

Perbandingan Model Deep Learning DenseNet121, EfficientNetB0 dan Resnet-50 pada Klasifikasi Anemia Citra Telapak Tangan

Muhammad Ihksan^{1*}, Dede Fauzi²

¹ Manajemen Informasi Kesehatan, Universitas Syedza Saintika, Padang, Indonesia

² Bisnis Digital, Universitas Syedza Saintika, Padang, Indonesia

Email: ^{1*} muhammad.ihksan2020@gmail.com, ² dedefauzi.mkom23@gmail.com

Email Penulis Korespondensi: muhammad.ihksan2020@gmail.com

Submitted 02-03-2026; Accepted 06-05-2026; Published 30-06-2026

Abstrak

Anemia merupakan masalah kesehatan global yang mempengaruhi sekitar 1,2 miliar orang di seluruh dunia, dengan prevalensi tertinggi pada ibu hamil dan remaja putri. Diagnosis konvensional melalui pemeriksaan darah di laboratorium bersifat invasif, memerlukan tenaga medis terlatih, serta tidak terjangkau bagi masyarakat di daerah terpencil. Penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja tiga arsitektur deep learning, yaitu DenseNet121, EfficientNetB0, dan ResNet-50, dalam mengklasifikasikan kondisi anemia dan non-anemia secara non-invasif berbasis citra telapak tangan. Dataset yang digunakan merupakan dataset publik anemiatangan dari platform Kaggle yang terdiri dari 10.200 citra dengan dua kelas, yaitu Anemia dan Non-Anemia, yang dibagi menjadi data pelatihan sebesar 80% (8.200 citra), validasi 10% (1.000 citra), dan pengujian 10% (1.000 citra). Ketiga model dilatih menggunakan pendekatan transfer learning dengan bobot pra-latih dari ImageNet, disertai pra-pemrosesan dan augmentasi data. Evaluasi dilakukan berdasarkan metrik akurasi, presisi, recall, F1-Score, dan AUC-ROC (Area Under the Receiver Operating Characteristic Curve). Hasil pengujian menunjukkan bahwa DenseNet121 dan EfficientNetB0 mencapai akurasi tertinggi sebesar 99% dengan nilai presisi, recall, dan F1-Score mendekati sempurna sebesar 0,99, sementara ResNet-50 mencatat akurasi sebesar 97%. Dengan demikian, DenseNet121 dan EfficientNetB0 terbukti sebagai arsitektur yang paling optimal untuk implementasi sistem skrining anemia non-invasif berbasis citra telapak tangan, sehingga berpotensi diintegrasikan ke dalam aplikasi mobile maupun sistem telemedicine guna mendukung deteksi dini anemia di daerah terpencil.

Kata Kunci: Deep Learning; Densenet121; EfficientNetB0; Resnet-50; Klasifikasi; Anemia; Citra Telapak Tangan

Abstract

Anemia is a global health problem affecting approximately 1.2 billion people worldwide, with the highest prevalence among pregnant women and adolescent girls. Conventional diagnosis through laboratory blood tests is invasive, requires trained medical personnel, and is unaffordable for communities in remote areas. This study aims to evaluate and compare the performance of three deep learning architectures, namely DenseNet121, EfficientNetB0, and ResNet-50, in classifying anemia and non-anemia conditions non-invasively based on palm images. The dataset used is a public dataset called anemiatangan from the Kaggle platform, consisting of 10,200 images with two classes, Anemia and Non-Anemia, divided into 80% training data (8,200 images), 10% validation (1,000 images), and 10% testing (1,000 images). All three models were trained using a transfer learning approach with pre-trained weights from ImageNet, accompanied by preprocessing and data augmentation. Evaluation was performed based on accuracy, precision, recall, F1-Score, and AUC-ROC (Area Under the Receiver Operating Characteristic Curve) metrics. The test results indicate that DenseNet121 and EfficientNetB0 achieved the highest accuracy of 99% with precision, recall, and F1-Score values approaching perfection at 0.99, while ResNet-50 recorded an accuracy of 97%. Therefore, DenseNet121 and EfficientNetB0 are proven to be the most optimal architectures for implementing a non-invasive anemia screening system based on palm images, with the potential to be integrated into mobile applications and telemedicine systems to support early detection of anemia in remote areas.

Keywords: Deep Learning; DenseNet121; EfficientNetB0; ResNet-50; Classification; Anemic; Palm Image

1. PENDAHULUAN

Anemia merupakan salah satu masalah kesehatan global yang masih menjadi perhatian serius hingga saat ini. Organisasi Kesehatan Dunia (WHO) memperkirakan bahwa anemia mempengaruhi sekitar 1,2 miliar orang di seluruh dunia, dengan prevalensi tertinggi pada anak-anak di bawah usia lima tahun dan wanita usia produktif [1], [2]. Kondisi ini ditandai dengan rendahnya kadar hemoglobin dalam darah, yang berdampak pada penurunan produktivitas, gangguan kognitif, hingga peningkatan risiko kematian ibu dan bayi [3]. Di Indonesia, anemia juga menjadi tantangan kesehatan masyarakat yang signifikan. Data prevalensi anemia pada ibu hamil mencapai 48,9% dan pada remaja putri sebesar 32%, angka yang tergolong tinggi dan memerlukan perhatian serius, terutama di daerah-daerah dengan akses layanan kesehatan yang terbatas [4], [5].

Metode diagnosis anemia secara konvensional umumnya dilakukan melalui pemeriksaan darah lengkap di laboratorium, seperti pengukuran kadar hemoglobin menggunakan alat hematologi [6]. Meskipun metode ini terbilang akurat, prosedurnya bersifat invasif, membutuhkan tenaga medis terlatih, serta memerlukan waktu dan biaya yang tidak sedikit. Hal ini menjadi kendala tersendiri bagi masyarakat di wilayah terpencil yang memiliki keterbatasan akses terhadap fasilitas kesehatan. Oleh karena itu, diperlukan pendekatan alternatif yang lebih praktis, non-invasif, dan terjangkau untuk mendeteksi anemia secara dini, sehingga penanganan dapat dilakukan lebih cepat dan efisien [7], [8].

Perkembangan kecerdasan buatan, khususnya *deep learning*, telah merevolusi cara komputer memahami dan menganalisis data visual. *Deep learning* merupakan cabang dari *machine learning* yang menggunakan jaringan saraf tiruan berlapis-lapis (*deep neural network*) untuk mempelajari representasi fitur secara hierarkis dari data mentah, sehingga mampu mengenali pola kompleks yang sulit diidentifikasi secara manual [9], [10], [11], [12]. Dalam konteks

klasifikasi citra medis, beberapa arsitektur *Convolutional Neural Network* (CNN) telah terbukti unggul dalam berbagai tugas pengenalan visual. ResNet-50 (*Residual Network*) menggunakan mekanisme *skip connection* untuk mengatasi masalah *vanishing gradient* pada jaringan yang sangat dalam dengan 50 lapisan, sehingga pelatihan model menjadi lebih stabil dan efisien [13], [14]. DenseNet121 (*Densely Connected Network*) memperluas konsep tersebut dengan menghubungkan setiap lapisan ke semua lapisan berikutnya secara langsung, mendorong penggunaan ulang fitur dan mengurangi jumlah parameter secara signifikan [15], [16]. Sementara itu, EfficientNetB0 mengadopsi pendekatan *compound scaling* yang menyeimbangkan kedalaman, lebar, dan resolusi jaringan secara proporsional, menghasilkan model yang lebih ringan namun tetap kompetitif dalam hal akurasi [17], [18]. Ketiga arsitektur tersebut umumnya digunakan dalam tugas *klasifikasi*, yaitu proses memetakan input citra ke dalam kategori atau kelas tertentu, yang dalam penelitian ini diterapkan untuk membedakan kondisi anemia dan non-anemia berdasarkan fitur visual yang diekstraksi secara otomatis [19], [20].

Beberapa arsitektur CNN yang telah terbukti unggul dalam tugas klasifikasi citra medis antara lain DenseNet121, EfficientNetB0, dan ResNet-50. DenseNet121 dikenal dengan koneksi padat antar lapisan (*dense connection*) yang memungkinkan aliran gradien lebih efisien serta mengurangi jumlah parameter secara signifikan. EfficientNetB0 menawarkan efisiensi komputasi tinggi dengan skalabilitas yang baik melalui teknik *compound scaling* yang menyeimbangkan kedalaman, lebar, dan resolusi jaringan secara serentak. ResNet-50, di sisi lain, memanfaatkan *residual connection* untuk mengatasi masalah *vanishing gradient* pada jaringan yang dalam. Meskipun ketiga arsitektur ini telah digunakan secara luas pada berbagai domain klasifikasi citra medis, studi perbandingan yang secara khusus dan sistematis mengevaluasi kinerja ketiganya pada klasifikasi anemia berbasis citra telapak tangan masih sangat terbatas. Penelitian yang ada umumnya hanya menggunakan satu arsitektur tanpa membandingkan secara komprehensif terhadap arsitektur lain pada domain dan dataset yang sama. Celah penelitian (*research gap*) inilah yang menjadi landasan utama dilakukannya penelitian ini [21], [22], [23].

