanan cerdas. Fokus utama penelitian bukan hanya pada aspek teknis akurasi, tetapi juga pada efektivitas implementasi algoritma yang efisien untuk mendukung kebijakan kesehatan publik di masa kini dan masa depan.

Meskipun demikian, tantangan utama dalam penerapan CNN adalah kompleksitas model dan kebutuhan komputasi yang besar. Beberapa arsitektur CNN populer seperti

VGGNet dan ResNet memiliki jumlah parameter yang sangat besar, sehingga membutuhkan sumber daya komputasi yang tinggi dan waktu pelatihan yang lama. Hal ini menjadi kendala tersendiri, terutama jika sistem akan diimplementasikan pada perangkat dengan keterbatasan sumber daya seperti perangkat *edge* atau sistem pemantauan skala besar.

Untuk mengatasi permasalahan tersebut, dikembangkan arsitektur CNN yang lebih efisien, salah satunya adalah *EfficientNet*. *EfficientNet* merupakan arsitektur CNN modern yang dirancang untuk mencapai keseimbangan optimal antara akurasi dan efisiensi komputasi. *EfficientNet* menggunakan konsep compound scaling, yaitu metode penskalaan yang secara seimbang meningkatkan kedalaman, lebar, dan resolusi jaringan secara bersamaan.

Dalam penelitian ini, digunakan varian *EfficientNet-B0* sebagai model dasar untuk klasifikasi masker wajah. *EfficientNet-B0* dipilih karena memiliki jumlah parameter yang relatif kecil namun tetap mampu menghasilkan performa yang kompetitif. Selain itu, penelitian ini menerapkan teknik transfer learning dengan memanfaatkan bobot pre-trained dari dataset ImageNet, sehingga proses pelatihan menjadi lebih cepat dan efisien meskipun dataset yang digunakan relatif terbatas.

Berdasarkan latar belakang tersebut, penelitian ini berfokus pada penerapan arsitektur *EfficientNet-B0* untuk mengklasifikasikan citra wajah menjadi dua kelas, yaitu wajah dengan masker dan wajah tanpa masker. Diharapkan hasil penelitian ini dapat memberikan kontribusi dalam pengembangan sistem pemantauan protokol kesehatan berbasis kecerdasan buatan yang akurat, efisien, dan mudah diimplementasikan.

## 2. METODE PENELITIAN

### 2.1 Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimental. Fokus utama penelitian adalah pengembangan model klasifikasi citra wajah menggunakan paradigma *Deep Learning* dengan arsitektur *EfficientNet-B0*. Tahapan eksperimen mencakup pengujian berbagai parameter teknis seperti *learning rate* dan jumlah *epoch* untuk mencapai tingkat akurasi yang optimal.

### 2.2 Prosedur Tahapan Penelitian

Proses penelitian dilaksanakan melalui lima tahapan utama yang sistematis:

- a. **Studi Literatur:** Mengkaji konsep *Convolutional Neural Networks* (CNN) dan arsitektur *EfficientNet* yang menggunakan *compound scaling* untuk efisiensi parameter.
- b. **Akuisisi Data:** Mengambil data dari *Face Mask Dataset* yang telah dilabeli menjadi dua kategori: wajah dengan masker dan tanpa masker.
- c. **Pra-pemrosesan Citra:** Melakukan transformasi data mentah agar sesuai dengan persyaratan input arsitektur model.
- d. **Pelatihan Model (Training):** Melakukan iterasi pelatihan menggunakan fungsi *loss Sparse Categorical Crossentropy* dan pengoptimal *Adam*.
- e. **Evaluasi:** Menguji model menggunakan data yang belum pernah dilihat sebelumnya (*testing set*) untuk mendapatkan nilai akurasi dan *loss*.

### 2.3 Karakteristik Dataset dan Augmentasi

Dataset terdiri dari ribuan citra dengan variasi orientasi wajah. Untuk meningkatkan ketahanan model terhadap berbagai kondisi lapangan, diterapkan teknik augmentasi data selama proses pemuatan. Teknik ini meliputi pergeseran rentang lebar (*width shift*), tinggi (*height shift*), pencerminan horizontal (*horizontal flip*), serta pengaturan sudut rotasi. Hal ini bertujuan agar model tidak hanya menghafal data (*overfitting*), tetapi mampu mengenali pola masker secara umum.

