

Perbandingan MobileNetV2, DenseNet121, InceptionV3, dan Xception pada Klasifikasi Citra Panel Surya Bersih dan Berdebu

Aswin Mulyo Nugroho, Hindayati Mustafidah*, Maulida Ayu Fitriani, Supriyono

Fakultas Teknik dan Sains, Prodi Teknik Informatika, Universitas Muhammadiyah Purwokerto, Purwokerto, Indonesia

Email: ¹aswinfabanyo46@gmail.com, ^{2*}h.mustafidah@ump.ac.id, ³maulidaayuf@gmail.com, ⁴neopriyo@gmail.com

Email Penulis Korespondensi: h.mustafidah@ump.ac.id

Submitted 30-05-2025; Accepted 17-07-2025; Published 14-08-2025

Abstrak

Penumpukan debu pada panel surya dapat secara signifikan mengurangi produksi energi, menurunkan efisiensi sistem, serta meningkatkan biaya operasional. Salah satu pendekatan yang efektif untuk mengatasi permasalahan ini adalah penerapan klasifikasi citra menggunakan metode *Convolutional Neural Network* (CNN). Studi ini mengkaji kemampuan klasifikasi empat model CNN, yaitu MobileNetV2, DenseNet121, InceptionV3, dan Xception, dengan menggunakan pendekatan *transfer learning*. Model-model ini memanfaatkan *pre-trained weights* dari dataset berskala besar seperti ImageNet untuk mempercepat konvergensi dan meningkatkan kemampuan generalisasi. Dataset citra yang digunakan diperoleh dari Kaggle, terdiri atas gambar panel surya dalam kondisi bersih dan berdebu. Dataset dibagi ke dalam subset pelatihan, validasi, dan pengujian menggunakan pendekatan stratifikasi guna memastikan distribusi kelas yang seimbang di setiap subset. Selama pelatihan, digunakan *class weighting* untuk mengatasi potensi ketidakseimbangan kelas. Model dikembangkan dengan TensorFlow dan dukungan *multi-GPU*, dioptimalkan menggunakan *AdamW optimizer*, dan disempurnakan melalui *fine-tuning* untuk meningkatkan performa. Evaluasi performa model dilakukan menggunakan beberapa metrik, seperti *accuracy*, *precision*, *recall*, dan *F1-score*. Dari seluruh arsitektur yang diuji, model Xception mencatat performa paling unggul dengan akurasi sebesar 90,52%, mengungguli MobileNetV2 dengan akurasi 87,92%, DenseNet121 dengan akurasi 89,78%, dan InceptionV3 yang mendapatkan akurasi sebesar 87,73%. Hasil ini menunjukkan bahwa model berbasis CNN modern mampu mengenali pola visual yang relevan secara efektif untuk mendeteksi debu pada panel surya.

Kata Kunci: Panel Surya, CNN, Klasifikasi Gambar, Pre-Trained Models, Transfer Learning

Abstract

The buildup of dust on solar panels can greatly diminish energy output, lower system efficiency, and raise operational expenses. A productive way to tackle this problem is to utilize image classification through Convolutional Neural Network (CNN) techniques. This study examines the classification capabilities of four CNN models, namely MobileNetV2, DenseNet121, InceptionV3, and Xception, using transfer learning. These models leverage pre-trained weights from large datasets such as ImageNet to accelerate convergence and improve generalization. The dataset of images utilized in this research is obtained from Kaggle and includes pictures of both clean and dusty solar panels. The dataset was divided into training, validation, and testing subsets using a stratified approach to ensure balanced class distribution across all subsets. During training, class weighting was used to address potential class imbalance. The models were developed using TensorFlow with multi-GPU support, optimized using the AdamW optimizer, and fine-tuned to enhance performance. Model evaluation was conducted using accuracy, precision, recall, and F1-score metrics. Among all the architectures evaluated, the Xception model achieved the best performance with an accuracy of 90.52%, outperforming MobileNetV2 with an accuracy of 87.92%, DenseNet121 with 89.78%, and InceptionV3 which achieved 87.73%. These results indicate that modern CNN-based models can effectively recognize relevant visual patterns to detect dust on solar panels.