Berdasarkan celah penelitian tersebut, perbedaan utama penelitian ini dibandingkan penelitian sebelumnya terletak pada evaluasi komparatif tiga arsitektur *transfer learning*, yaitu DenseNet121, EfficientNetB0, dan ResNet-50, secara sistematis pada dataset citra telapak tangan yang sama untuk klasifikasi Anemia dan Non-Anemia. Penelitian ini tidak hanya membandingkan akurasi, tetapi juga mengevaluasi performa model menggunakan metrik *precision*, *recall*, *F1-score*, *confusion matrix*, dan AUC-ROC. Dengan demikian, penelitian ini diharapkan dapat memberikan gambaran yang lebih menyeluruh mengenai arsitektur yang paling optimal untuk pengembangan sistem skrining anemia non-invasif berbasis citra telapak tangan.

Berdasarkan uraian di atas, rumusan masalah dalam penelitian ini mencakup tiga hal utama, yaitu: bagaimana kinerja masing-masing arsitektur DenseNet121, EfficientNetB0, dan ResNet-50 dalam klasifikasi anemia berbasis citra telapak tangan berdasarkan metrik akurasi, presisi, *recall*, dan AUC-ROC; arsitektur manakah yang menghasilkan performa terbaik dalam mengklasifikasikan kondisi anemia dan non-anemia pada citra telapak tangan; serta seberapa efektif pendekatan *transfer learning* berbasis ImageNet dalam meningkatkan kinerja ketiga model pada domain citra telapak tangan.

Penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja tiga arsitektur *deep learning*, yaitu DenseNet121, EfficientNetB0, dan ResNet-50, dalam mengklasifikasikan kondisi anemia dan non-anemia berdasarkan citra telapak tangan. Selain itu, penelitian ini juga bertujuan untuk mengidentifikasi model dengan performa terbaik berdasarkan metrik akurasi, presisi, *recall*, dan nilai AUC-ROC, serta menghasilkan rekomendasi arsitektur yang paling optimal untuk implementasi sistem skrining anemia non-invasif berbasis citra digital.

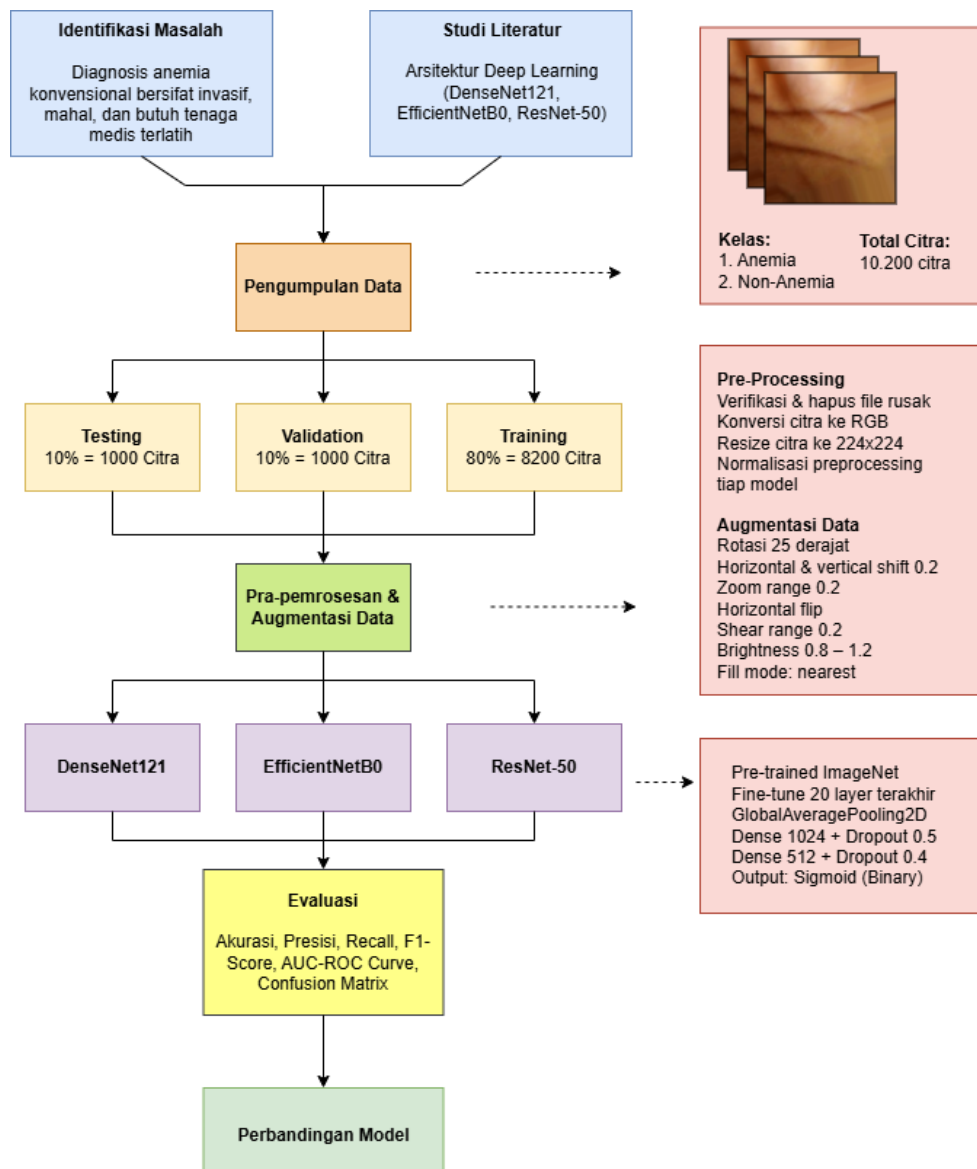
Hasil penelitian ini diharapkan memberikan kontribusi pada beberapa aspek. Secara teoritis, penelitian ini menyediakan bukti empiris komparatif performa arsitektur CNN pada domain klasifikasi anemia berbasis citra telapak tangan, yang dapat memperkaya literatur *deep learning* di bidang kesehatan. Secara praktis, penelitian ini memberikan rekomendasi model *deep learning* yang optimal sebagai dasar pengembangan sistem skrining anemia non-invasif yang dapat diintegrasikan ke dalam aplikasi mobile maupun sistem telemedicine, sehingga memudahkan tenaga kesehatan dan masyarakat umum dalam melakukan deteksi dini anemia. Dari sisi kebijakan, penelitian ini diharapkan dapat mendukung upaya digitalisasi layanan kesehatan primer di Indonesia, khususnya di daerah terpencil yang memiliki keterbatasan akses terhadap fasilitas laboratorium. Penelitian ini menggunakan dataset publik citra telapak tangan (anemiatangan) yang bersumber dari platform Kaggle, terdiri dari dua kelas yaitu Anemia dan Non-Anemia, dengan total 8.200 citra pelatihan, 1.000 citra validasi, dan 1.000 citra pengujian. Ketiga model dilatih menggunakan pendekatan *transfer learning* dengan bobot pra-latih dari ImageNet dan dievaluasi berdasarkan metrik akurasi, presisi, *recall*, dan kurva AUC-ROC.

2. METODOLOGI PENELITIAN

Metode penelitian ini dirancang untuk mengevaluasi dan membandingkan kinerja tiga arsitektur *deep learning*, yaitu EfficientNetB0, DenseNet121, dan ResNet-50, dalam menyelesaikan tugas klasifikasi biner antara kondisi Anemia dan Non-Anemia berbasis citra telapak tangan, guna menentukan model yang memiliki performa terbaik.

2.1 Alur Penelitian

Penelitian ini dilaksanakan melalui serangkaian tahapan yang terstruktur untuk menghasilkan model klasifikasi anemia yang akurat dan mampu menggeneralisasi data dengan baik. Secara keseluruhan, alur penelitian yang digunakan dalam penelitian ini ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

Berdasarkan Gambar 1, penelitian ini diawali dengan dua kegiatan paralel, yaitu identifikasi masalah terkait keterbatasan diagnosis anemia konvensional yang bersifat invasif dan membutuhkan tenaga medis terlatih, serta studi literatur mengenai arsitektur *deep learning* yang relevan, meliputi DenseNet121, EfficientNetB0, dan ResNet-50. Selanjutnya dilakukan pengumpulan data menggunakan dataset publik anemiatangan dari platform Kaggle yang terdiri dari dua kelas, yaitu Anemia dan Non-Anemia, dengan total 10.200 citra. Data kemudian melewati tahap pra-pemrosesan dan augmentasi, yang mencakup verifikasi dan penghapusan file rusak, konversi citra ke format RGB, resize ke ukuran 224×224 piksel, serta normalisasi preprocessing tiap model. Augmentasi data juga diterapkan meliputi rotasi 25 derajat, pergeseran horizontal dan vertikal, zoom, flip, shear, dan penyesuaian brightness. Setelah itu, dataset dibagi menjadi tiga subset, yaitu data pelatihan sebesar 80% (8.200 citra), data validasi sebesar 10% (1.000 citra), dan data pengujian sebesar 10% (1.000 citra) [24], [25], [26].