### 2.4 Arsitektur *EfficientNet-B0*

Model ini menggunakan *EfficientNet-B0* sebagai ekstraktor fitur utama. Keunggulan arsitektur ini terletak pada penggunaan Mobile Inverted Bottleneck Convolution (MBConv). Parameter model diatur sebagai berikut:

- a. **Input Layer:** Citra dengan dimensi  $224 \times 224 \times 3$  (RGB).
- b. **Base Model:** Lapisan *EfficientNet-B0* yang dibekukan (frozen) untuk mempertahankan fitur dasar seperti garis dan tekstur.
- c. **Custom Head:** Penambahan lapisan baru yang terdiri dari:
  - 1) Global Average Pooling 2D untuk meratakan peta fitur menjadi satu vektor.
  - 2) Dropout Layer dengan tingkat 0,3 untuk mengurangi ketergantungan antar neuron.
  - 3) Dense Layer (lapisan output) dengan 2 neuron yang menggunakan fungsi aktivasi Softmax untuk menghasilkan distribusi probabilitas kelas.

### 2.5 Parameter Pelatihan

Eksperimen dilakukan dalam lingkungan Google Colab dengan spesifikasi pengujian:

- a. **Epoch:** 5 iterasi.
- b. **Batch Size:** 32 citra per iterasi.
- c. **Optimizer:** Adam dengan learning rate yang diatur secara otomatis oleh sistem untuk memastikan konvergensi yang stabil.

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Hasil Eksperimen

Proses pelatihan model dilakukan menggunakan algoritma *Transfer Learning* dengan arsitektur *EfficientNet-B0*. Pelatihan dilakukan sebanyak 5 epoch dengan ukuran *batch* 32. Berdasarkan kode program yang dijalankan, proses pelatihan menunjukkan peningkatan akurasi dan penurunan *loss* secara bertahap di setiap iterasinya.

Pada tahap ini, fungsi `model.fit()` merekam riwayat pelatihan yang mencakup empat metrik utama:

- a. *Training Accuracy*: Akurasi model pada data latih.
- b. *Validation Accuracy*: Akurasi model pada data uji (*test*).
- c. *Training Loss*: Nilai kesalahan pada data latih.
- d. *Validation Loss*: Nilai kesalahan pada data uji.

Using sample image from: Face Mask Dataset/Test/WithMask/Augmented\_411\_871195.png

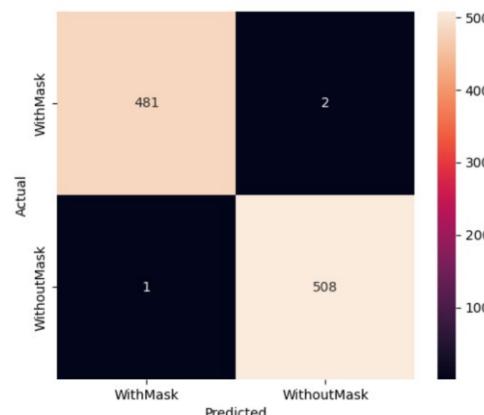
1/1 ————— 0s 110ms/step

*Prediction: WithMask*

*Confidence: 0.9999995*



**Gambar 1.** Model Gambar Pengguna Menggunakan Masker



**Gambar 2. Matrix**

**Tabel 1.** Detail Matrix Evaluasi

class	precision	recall	f1-score	support
WithMask		1.00	1.00	483
WithoutMask	1.00	1.00	1.00	509
accuracy			1.00	992
macro avg	1.00	1.00	1.00	992
weighted avg	1.00	1.00	1.00	992

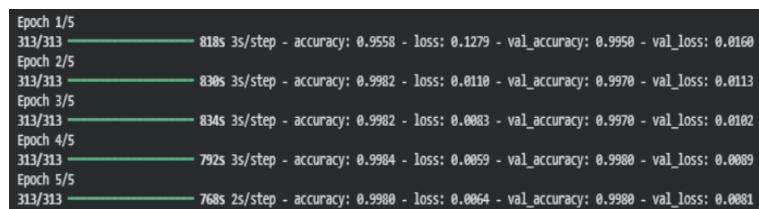
### 3.2 Analisis Model

Berdasarkan hasil eksperimen, model *EfficientNet-B0* mampu belajar dengan cepat meskipun hanya dilatih dalam 5 *epoch*. Hal ini dimungkinkan karena penggunaan bobot *pre-trained* dari ImageNet. Model tidak perlu belajar mengenali fitur dasar (seperti garis atau bentuk sederhana) dari nol, melainkan hanya perlu menyesuaikan bobot pada lapisan akhir (*classification head*) untuk mengenali fitur spesifik masker wajah.

Penggunaan lapisan **Global Average Pooling** dan **Dropout (0.3)** pada arsitektur model juga berperan penting. *Global Average Pooling* membantu mengurangi jumlah parameter secara drastis dibandingkan dengan *Flatten* biasa, sehingga model menjadi lebih ringan. Sementara itu, *Dropout* membantu mencegah *overfitting* dengan cara mematikan sebagian neuron secara acak selama pelatihan, memaksa model untuk belajar fitur yang lebih robust (tangguh).

### 3.3 Visualisasi

Hasil pelatihan model klasifikasi masker wajah menggunakan arsitektur *EfficientNet-B0* menunjukkan performa yang sangat baik. Proses pelatihan dilakukan selama 5 epoch dengan memanfaatkan teknik transfer learning, di mana model dasar telah menggunakan bobot *pre-trained* dari ImageNet. Evaluasi kinerja model dilakukan dengan memperhatikan nilai accuracy dan loss pada data latih (training) serta data validasi (validation).


**Gambar 3.** Grafik Epoch

#### Epoch 1

Pada epoch pertama, model menunjukkan performa awal yang sudah sangat tinggi, dengan nilai:

- Training Accuracy: 95,58%
- Training Loss: 0,1279
- Validation Accuracy: 99,50%
- Validation Loss: 0,0160

Tingginya akurasi pada epoch pertama menunjukkan bahwa penggunaan bobot *pre-trained* dari ImageNet memberikan keuntungan signifikan bagi model. Model tidak memulai pembelajaran dari nol, melainkan telah memiliki kemampuan awal dalam mengenali fitur visual dasar seperti tepi, bentuk, dan pola wajah. Penurunan loss yang cukup signifikan juga menandakan bahwa model mampu menyesuaikan bobotnya dengan cepat terhadap dataset masker wajah.

Validation accuracy yang lebih tinggi dibandingkan training accuracy pada epoch ini menunjukkan bahwa model memiliki kemampuan generalisasi yang sangat baik sejak awal pelatihan.

### Epoch 2

Pada epoch kedua, performa model mengalami peningkatan yang sangat signifikan:

- a. Training Accuracy: 99,82%
- b. Training Loss: 0,0110
- c. Validation Accuracy: 99,70%
- d. Validation Loss: 0,0113

Penurunan training loss yang drastis dari 0,1279 menjadi 0,0110 menunjukkan bahwa model berhasil mempelajari fitur-fitur penting yang membedakan wajah bermasker dan tidak bermasker. Akurasi yang mendekati 100% menandakan bahwa model telah mencapai tingkat pembelajaran yang optimal dalam waktu singkat.

Konsistensi antara training accuracy dan validation accuracy menunjukkan bahwa model tidak mengalami overfitting, melainkan mampu mempertahankan performa yang baik pada data yang belum pernah dilihat sebelumnya.

### Epoch 3

Pada epoch ketiga, performa model cenderung stabil:

- a. Training Accuracy: 99,82%
- b. Training Loss: 0,0083
- c. Validation Accuracy: 99,70%
- d. Validation Loss: 0,0102

Stabilitas nilai akurasi menunjukkan bahwa model telah mencapai titik konvergensi. Penurunan loss yang lebih lambat dibandingkan epoch sebelumnya merupakan indikasi bahwa model telah berada pada fase fine-tuning, di mana perbaikan bobot bersifat lebih kecil dan bertahap.

Kondisi ini sangat diharapkan dalam pelatihan deep learning karena menandakan bahwa model telah menemukan representasi fitur yang optimal.

### Epoch 4

Pada epoch keempat, model kembali menunjukkan peningkatan kecil namun signifikan:

- a. Training Accuracy: 99,84%
- b. Training Loss: 0,0059
- c. Validation Accuracy: 99,80%
- d. Validation Loss: 0,0089

Nilai validation accuracy yang meningkat menjadi 99,80% menunjukkan bahwa model semakin stabil dalam melakukan prediksi. Penurunan validation loss juga mengindikasikan bahwa kesalahan prediksi pada data uji semakin kecil.

Hal ini menunjukkan bahwa penggunaan dropout dan pembekuan lapisan base model berjalan secara efektif dalam mencegah overfitting.