Ketiga model arsitektur CNN, yaitu DenseNet121, EfficientNetB0, dan ResNet-50, kemudian dilatih secara paralel menggunakan pendekatan *transfer learning* dengan bobot pra-latih dari ImageNet, dilengkapi lapisan GlobalAveragePooling2D, Dense 1024 dengan Dropout 0,5, Dense 512 dengan Dropout 0,4, dan lapisan output sigmoid untuk klasifikasi biner. Konfigurasi pelatihan menggunakan optimizer Adam dengan learning rate 1×10^{-4} , fungsi loss binary crossentropy, serta sejumlah callback berupa EarlyStopping, ModelCheckpoint, dan ReduceLROnPlateau untuk mengoptimalkan proses pelatihan. Hasil pelatihan ketiga model selanjutnya dievaluasi menggunakan metrik akurasi, presisi, *recall*, F1-Score, kurva AUC-ROC, dan confusion matrix, yang kemudian dibandingkan secara menyeluruh untuk menentukan arsitektur dengan performa terbaik dalam klasifikasi anemia berbasis citra telapak tangan.

2.2 Pengumpulan Data

Pengumpulan data (*dataset*) adalah tahap awal dan fundamental dalam membangun model deep learning, yaitu proses mengumpulkan sekumpulan data yang akan digunakan untuk melatih, memvalidasi, dan menguji model. Dataset merupakan fondasi utama bagi model untuk mempelajari pola, sehingga kualitas dan kuantitas data yang dikumpulkan sangat menentukan performa model yang dihasilkan. Dalam konteks klasifikasi citra medis, pengumpulan dataset dilakukan dengan mengambil gambar dari subjek penelitian secara langsung maupun memanfaatkan dataset yang telah tersedia secara publik, seperti yang terdapat pada platform Kaggle atau repositori penelitian terbuka. Data yang terkumpul kemudian dibagi menjadi tiga subset, yaitu *training set* untuk melatih model, *validation set* untuk memantau performa selama pelatihan, dan *testing set* untuk mengevaluasi kemampuan model pada data yang belum pernah dilihat sebelumnya [27], [28], [29].

Data yang digunakan dalam penelitian ini merupakan dataset publik yang diperoleh dari *platform* Kaggle dengan nama dataset anemia tangan. Dataset ini terdiri dari dua kelas, yaitu Anemia dan Non-Anemia, yang merepresentasikan kondisi klinis pasien berdasarkan citra telapak tangan. Pemilihan citra telapak tangan sebagai objek penelitian didasarkan pada perubahan warna kulit yang tampak pucat akibat berkurangnya kadar hemoglobin dalam darah, sehingga dapat dijadikan indikator visual non-invasif untuk mendeteksi kondisi anemia. Total keseluruhan dataset berjumlah 10.200 citra, yang kemudian dibagi menjadi tiga subset sesuai kebutuhan pelatihan model, yaitu data pelatihan (*training*) sebanyak 8.200 citra (80%), data validasi (*validation*) sebanyak 1.000 citra (10%), dan data pengujian (*testing*) sebanyak 1.000 citra (10%). Pembagian data dilakukan secara proporsional untuk memastikan distribusi kelas yang seimbang pada setiap subset, sehingga proses pelatihan model dapat berjalan secara optimal dan hasil evaluasi yang diperoleh mencerminkan kemampuan generalisasi model secara objektif.

Gambar 2 menyajikan representasi visual dari contoh citra telapak tangan pada masing-masing kelas dalam dataset yang digunakan pada penelitian ini. Gambar 2(a) menunjukkan contoh citra dari kelas Anemia, yang secara visual cenderung memperlihatkan karakteristik warna telapak tangan lebih pucat atau kebiruan. Sementara itu, Gambar 2(b) menampilkan contoh citra dari kelas Non-Anemia, yang umumnya menunjukkan warna telapak tangan lebih kemerahan atau mendekati kondisi normal. Perbedaan karakteristik visual tersebut menjadi salah satu informasi penting yang dipelajari oleh model dalam proses klasifikasi kondisi anemia dan non-anemia berbasis citra telapak tangan.



Gambar 2. Contoh Dataset Anemia dan Non-Anemia

Berdasarkan Tabel 1 dibawah ini, menunjukkan distribusi dataset yang digunakan dalam penelitian ini, yang terdiri dari dua kelas, yaitu Anemia dan Non-Anemia. Dataset dibagi secara proporsional ke dalam tiga subset, yaitu testing, validation, dan training. Masing-masing kelas memiliki jumlah data yang seimbang (balanced), di mana kelas Anemia dan Non-Anemia masing-masing berjumlah 5.100 citra (50%), sehingga total keseluruhan dataset berjumlah 10.200 citra. Pada subset testing dan validation, setiap kelas terdiri dari 500 citra (5% dari total data), sedangkan pada subset training setiap kelas terdiri dari 4.100 citra (40% dari total data). Distribusi data yang seimbang antara kedua kelas pada setiap subset bertujuan untuk menghindari bias pada proses pelatihan model, sehingga model tidak cenderung memprediksi salah satu kelas secara dominan dan mampu mengklasifikasikan kondisi Anemia maupun Non-Anemia dengan tingkat akurasi yang optimal.

Tabel 1. Distribusi Dataset Anemia dan Non-Anemia

Kategori	Testing	Validation	Training	Total
Anemia	500 / (5%)	500 / (5%)	4100 / (40%)	5100 / (50%)
Non-Anemia	500 / (5%)	500 / (5%)	4100 / (40%)	5100 / (50%)

2.3 Pra-pemrosesan & Augmentasi

Pra-pemrosesan dan augmentasi data adalah dua tahapan penting yang dilakukan sebelum citra dimasukkan ke dalam model deep learning. Pra-pemrosesan berfungsi untuk menyeragamkan data citra, seperti menyamakan ukuran gambar, menormalkan nilai piksel, serta membagi data menjadi bagian pelatihan, validasi, dan pengujian. Augmentasi data dilakukan dengan membuat variasi baru dari citra yang sudah ada melalui teknik seperti rotasi, pembalikan, pergeseran, dan perubahan kecerahan, sehingga jumlah data pelatihan menjadi lebih beragam. Kedua tahapan ini bekerja bersama untuk membantu model belajar lebih baik, mencegah overfitting, dan meningkatkan kemampuan model dalam mengklasifikasikan citra secara akurat pada data yang belum pernah dilihat sebelumnya [30], [31].

Sebelum data citra digunakan dalam proses pelatihan model, terlebih dahulu dilakukan tahap pra-pemrosesan untuk memastikan kualitas dan konsistensi data yang akan digunakan. Tahap ini diawali dengan verifikasi seluruh file citra dalam dataset dan penghapusan file yang rusak atau tidak dapat dibaca, guna menghindari gangguan pada proses pelatihan. Selanjutnya, seluruh citra dikonversi ke format RGB untuk memastikan keseragaman representasi warna pada setiap piksel. Citra kemudian di-resize ke ukuran 224×224 piksel sesuai dengan kebutuhan input ketiga arsitektur model yang digunakan, yaitu DenseNet121, EfficientNetB0, dan ResNet-50. Normalisasi nilai piksel dilakukan menggunakan fungsi preprocessing bawaan masing-masing arsitektur yang tersedia pada library TensorFlow/Keras, yaitu `tf.keras.applications.densenet.preprocess_input`, `tf.keras.applications.efficientnet.preprocess_input`, dan `tf.keras.applications.resnet50.preprocess_input`, sehingga distribusi nilai piksel yang dihasilkan sesuai dengan karakteristik bobot pra-latih (pre-trained weights) dari masing-masing model.

Mengingat jumlah data pelatihan yang terbatas, augmentasi data diterapkan secara otomatis selama proses pelatihan menggunakan ImageDataGenerator dari TensorFlow/Keras untuk memperkaya variasi data dan mengurangi risiko overfitting. Teknik augmentasi yang diterapkan meliputi rotasi citra hingga 25 derajat, pergeseran horizontal dan vertikal sebesar 0,2, zoom range sebesar 0,2, horizontal flip, shear range sebesar 0,2, serta penyesuaian brightness dalam rentang 0,8 hingga 1,2. Metode pengisian piksel kosong akibat transformasi geometris menggunakan fill mode nearest, yaitu mengisi piksel kosong dengan nilai piksel terdekat. Augmentasi data hanya diterapkan pada subset data pelatihan, sementara data validasi dan data pengujian hanya melewati proses normalisasi tanpa augmentasi, untuk memastikan evaluasi model dilakukan pada data yang merepresentasikan kondisi citra yang sesungguhnya.

2.4 Pelatihan

Pelatihan model dalam penelitian ini menggunakan pendekatan *transfer learning* dengan memanfaatkan bobot pra-latih (pre-trained weights) dari ImageNet pada ketiga arsitektur yang dibandingkan, yaitu DenseNet121, EfficientNetB0, dan ResNet-50. Pendekatan ini dipilih karena *transfer learning* terbukti efektif dalam meningkatkan performa model pada dataset dengan jumlah data yang terbatas, sekaligus mempercepat proses konvergensi selama pelatihan [32]. Sebanyak 20 layer terakhir dari masing-masing model dasar (base model) dibekukan sementara pada tahap awal, kemudian dilepas (unfreeze) untuk proses fine-tuning guna menyesuaikan bobot model dengan karakteristik domain citra telapak tangan. Pada bagian atas setiap base model, ditambahkan lapisan GlobalAveragePooling2D untuk merangkul fitur spasial, diikuti lapisan Dense dengan 1.024 neuron dan fungsi aktivasi ReLU dengan regularisasi L2 sebesar 0,01 serta Dropout 0,5, kemudian lapisan Dense kedua dengan 512 neuron dan fungsi aktivasi ReLU dengan regularisasi L2 sebesar 0,01 serta Dropout 0,4, dan diakhiri dengan lapisan output tunggal menggunakan fungsi aktivasi sigmoid untuk menghasilkan prediksi klasifikasi biner antara kelas Anemia dan Non-Anemia.

Konfigurasi pelatihan ketiga model menggunakan optimizer Adam dengan learning rate awal sebesar 1×10^{-4} dan fungsi loss binary crossentropy, serta metrik evaluasi berupa akurasi, presisi, dan recall. Proses pelatihan dijalankan selama maksimal 50 epoch dengan ukuran batch sebesar 32. Untuk mengoptimalkan proses pelatihan dan mencegah overfitting, digunakan beberapa callback, yaitu EarlyStopping dengan patience 10 epoch yang memantau validation loss dan memulihkan bobot terbaik (restore best weights), ModelCheckpoint untuk menyimpan model dengan nilai validation accuracy tertinggi secara otomatis, ReduceLROnPlateau dengan faktor reduksi 0,5 dan patience 5 epoch untuk menurunkan learning rate secara adaptif ketika performa validasi stagnan, serta LearningRateScheduler untuk mengatur penjadwalan learning rate secara eksponensial. Seluruh proses pelatihan dilakukan menggunakan framework TensorFlow 2.x dengan akselerasi GPU pada platform Kaggle Notebooks.

2.5 Evaluasi

Evaluasi kinerja pelatihan model adalah proses menganalisis seberapa baik model deep learning yang telah dilatih mampu menyelesaikan tugasnya, khususnya dalam mengklasifikasikan data baru yang belum pernah dilihat sebelumnya. Proses ini dilakukan menggunakan berbagai metrik kuantitatif, di antaranya akurasi yang mengukur persentase prediksi benar secara keseluruhan, presisi (*precision*) yang mengukur ketepatan prediksi positif, *recall* yang mengukur kemampuan model menemukan seluruh data positif yang sebenarnya, serta F1-Score sebagai rata-rata harmonik antara presisi dan *recall* yang berguna saat data tidak seimbang. Selain itu, *confusion matrix* digunakan untuk memberikan gambaran lebih rinci tentang di mana model melakukan kesalahan pada masing-masing kelas, sementara kurva ROC-AUC mengukur kemampuan model dalam membedakan antara kelas positif dan negatif pada berbagai ambang batas keputusan. Evaluasi yang komprehensif menggunakan kombinasi beberapa metrik ini sangat penting untuk memastikan model benar-benar andal sebelum diterapkan dalam skenario nyata, seperti diagnosis medis berbasis citra [33], [34], [35].

Evaluasi kinerja ketiga model dilakukan menggunakan data pengujian (testing set) yang terdiri dari 1.000 citra dan tidak pernah digunakan selama proses pelatihan, sehingga hasil evaluasi mencerminkan kemampuan generalisasi model

terhadap data baru secara objektif. Metrik evaluasi yang digunakan meliputi akurasi, presisi, *recall*, *F1-Score*, kurva AUC-ROC (*Area Under the Receiver Operating Characteristic Curve*), dan *confusion matrix*. Akurasi mengukur proporsi prediksi yang benar dari keseluruhan data pengujian, sedangkan presisi mengukur seberapa besar proporsi prediksi positif yang benar-benar positif. *Recall* mengukur kemampuan model dalam mendeteksi seluruh sampel positif yang sesungguhnya, sementara *F1-Score* merupakan nilai harmonis antara presisi dan *recall* yang memberikan gambaran keseimbangan antara keduanya. Secara matematis, keempat metrik tersebut diformulasikan sebagai berikut:

2.5.1. Akurasi (*Accuracy*)

Akurasi merupakan metrik dasar yang digunakan untuk menilai kinerja model secara keseluruhan dengan menghitung perbandingan antara jumlah prediksi yang tepat terhadap total keseluruhan data yang diuji. Nilai akurasi yang tinggi mengindikasikan bahwa model mampu mengklasifikasikan data dengan benar secara konsisten.

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

2.5.2. Presisi (*Precision*)

Presisi digunakan untuk menilai seberapa andal model dalam menghasilkan prediksi positif yang tepat sasaran. Metrik ini menggambarkan tingkat ketepatan model ketika menyatakan suatu data sebagai positif, di mana nilai presisi yang tinggi menunjukkan rendahnya jumlah kesalahan prediksi positif (*False Positive*) yang dihasilkan oleh model.

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

2.5.3. Recall

Recall mengukur sensitivitas model dalam mengenali keseluruhan sampel yang sesungguhnya termasuk kelas positif. Nilai *recall* yang tinggi mencerminkan bahwa model memiliki kemampuan yang baik dalam mendeteksi data positif secara menyeluruh dengan meminimalkan jumlah data positif yang terlewat (*False Negative*).

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

2.5.4. F1-Score

F1-Score merupakan metrik yang menggabungkan nilai presisi dan *recall* menjadi satu ukuran tunggal melalui perhitungan rata-rata harmonik keduanya. Metrik ini sangat relevan digunakan pada kondisi di mana terdapat ketidakseimbangan distribusi antar kelas, karena mampu memberikan gambaran yang lebih representatif terhadap stabilitas performa klasifikasi model secara keseluruhan.

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

Keterangan:

TP (<i>True Positive</i>)	: Jumlah data Anemia yang diprediksi benar.
TN (<i>True Negative</i>)	: Jumlah data Non-Anemia yang diprediksi benar.
FP (<i>False Positive</i>)	: Jumlah data Non-Anemia yang salah diprediksi sebagai Anemia.
FN (<i>False Negative</i>)	: Jumlah data Anemia yang salah diprediksi sebagai Non-Anemia.

2.6 Perbandingan

Tahap perbandingan model merupakan tahap akhir dari rangkaian metodologi penelitian ini, yang bertujuan untuk mengidentifikasi arsitektur *deep learning* terbaik di antara ketiga model yang diuji, yaitu DenseNet121, EfficientNetB0, dan ResNet-50, dalam tugas klasifikasi anemia berbasis citra telapak tangan. Perbandingan dilakukan secara komprehensif dengan mengacu pada hasil evaluasi yang diperoleh dari data pengujian, meliputi nilai akurasi, presisi, *recall*, *F1-Score*, dan AUC-ROC dari masing-masing model. Seluruh hasil evaluasi dirangkum dalam satu tabel perbandingan yang memudahkan pembaca dalam menelaah perbedaan performa antar arsitektur secara objektif dan terstruktur.

Selain membandingkan nilai metrik evaluasi secara numerik, perbandingan juga dilakukan secara visual melalui kurva AUC-ROC dan *confusion matrix* dari masing-masing model, sehingga perbedaan kemampuan diskriminasi dan pola kesalahan klasifikasi antar arsitektur dapat diidentifikasi dengan lebih jelas. Model yang dinyatakan sebagai model terbaik adalah model yang secara konsisten menunjukkan nilai tertinggi pada seluruh metrik evaluasi yang digunakan. Hasil perbandingan ini selanjutnya menjadi dasar rekomendasi pemilihan arsitektur yang paling optimal untuk diimplementasikan dalam pengembangan sistem skrining anemia non-invasif berbasis citra telapak tangan di masa mendatang.

3. HASIL DAN PEMBAHASAN

Berdasarkan tahapan metodologi yang telah dijelaskan terhadap eksperimen klasifikasi citra anemia menggunakan tiga arsitektur *Convolutional Neural Network* (CNN) berbasis *transfer learning*. Tujuannya adalah untuk mengevaluasi dan

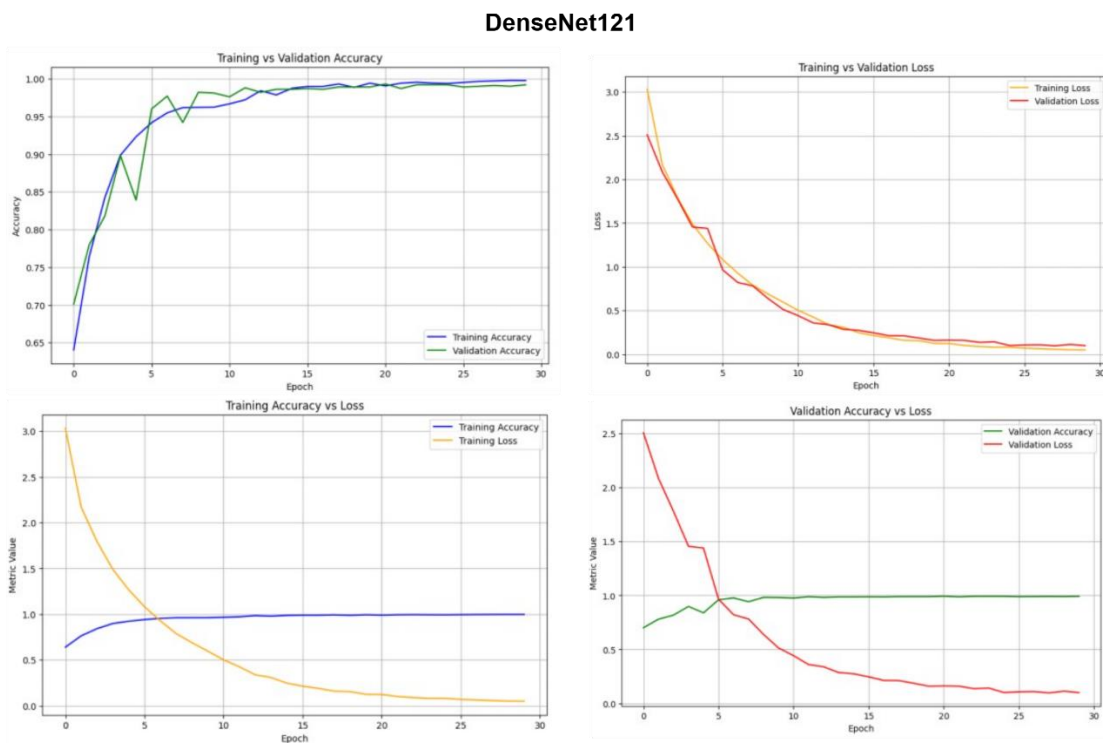
memvalidasi kinerja masing-masing arsitektur, yaitu DenseNet121, EfficientNetB0, dan ResNet-50, dalam mengklasifikasikan kondisi Anemia dan Non-Anemia berdasarkan citra telapak tangan. Analisis yang dilakukan tidak hanya berdasarkan nilai metrik akurasi akhir, tetapi juga mencakup dinamika stabilitas selama proses pelatihan, evaluasi metrik performa secara menyeluruh meliputi presisi, *recall*, *F1-Score*, dan AUC-ROC, analisis kesalahan prediksi melalui confusion matrix, serta implikasi hasil terhadap pengembangan sistem skrining anemia non-invasif berbasis citra digital yang dapat diimplementasikan secara luas di bidang kesehatan.