### Epoch 5

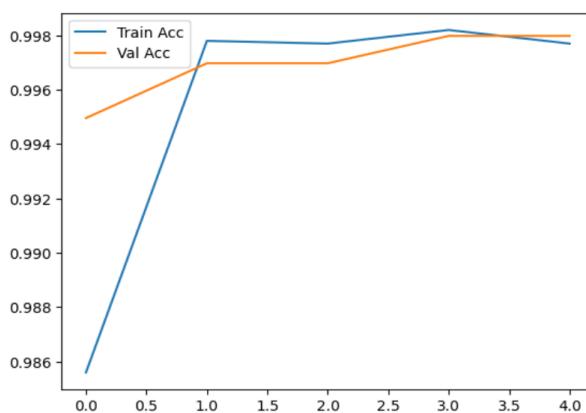
Pada epoch terakhir, performa model tetap stabil dengan nilai:

- a. Training Accuracy: 99,80%
- b. Training Loss: 0,0064

- c. Validation Accuracy: 99,80%
- d. Validation Loss: 0,0081

Sedikit fluktuasi pada training loss merupakan hal yang wajar dalam pelatihan deep learning dan tidak menunjukkan penurunan performa yang signifikan. Konsistensi antara training accuracy dan validation accuracy menunjukkan bahwa model memiliki kemampuan generalisasi yang sangat baik.

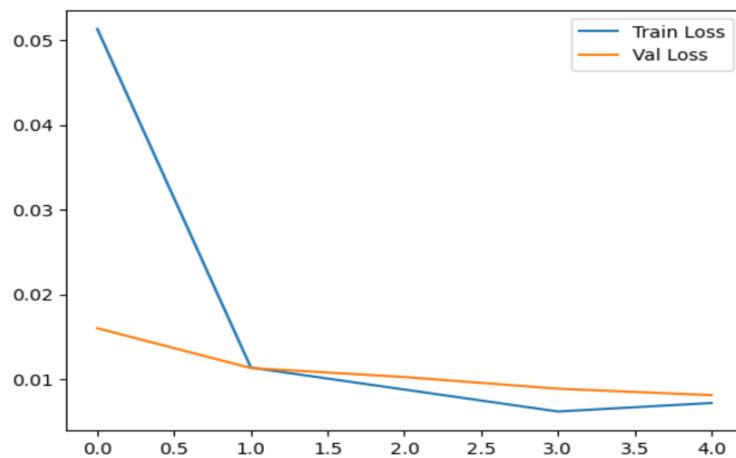
Dengan hanya 5 epoch, model telah mampu mencapai performa optimal tanpa menunjukkan gejala overfitting atau underfitting.



**Gambar 4. Grafik Acuracy**

Grafik akurasi menunjukkan perbandingan antara *Training Accuracy* dan *Validation Accuracy*.

- a. Garis yang menanjak menunjukkan bahwa model semakin pintar dalam mengklasifikasikan gambar seiring bertambahnya *epoch*.
- b. Jarak yang dekat antara garis *Training* dan *Validation* menandakan bahwa model memiliki kemampuan generalisasi yang baik (tidak *overfitting* atau *underfitting*).