3.1 Analisis *Training* dan *Validation* Model

3.1.1. DenseNet121

Kurva *training* dan *validation* DenseNet121 Gambar 3 di bawah ini menunjukkan kurva *training* dan *validation* untuk model DenseNet121 selama proses pelatihan. Plot pada bagian kiri atas memperlihatkan bahwa nilai akurasi *training* dan *validation* sama-sama meningkat tajam pada beberapa *epoch* awal dan kemudian stabil mendekati 1,00, yang mengindikasikan bahwa model mampu belajar pola data dengan baik tanpa perbedaan yang signifikan antara kinerja pada data latih dan data validasi. Grafik di kanan atas menampilkan penurunan *loss training* dan *validation* yang konsisten dan cenderung konvergen ke nilai mendekati nol, memperkuat indikasi bahwa proses optimasi berjalan efektif. Sementara itu, grafik di bagian bawah memperjelas hubungan antara akurasi dan *loss* pada masing-masing tahap, di mana *training loss* dan *validation loss* terus menurun seiring meningkatnya akurasi, tanpa adanya pola divergensi yang mengarah pada *overfitting* yang signifikan. Secara keseluruhan, bentuk kurva pada Gambar 3 di bawah ini menunjukkan bahwa konfigurasi pelatihan DenseNet121 menghasilkan model yang stabil dan terkonvergensi dengan baik.

Untuk mengetahui kestabilan dan proses konvergensi model DenseNet121 selama pelatihan, hasil kurva *training* dan *validation* ditampilkan pada Gambar 3.



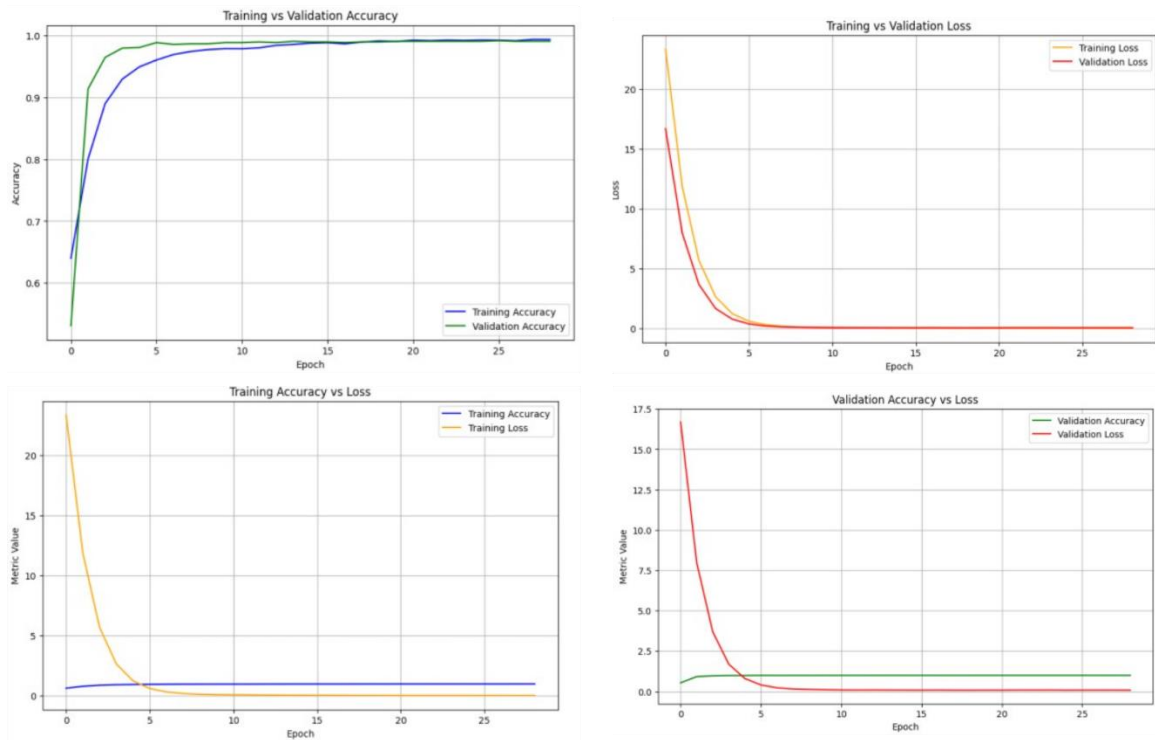
Gambar 3. Kurva *Training* dan *Validation* DenseNet121

3.1.2. EfficientNetB0

Kurva *Training* dan *Validation* EfficientNetB0 Gambar 4 di bawah ini memperlihatkan kurva *training* dan *validation* untuk model EfficientNetB0 selama proses pelatihan. Grafik pada bagian kiri atas menunjukkan bahwa akurasi *training* dan *validation* meningkat tajam pada beberapa *epoch* awal dan kemudian cepat mencapai nilai mendekati 1,00, dengan jarak yang sangat kecil di antara keduanya, yang mengindikasikan bahwa model mampu belajar dengan stabil tanpa perbedaan kinerja yang signifikan antara data latih dan data validasi. Pada grafik kanan atas terlihat bahwa *training loss* dan *validation loss* turun drastis sejak awal pelatihan dan secara bertahap konvergen menuju nilai mendekati nol, menandakan proses optimasi parameter berjalan efektif. Dua grafik di bagian bawah memperjelas hubungan antara akurasi dan *loss*, di mana *training loss* dan *validation loss* terus menurun seiring dengan meningkatnya akurasi, tanpa menunjukkan pola divergensi yang menandakan *overfitting* berat.

Visualisasi kurva *training* dan *validation* pada model EfficientNetB0 disajikan pada Gambar 4 untuk menunjukkan perkembangan akurasi dan *loss* selama proses pelatihan pada dataset citra telapak tangan.

EfficientNetB0




Gambar 4. Kurva *Training* dan *Validation* EfficientNetB0


3.1.3. ResNet-50

Kurva *training* dan *validation* ResNet-50 pada Gambar 5 dibawah ini menampilkan kurva training dan validation untuk model ResNet-50 selama proses pelatihan. Grafik pada bagian kiri atas memperlihatkan bahwa akurasi *training* (garis biru) meningkat secara konsisten dan mendekati nilai 1,00, sementara akurasi *validation* (garis hijau) juga mengikuti tren serupa meskipun sedikit tertinggal pada beberapa *epoch* akhir, yang masih berada dalam rentang yang dapat diterima. Pada grafik kanan atas terlihat bahwa *training loss* (garis oranye) turun dengan tajam di awal pelatihan dan kemudian melambat, sementara *validation loss* (garis merah) mengalami fluktuasi yang lebih besar pada *epoch* akhir, menunjukkan sedikit tantangan dalam konvergensi akhir dibandingkan dua model lainnya. Grafik bagian bawah menjelaskan hubungan antara akurasi dan *loss*, di mana *training loss* dan *validation loss* secara umum terus menurun meskipun dengan variabilitas yang lebih tinggi pada *validation loss*, yang mengindikasikan bahwa ResNet-50 memerlukan konfigurasi regularisasi atau tuning tambahan untuk mencapai konvergensi yang sama stabilnya dengan DenseNet121 dan EfficientNetB0.

Visualisasi kurva *training* dan *validation* pada model ResNet-50 disajikan pada Gambar 5 untuk menunjukkan perkembangan nilai akurasi dan *loss* selama proses pelatihan pada dataset citra telapak tangan.

ResNet-50





Gambar 5. Kurva *Training* dan *Validation* ResNet-50

3.2 Evaluasi *Testing Model*

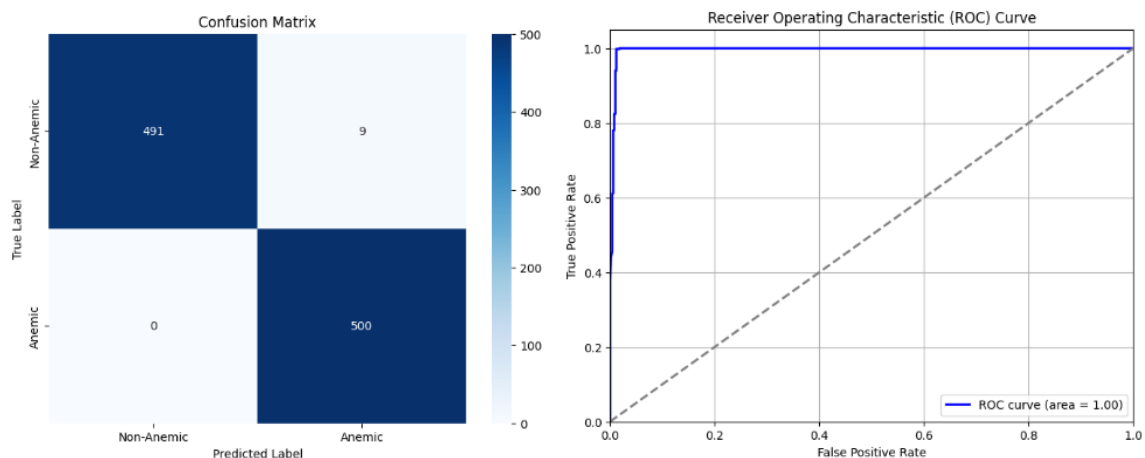
3.2.1. DenseNet121

Tabel 2 di bawah ini menyajikan *classification report* untuk model DenseNet121 pada data uji. Tabel tersebut menunjukkan bahwa model mampu mengklasifikasikan kedua kelas, Anemia dan Non-Anemia, dengan sangat baik, yang terlihat dari nilai *presisi*, *recall*, dan *F1-Score* yang tinggi dan seimbang pada masing-masing kelas. Nilai presisi yang mendekati 1,00 menunjukkan bahwa model jarang melakukan kesalahan ketika memberikan prediksi positif, sedangkan nilai *recall* yang juga tinggi mengindikasikan bahwa sebagian besar sampel yang benar-benar positif berhasil terdeteksi. Kombinasi nilai *F1-Score* yang konsisten pada kedua kelas menegaskan bahwa DenseNet121 memiliki keseimbangan yang baik antara ketepatan dan kelengkapan prediksi, sehingga layak dipertimbangkan sebagai kandidat utama dalam klasifikasi anemia berbasis citra telapak tangan.

Tabel 2. *Classification Report* Model DenseNet121

Kategori	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Anemia	1.00	0.98	0.99	500
Non-Anemia	0.98	1.00	0.99	500

Gambar 6 di bawah ini menampilkan *confusion matrix* dan kurva ROC untuk model DenseNet121. Pada *confusion matrix* terlihat bahwa sebagian besar sampel Anemia dan Non-Anemia diklasifikasikan secara benar, dengan jumlah *True Positive* dan *True Negative* yang jauh lebih besar dibandingkan *False Positive* maupun *False Negative*, sehingga mendukung nilai *recall* dan *presisi* tinggi yang tercantum pada *classification report*. Kurva ROC pada gambar yang sama menunjukkan bentuk kurva yang menempel pada sisi kiri atas dengan nilai AUC yang sangat tinggi, menandakan kemampuan DenseNet121 dalam membedakan kelas Anemia dan Non-Anemia berada pada tingkat yang sangat baik. Secara visual, kombinasi kedua grafik ini mengonfirmasi bahwa kinerja DenseNet121 stabil dan andal pada skenario pengujian.



Gambar 6. Confusion Matrix dan ROC Curve DenseNet121

3.2.2. EfficientNetB0

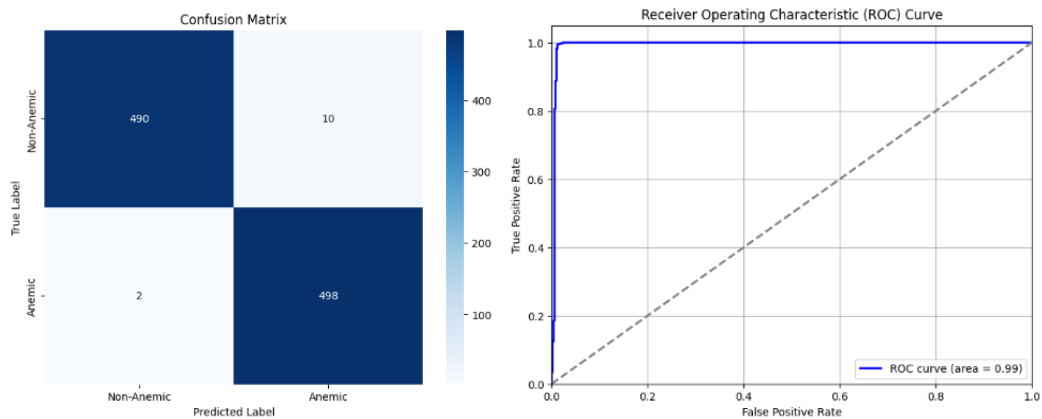
Tabel 3 di bawah ini memperlihatkan *classification report* untuk model EfficientNetB0. Berdasarkan tabel tersebut, terlihat bahwa nilai presisi dan recall pada kelas Anemia dan Non-Anemia berada pada rentang yang sangat tinggi dan hampir simetris, sehingga menghasilkan *F1-Score* yang juga mendekati sempurna pada kedua kelas. Hal ini menunjukkan

bahwa EfficientNetB0 tidak hanya akurat dalam mengidentifikasi sampel yang benar-benar positif, tetapi juga minim dalam menghasilkan prediksi positif yang salah. Dengan jumlah support yang seimbang antara kelas Anemia dan Non-Anemia, performa ini merefleksikan kemampuan EfficientNetB0 dalam melakukan klasifikasi yang konsisten tanpa kecenderungan bias terhadap salah satu kelas.

Tabel 3. *Clasification Report Model EfficientNetB0*

Kategori	Precision	Recall	F1-Score	Support
Anemia	1.00	0.98	0.99	500
Non-Anemia	0.98	1.00	0.99	500

Gambar 7 di bawah ini menampilkan *confusion matrix* dan kurva *ROC* untuk EfficientNetB0. *Confusion matrix* menunjukkan bahwa hampir seluruh sampel uji berhasil diklasifikasikan dengan benar, dengan jumlah kesalahan yang sangat kecil pada kedua kelas. Pola ini sejalan dengan nilai presisi dan *recall* tinggi yang ditampilkan pada Tabel 3. Kurva *ROC* pada Gambar 7 memiliki lintasan yang sangat dekat dengan sudut kiri atas dan nilai *AUC* yang tinggi, yang menunjukkan bahwa EfficientNetB0 mempunyai kemampuan diskriminasi yang sangat baik dalam membedakan antara citra Anemia dan Non-Anemia. Visualisasi ini menguatkan bahwa EfficientNetB0 merupakan arsitektur yang sangat kompetitif untuk tugas klasifikasi anemia berbasis citra telapak tangan.



Gambar 7. *Confusion Matrix dan ROC Curve EfficientNetB0*

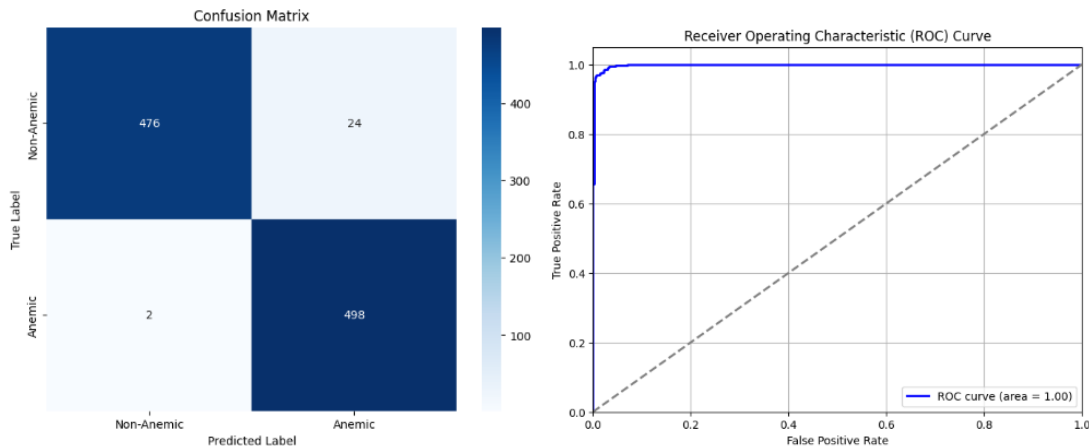
3.2.3. ResNet-50

Tabel 4 di bawah ini menampilkan *classification report* untuk model ResNet-50. Dari tabel tersebut terlihat bahwa nilai presisi dan *recall* pada kedua kelas masih berada pada kategori tinggi, meskipun sedikit lebih rendah dibandingkan DenseNet121 dan EfficientNetB0. Pada kelas Anemia, nilai *recall* yang sedikit lebih rendah mengindikasikan masih adanya sejumlah sampel Anemia yang tidak terdeteksi (menjadi *False Negative*), sementara presisi yang tinggi menunjukkan bahwa ketika model memprediksi Anemia, prediksi tersebut umumnya tepat. Secara keseluruhan, nilai *F1-Score* yang mendekati 1,00 pada kedua kelas menunjukkan bahwa ResNet-50 tetap memiliki performa klasifikasi yang kuat dan konsisten, walaupun sedikit tertinggal dibandingkan dua model lainnya dalam hal sensitivitas terhadap kasus Anemia.