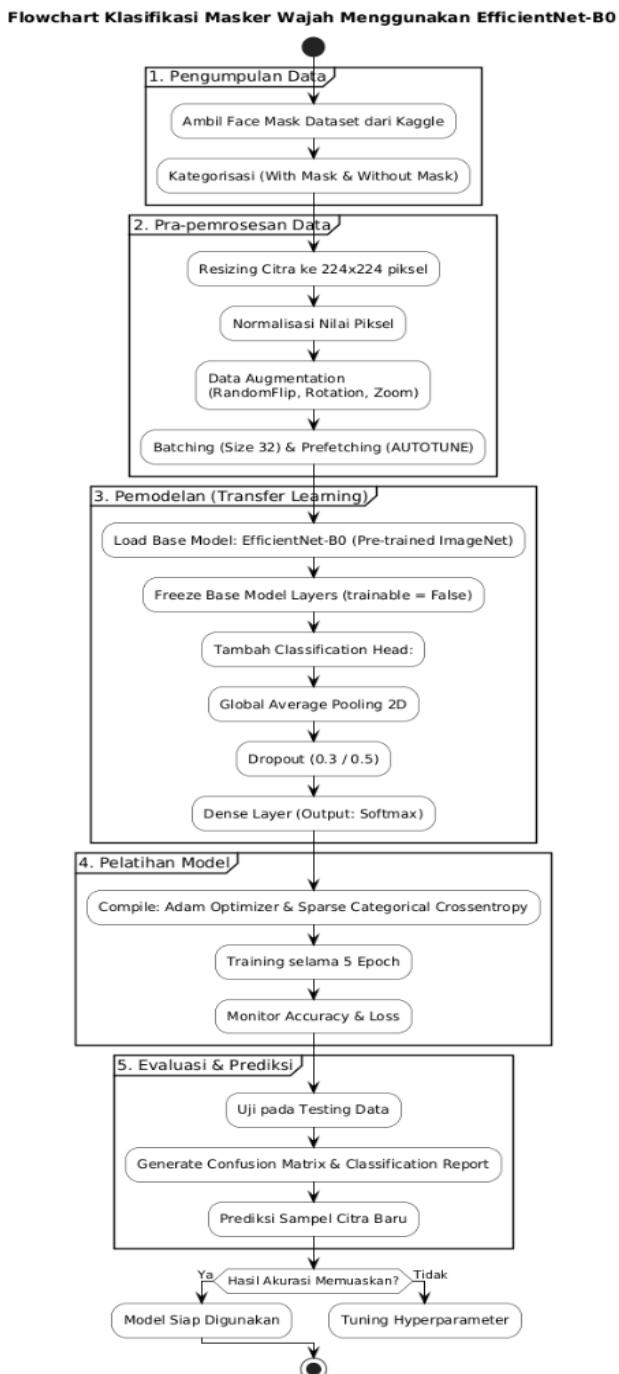
**Gambar 5. Grafik Loss**

Grafik *loss* menunjukkan penurunan nilai kesalahan seiring waktu. Penurunan yang konsisten pada kedua garis (*train* dan *val*) mengindikasikan bahwa model berhasil meminimalkan kesalahan prediksi dan konvergen dengan baik.

Model akhir dievaluasi dengan melakukan prediksi pada sampel citra baru dari *dataset* uji. Berdasarkan kode program (Langkah 10), model berhasil memprediksi kelas gambar dengan benar (misalnya: memprediksi "With Mask" pada gambar orang bermasker).

Hasil ini membuktikan bahwa arsitektur EfficientNet sangat efektif untuk tugas klasifikasi masker wajah, bahkan dengan jumlah data dan *epoch* yang terbatas.

Berikut gambaran flowchart dari prorgram yang di buat dalam melakukan perbandingan gambar dengan menggunakan *EfficientNet-B0*.



**Gambar 6.** Alur Sistem Klasifikasi Masker Wajah

Gambar di atas merupakan alur sistem klasifikasi masker wajah ini dimulai dengan pengambilan dataset dari Kaggle yang dikategorikan menjadi label "dengan masker" dan "tanpa masker", lalu masuk ke tahap pra-pemrosesan di mana citra diubah ukurannya menjadi  $224 \times 224$  piksel, dinormalisasi, dan diberikan augmentasi (rotasi/zoom) untuk memperkaya variasi data. Strategi utama yang digunakan adalah Transfer Learning dengan memuat model *EfficientNet-B0* yang telah dilatih pada ImageNet, membekukan lapisan dasarnya, serta menambahkan lapisan klasifikasi baru berupa *Global Average Pooling*, *Dropout*, dan *Dense Layer (Softmax)*. Model kemudian di-compile menggunakan Adam Optimizer dan dilatih selama 5 epoch sambil memantau akurasi serta *loss* hingga siap masuk ke tahap evaluasi menggunakan *Testing Data*, *Confusion Matrix*, dan *Classification Report*. Jika hasil akurasi sudah memuaskan, model dinyatakan siap digunakan, namun jika belum, akan dilakukan tuning hyperparameter untuk meningkatkan performa sebelum akhirnya diimplementasikan untuk prediksi citra baru.