Tabel 4. *Clasification Report Model ResNet-50*

Kategori	Precision	Recall	F1-Score	Support
Anemia	1.00	0.95	0.97	500
Non-Anemia	0.95	1.00	0.97	500

Gambar 8 di bawah ini menyajikan *confusion matrix* dan kurva *ROC* untuk ResNet-50. Pada *confusion matrix* tampak bahwa sebagian besar sampel dari kedua kelas berhasil diklasifikasikan dengan benar, namun jumlah *False Negative* pada kelas Anemia terlihat sedikit lebih tinggi dibandingkan dua model lain, selaras dengan nilai *recall* yang lebih rendah pada Tabel 4. Meski demikian, kurva *ROC* pada Gambar 8 tetap menunjukkan nilai *AUC* yang tinggi dengan kurva yang jauh di atas garis diagonal acak, menandakan bahwa kemampuan ResNet-50 dalam membedakan kelas Anemia dan Non-Anemia masih sangat baik. Dengan demikian, meskipun secara relatif performanya sedikit di bawah DenseNet121 dan EfficientNetB0, ResNet-50 tetap layak dipertimbangkan sebagai alternatif arsitektur dalam sistem skrining anemia berbasis citra telapak tangan.



Gambar 8. Confusion Matrix dan ROC Curve ResNet-50

3.2 Perbandingan Model

Tabel 5 di bawah ini menyajikan perbandingan performa ketiga arsitektur *deep learning* pada data pengujian, yang menunjukkan bahwa DenseNet121 dan EfficientNetB0 berhasil mencapai akurasi tertinggi sebesar 0,99 dengan nilai loss yang sangat rendah, masing-masing sebesar 0,046 dan 0,035. Kedua model ini juga mencatat nilai presisi, recall, dan F1-Score yang mendekati sempurna sebesar 0,99, yang mencerminkan kemampuan klasifikasi yang sangat stabil dan seimbang pada kedua kelas Anemia dan Non-Anemia. Keunggulan performa kedua arsitektur ini merupakan hasil dari mekanisme *dense connection* pada DenseNet121 yang memungkinkan aliran informasi antarlayer secara langsung, serta pendekatan *compound scaling* pada EfficientNetB0 yang mengoptimalkan keseimbangan antara kedalaman, lebar, dan resolusi jaringan, sehingga keduanya mampu mengekstraksi fitur visual dari citra telapak tangan secara lebih efektif dan presisi.

Tabel 5. Perbandingan Model DenseNet121, EfficientNetB0, dan Resnet-50

Kategori	Accuracy	Loss	Precision	Recall	F1-Score
DenseNet121	0.99	0.046	0.99	0.99	0.99
EfficientNetB0	0.99	0.035	0.99	0.99	0.99
ResNet-50	0.97	0.089	0.97	0.97	0.97

ResNet-50 mencatat akurasi sebesar 0,97 dengan nilai loss 0,089, disertai nilai presisi, *recall*, dan F1-Score yang juga sebesar 0,97 pada data pengujian. Penurunan performa ResNet-50 dibandingkan dua model lainnya disebabkan oleh keterbatasan arsitektur residual *connection* dalam menangkap fitur visual berskala halus yang menjadi karakteristik utama citra telapak tangan penderita anemia, khususnya variasi warna pucat yang bersifat gradual dan memerlukan representasi fitur yang lebih mendalam. Terlepas dari perbedaan tersebut, ketiga model secara keseluruhan menunjukkan performa yang tinggi, dan Tabel 5 secara tegas mengonfirmasi keunggulan DenseNet121 dan EfficientNetB0 sebagai arsitektur terbaik untuk implementasi sistem skrining anemia non-invasif berbasis citra telapak tangan.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan dan membandingkan tiga model klasifikasi anemia berbasis citra telapak tangan menggunakan pendekatan *transfer learning* dengan arsitektur DenseNet121, EfficientNetB0, dan ResNet-50. Ketiga model dilatih menggunakan *dataset* publik anemia tangan yang terdiri dari 10.200 citra dengan dua kelas, yaitu Anemia dan Non-Anemia, yang dibagi secara proporsional menjadi subset pelatihan (80%), validasi (10%), dan pengujian (10%). Hasil evaluasi pada data pengujian menunjukkan bahwa DenseNet121 dan EfficientNetB0 mencapai akurasi tertinggi sebesar 0,99 dengan nilai *precision*, *recall*, dan *F1-score* yang mendekati sempurna, sedangkan ResNet-50 mencatat akurasi sebesar 0,97 dengan performa yang tetap berada pada kategori sangat baik. Keunggulan DenseNet121 didukung oleh mekanisme *dense connection* yang memungkinkan aliran fitur antarlayer secara langsung, sementara EfficientNetB0 unggul melalui pendekatan *compound scaling* yang mampu mengoptimalkan representasi fitur secara lebih efisien. Dengan demikian, DenseNet121 dan EfficientNetB0 terbukti sebagai arsitektur yang paling optimal untuk klasifikasi anemia berbasis citra telapak tangan dalam penelitian ini. Meskipun hasil yang diperoleh sangat menjanjikan, penelitian ini masih memiliki beberapa keterbatasan yang perlu diperhatikan untuk pengembangan selanjutnya. *Dataset* yang digunakan bersumber dari satu platform publik dengan kondisi pencahayaan dan sudut pengambilan gambar yang relatif terkontrol, sehingga performa model pada data dunia nyata dengan variasi kondisi lingkungan yang lebih beragam masih perlu divalidasi lebih lanjut. Selain itu, penelitian ini hanya membedakan dua kelas secara umum tanpa mempertimbangkan tingkat keparahan anemia secara klinis, seperti anemia ringan, sedang, dan berat. Oleh karena itu, penelitian selanjutnya disarankan untuk memperluas cakupan *dataset* dengan menambahkan variasi kondisi pengambilan

gambar, mengeksplorasi klasifikasi multikelas berdasarkan tingkat keparahan anemia, serta mempertimbangkan integrasi model ke dalam sistem berbasis *mobile application* agar dapat diimplementasikan sebagai alat skrining anemia non-invasif yang praktis dan mudah diakses oleh masyarakat luas.