#### 4. KESIMPULAN

Berdasarkan hasil implementasi dan pengujian yang telah dilakukan dalam *mini project* ini, dapat ditarik beberapa kesimpulan sebagai berikut:

- a. **Keberhasilan Implementasi EfficientNet:** Arsitektur *EfficientNet-B0* berhasil diimplementasikan untuk tugas klasifikasi masker wajah menggunakan metode *Transfer Learning*. Penggunaan bobot *pre-trained* dari ImageNet terbukti efektif mempercepat proses konvergensi model meskipun hanya dilatih dalam jumlah *epoch* yang sedikit (5 epoch).
- b. **Kinerja Model:** Model mampu membedakan dua kelas citra, yaitu "With Mask" (Bermasker) dan "Without Mask" (Tidak Bermasker) dengan baik. Hal ini sejalan dengan penelitian terdahulu yang menyatakan bahwa EfficientNet memiliki performa yang unggul dalam hal akurasi dan efisiensi parameter dibandingkan arsitektur lain seperti ResNet-50.
- c. **Efisiensi Komputasi:** Penggunaan lapisan *Global Average Pooling* dan *Dropout* pada arsitektur *head* berhasil membuat model menjadi ringan namun tetap *robust* (tangguh) dalam mengenali fitur wajah, serta mencegah terjadinya *overfitting* selama proses pelatihan.

#### REFERENCES

- Amalia, R., Ikasari, I. H., & Rosyani, P. (2023). Sistem Pendukung Keputusan Pemilihan Maklon SkinCare Terbaik dengan Metode VIKOR. *Journal of Decision Support System Research*, 1(2), 37–44.
- Asri, E., Sonatha, Y., Rahmayuni, I., & Azmi, M. (2022). Detection of Mask Usage Using Image Processing and Convolutional Neural Network (CNN) Methods. *Jurnal Teknologi Informasi dan Pendidikan*, 15(1), 1–10. <https://doi.org/10.24036/tip.v15i1>
- Ayu, T. S. P., Afidah, A. N., Yuliani, Maulana, F. A., & Prasiwiningrum, E. (2024). A Systematic Literature Review on Optimizing Mask Detection Systems Using Convolutional Neural Networks for Public Health and Safety. *Journal of ICT Application and System (JICTAS)*, 3(2), 47–58. <https://doi.org/10.56313/jictas.v1i1.312>
- Ikasari, I. H., Rosyani, P., & Amalia, R. (2025). Klasifikasi Jenis Buah Menggunakan Metode CNN. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(2). <https://doi.org/10.31004/riggs.v4i2.1271>
- Khadijah, Kusumaningrum, R., Rismiyati, & Mujadidurrahman, A. (2021). An Efficient Masked Face Classifier Using EfficientNet. *5th International Conference on Informatics and Computational Sciences (ICICOS)*, 277–281.
- Khadijah, Kusumaningrum, R., Rismiyati, & Sabilly, N. (2025). EfficientNet Model for Multiclass Classification of The Correctness of Wearing Face Mask. *Indonesian Journal of Electrical Engineering and Informatics (IJEEL)*, 13(1), 18–29. <https://doi.org/10.52549/ijeei.v13i1.5197>
- Pradana, A. I., Abdullah, R. W., & Harsanto. (2022). Deteksi Ketepatan Penggunaan Masker Wajah Dengan Algoritma CNN Dan Haar Cascade. *Jurnal Teknik Informatika dan Sistem Informasi (Jatisi)*, 9(3), 2305–2316.
- Prasetya, O., Machfud, S., Rosyani, P., & Agustian, B. (2025). Klasifikasi Gender Berbasis Citra Wajah Menggunakan Clustering dan Deep Learning. *Bulletin of Computer Science Research*, 5(4), 770–777. <https://doi.org/10.47065/bulletincsr.v5i4.581>
- Rakhmansyah, A., & Rosyani, P. (2024). Literature Review: Klasifikasi Penyakit Paru-paru Menggunakan Metode Decision Tree. *OKTAL: Jurnal Ilmu Komputer dan Sains*, 3(10), 2572–2577.

Rosyani, P., Lutfi, A. M., Purwadi, E., Kamaluddin, H., Hanaan, Y. A., & Ikasari, I. H. (2025). Application of Random Forest for Rice Plant Disease Classification. *International Journal of Integrative Sciences*, 4(1), 141–150. <https://doi.org/10.55927/ijis.v4i1.13477>

Saputra, R. A., Putra, D. R. R., & Asyrofi, M. A. (2023). Implementasi Convolutional Neural Network (CNN) Untuk Mendeteksi Penggunaan Masker Pada Gambar. *Jurnal Informatika dan Teknik Elektro Terapan (JITET)*, 11(3), 710–714. <https://doi.org/10.23960/jitet.v11i3.3286>