REFERENCES

- [1] N. L. Fitri, S. A. Sari Hs, S. Nurhayati, A. T. Pakarti, S. Supardi, and U. Hasanah, "Hubungan Usia Gestasi Dengan Kejadian Anemia Pada Ibu Hamil," *J. Wacana Kesehatan.*, vol. 8, no. 1, p. 57, Jul. 2023, doi: 10.52822/jwk.v8i1.519.
- [2] T. Rahmawati, "Penyuluhan Kesehatan Anemia pada Remaja dalam Upaya Meningkatkan Pengetahuan dan Mencegah Kejadian Anemia," *J. Abdimas Kesehat. JAK*, vol. 5, no. 1, p. 186, Jan. 2023, doi: 10.36565/jak.v5i1.499.
- [3] D. Yolanda, J. Gambir, and E. Waliyo, "EFEKTIVITAS PENGGUNAAN APLIKASI EDUKASI ANEMIA (EDUANEMIA) TERHADAP KONSUMSI TABLET Fe DAN KADAR HEMOGLOBIN REMAJA PUTRI," vol. 2, 2025.
- [4] S. Lasmawanti and M. A. Siregar, "Faktor-Faktor yang Berhubungan dengan Kejadian Anemia Pada Remaja di SMA Budi Agung Medan," vol. 5, no. 1, 2024.
- [5] R. Djannah and W. Wisudawati, "PENGARUH PENDIDIKAN GIZI DAN ANEMIA TERHADAP PENGETAHUAN REMAJA TENTANG PENCEGAHAN ANEMIA," vol. 9, no. 1, 2023.
- [6] A. D. Lestari and L. Sundayani, "Pemeriksaan Hemoglobin (HB) pada Remaja untuk Pencegahan Anemia di Kelurahan Jatibaru Wilayah Kerja Puskesmas Jatibaru Tahun 2025," *J. Midwifery Update MU*, vol. 1, no. 2, pp. 79–86, Mar. 2020, doi: 10.32807/jmu.v1i2.64.
- [7] C. Wijaya, A. H. Santoso, E. Destra, L. A. Sukianto, and A. Ismi, "Pemeriksaan Hemoglobin dan Hematokrit dalam Rangka Deteksi dini Anemia pada Perempuan Usia Subur di Jakarta Utara," vol. 02, 2025.
- [8] V. Mintsopoulos, E. Tannenbaum, A. K. Malinowski, N. Shehata, and M. Walker, "Identification and treatment of iron-deficiency anemia in pregnancy and postpartum: A systematic review and quality appraisal of guidelines using AGREE II," *Int. J. Gynecol. Obstet.*, vol. 164, no. 2, pp. 460–475, Feb. 2024, doi: 10.1002/ijgo.14978.
- [9] I. Z. Yao, M. Dong, and W. Y. K. Hwang, "Deep Learning Applications in Clinical Cancer Detection: A Review of Implementation Challenges and Solutions," *Mayo Clin. Proc. Digit. Health*, vol. 3, no. 3, p. 100253, Sep. 2025, doi: 10.1016/j.mcpdig.2025.100253.
- [10] O. Olabanjo *et al.*, "Application of Machine Learning and Deep Learning Models in Prostate Cancer Diagnosis Using Medical Images: A Systematic Review," *Analytics*, vol. 2, no. 3, pp. 708–744, Sep. 2023, doi: 10.3390/analytics2030039.
- [11] Dede Fauzi, Hafizah Hanim, Gregorius Natanael Elwirehardja, Mahmud Isnain, and Muhammad Ihksan, *Fondasi Ilmu Komputer dari Algoritma hingga Kecerdasan Buatan*. in Media SciTech. Padang: Media SciTech, 2024.
- [12] D. Fauzi, M. Ihksan, A. Rahman, and A. Swandi, "Peningkatan Literasi Artificial Intelligence melalui Pelatihan Deep Learning pada Pengenalan Citra Bidang Kesehatan," 2026.
- [13] M. Ihksan, M. Isnain, D. Fauzi, and H. Prayuda, "Performance Comparison of ResNet50 and CNN-LSTM in Concrete Classification," in *2025 5th International Conference on Electronic and Electrical Engineering and Intelligent System (ICE3IS)*, Yogyakarta, Indonesia: IEEE, Aug. 2025, pp. 226–231. doi: 10.1109/ICE3IS66769.2025.11281310.
- [14] K. Kansal, T. B. Chandra, and A. Singh, "ResNet-50 vs. EfficientNet-B0: Multi-Centric Classification of Various Lung Abnormalities Using Deep Learning," *Procedia Comput. Sci.*, vol. 235, pp. 70–80, 2024, doi: 10.1016/j.procs.2024.04.007.
- [15] J. Potsangbam and S. Shuleenda Devi, "Classification of Breast Cancer Histopathological Images Using Transfer Learning with DenseNet121," *Procedia Comput. Sci.*, vol. 235, pp. 1990–1997, 2024, doi: 10.1016/j.procs.2024.04.188.
- [16] R. Nalawade, C. Bhosale, B. Mhaiskar, and U. Gurav, "Alzheimer's disease detection from brain MRI: Comparative Study of ResNet50, VGG19, DenseNet121 Multibranch CNN models," *Procedia Comput. Sci.*, vol. 259, pp. 1490–1500, 2025, doi: 10.1016/j.procs.2025.04.104.
- [17] M. Assaduzzaman, P. Bishshash, Md. A. S. Nirob, A. A. Marouf, J. G. Rokne, and R. Alhadjj, "XSE-TomatoNet: An explainable AI based tomato leaf disease classification method using EfficientNetB0 with squeeze-and-excitation blocks and multi-scale feature fusion," *MethodsX*, vol. 14, p. 103159, Jun. 2025, doi: 10.1016/j.mex.2025.103159.
- [18] A. H. Ali, A. Youssef, M. Abdelal, and M. A. Raja, "An ensemble of deep learning architectures for accurate plant disease classification," *Ecol. Inform.*, vol. 81, p. 102618, Jul. 2024, doi: 10.1016/j.ecoinf.2024.102618.
- [19] J. Mauricio, I. Domingues, and J. Bernardino, "Comparing Vision Transformers and Convolutional Neural Networks for Image Classification: A Literature Review," *Appl. Sci.*, vol. 13, no. 9, p. 5521, Apr. 2023, doi: 10.3390/app13095521.
- [20] Md. M. Islam, G. M. S. Himel, Md. G. Moazzam, and M. S. Uddin, "Artificial Intelligence-based Rice Variety Classification: A State-of-the-art Review and Future Directions," *Smart Agric. Technol.*, vol. 10, p. 100788, Mar. 2025, doi: 10.1016/j.atech.2025.100788.
- [21] A. M. Hazim and P. H. Gunawan, "Performance Analysis of Convolutional Neural Network Architecture in Pneumonia Detection From X-Ray Images," in *2025 4th International Conference on Electronics Representation and Algorithm (ICERA)*, Yogyakarta, Indonesia: IEEE, Jun. 2025, pp. 174–179. doi: 10.1109/ICERA66156.2025.11087383.
- [22] S. Vallukappully, I. Van Der Linde, and A. Chakraborty, "Early detection and classification of diabetic retinopathy by transfer learning of NASNet-large and ResNet-50 convolutional neural networks," *Inform. Med. Unlocked*, vol. 58, p. 101688, 2025, doi: 10.1016/j.imu.2025.101688.
- [23] S. S. Sousa-Neto *et al.*, "Comparative analysis of convolutional neural network models for the histopathological differentiation of acinic cell carcinoma and secretory carcinoma," *Oral Surg. Oral Med. Oral Pathol. Oral Radiol.*, vol. 141, no. 3, pp. 387–399, Mar. 2026, doi: 10.1016/j.oooo.2025.09.018.
- [24] R. İncir and F. Bozkurt, "Improving brain tumor classification with combined convolutional neural networks and transfer learning," *Knowl.-Based Syst.*, vol. 299, p. 111981, Sep. 2024, doi: 10.1016/j.knsys.2024.111981.
- [25] D. Añez, G. Conti, J. J. Uriarte, J.-J. Serrano-Olmedo, R. Martínez-Murillo, and O. Casanova-Carvajal, "Artificial Intelligence Pipeline for Mammography-Based Breast Cancer Detection: An Integrated Systematic Review and Large-Scale Experimental Validation," *Medicina (Mex.)*, vol. 61, no. 12, p. 2237, Dec. 2025, doi: 10.3390/medicina61122237.

- [26] M. Ihksan, D. Fauzi, M. Isnain, and I. Sari, "Arsitektur Sistem Automatic Number Plate Recognition Berbasis Web dengan Pipeline Deteksi YOLOv8 dan Pengenalan Karakter EasyOCR," *J. Rekayasa Teknol. Inf. JURTI*, vol. 9, no. 2, p. 206, Jul. 2025, doi: 10.30872/jurti.v9i2.21955.
- [27] P. P. Allorerung, A. Erna, M. Bagussahrir, and S. Alam, "Analisis Performa Normalisasi Data untuk Klasifikasi K-Nearest Neighbor pada Dataset Penyakit," *JISKA J. Inform. Sunan Kalijaga*, vol. 9, no. 3, pp. 178–191, Sep. 2024, doi: 10.14421/jiska.2024.9.3.178-191.
- [28] M. Abdillah *et al.*, "Implementasi XGBoost dalam Klasifikasi Gagal Ginjal Kronis Menggunakan Dataset Chronic Kidney Disease," *JATISI J. Tek. Inform. Dan Sist. Inf.*, vol. 12, no. 3, Sep. 2025, doi: 10.35957/jatisi.v12i3.11546.
- [29] H. Tantyoko, D. K. Sari, and A. R. Wijaya, "PREDIKSI POTENSIAL GEMPA BUMI INDONESIA MENGGUNAKAN METODE RANDOM FOREST DAN FEATURE SELECTION," *IDEALIS Indones. J. Inf. Syst.*, vol. 6, no. 2, pp. 83–89, Jul. 2023, doi: 10.36080/idealisis.v6i2.3036.
- [30] M. A. Al-Fahrezi, "Pengaruh Augmentasi Data Terhadap Akurasi Pelatihan Model CNN untuk Klasifikasi Jenis Ikan," *JITSI J. Ilm. Teknol. Sist. Inf.*, vol. 6, no. 2, pp. 177–185, Jun. 2025, doi: 10.62527/jitsi.6.2.471.
- [31] M. Malik Ibrahim, R. Rahmadewi, and L. Nurpulaela, "PENDETEKSIAN NOMINAL UANG PADA GAMBAR MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK: INTEGRASI METODE PRA-PEMROSESAN CITRA DAN KLASIFIKASI BERBASIS CNN," *JATI J. Mhs. Tek. Inform.*, vol. 7, no. 2, pp. 1394–1400, Sep. 2023, doi: 10.36040/jati.v7i2.6863.
- [32] J. Christian and S. I. A. Idrus, "Introduction to Citrus Fruit Ripens Using the Deep Learning Convolutional Neural Network (CNN) Learning Method," *Asian J. Appl. Educ. AJAE*, vol. 2, no. 3, pp. 459–470, Jul. 2023, doi: 10.55927/ajae.v2i3.5003.
- [33] G. Gunawan, S. A. Wibowo, and W. Andriani, "Evaluasi Model Deep Learning pada Pola Dataset Biomedis," *J. SAINTEKOM*, vol. 14, no. 2, pp. 195–207, Sep. 2024, doi: 10.33020/saintekom.v14i2.738.
- [34] S. M. P. Tyas, R. Sarno, and B. S. Rintyarna, "Analisis Perbandingan Metode Klasifikasi Sentimen Berita Saham: Pendekatan Machine Learning, Deep Learning, Transfer Learning, dan Graf," *J. Penelit. IPTEKS*, vol. 9, no. 1, pp. 58–64, Jan. 2024, doi: 10.32528/penelitianipteks.v9i1.1479.
- [35] M. Rijal, A. M. Yani, and A. Rahman, "Deteksi Citra Daun untuk Klasifikasi Penyakit Padi menggunakan Pendekatan Deep Learning dengan Model CNN," *J. Teknol. Terpadu*, vol. 10, no. 1, pp. 56–62, Jul. 2024, doi: 10.54914/jtt.v10i1.1224.