Keywords: Solar Panel, CNN, Image Classification, Pre-Trained Models, Transfer Learning

1. PENDAHULUAN

Pemakaian bahan bakar fosil sebagai sumber energi utama berdampak pada munculnya berbagai permasalahan serius, terutama di bidang lingkungan. Dalam upaya global mengurangi ketergantungan pada bahan bakar fosil, energi surya atau matahari kini menjadi salah satu fokus utama pengembangan energi terbarukan [1]. Pemanfaatan energi matahari kini semakin meningkat, terutama melalui instalasi panel surya sebagai teknologi utama dalam konversi energi cahaya menjadi listrik. Namun, kinerja panel surya dapat menurun karena penumpukan debu yang menempel pada permukaan modul [2]. Permasalahan ini menjadi semakin relevan di lingkungan perkotaan yang rawan terhadap polusi udara dan debu. Ketika partikel debu menutupi permukaan panel, penyerapan sinar matahari oleh sel surya menjadi terhambat. Akibatnya, efisiensi produksi listrik menurun secara signifikan, sehingga potensi energi terbarukan yang dihasilkan juga berkurang. Debu yang menumpuk pada panel surya berkontribusi pada penurunan energi yang dihasilkan sekaligus meningkatkan kebutuhan dan biaya perawatan panel surya [3].

Klasifikasi citra panel surya menggunakan *Convolutional Neural Network* (CNN) merupakan solusi potensial untuk mendeteksi debu pada panel surya. CNN, yang dirancang untuk pemrosesan data visual, efektif mengenali objek dalam citra [4]. Selain citra, CNN juga diterapkan pada data suara dan teks [5]. Keunggulannya terletak pada kemampuannya menangkap hubungan spasial antar piksel dalam data seperti citra (gambar) [6]. *Transfer learning* dengan model CNN pra-latih terbukti efektif untuk berbagai tugas klasifikasi citra dengan memanfaatkan fitur yang telah dipelajari sebelumnya [7]. Berbagai arsitektur CNN yang umum digunakan telah menunjukkan kinerja baik dalam tugas pengenalan citra. MobileNetV2 memanfaatkan teknik *depthwise separable convolution* guna menekan jumlah parameter serta mempercepat proses prediksi [8]. DenseNet121 memanfaatkan *dense connection* untuk memperlancar aliran gradien dan mengurangi *overfitting* [9]. InceptionV3 menangkap fitur multi-skala melalui kombinasi berbagai ukuran filter [10].

Xception sebagai pengembangan Inception menggabungkan efisiensi dan akurasi dengan *depthwise separable convolution* [11].

Beberapa studi sebelumnya telah membahas klasifikasi debu pada panel surya. Cipriani et al. memanfaatkan citra termografi untuk mendeteksi anomali pada modul fotovoltaik menggunakan CNN khusus yang menganalisis pola suhu tidak normal, seperti debu dan *hotspot*. Dengan konfigurasi ringan dan dua optimizer (Adam dan SGD), model mencapai akurasi 98% dan eksekusi cepat tanpa overfitting [12]. Shao et al. meningkatkan proses optimisasi pelatihan model deteksi debu dengan memodifikasi algoritma Adam menggunakan teknik *Warmup* dan *Cosine Annealing*. Metode ini diuji pada ResNet-18, VGG-16, dan MobileNetV2, menghasilkan peningkatan akurasi dan penurunan loss, dengan MobileNetV2 mencapai akurasi tertinggi sebesar 99,43% [13]. Alatwi et al. menerapkan pendekatan hybrid dengan menggunakan 20 CNN pra latih untuk ekstraksi fitur citra panel surya, kemudian mengklasifikasikannya dengan *Support Vector Machine* (SVM). Kombinasi terbaik yang didapatkan adalah DenseNet169 dan SVM linier, dengan akurasi yang dihasilkan sebesar 86,79%. Pendekatan ini menekankan efisiensi komputasi dengan memanfaatkan kekuatan ekstraksi fitur dari CNN pra latih namun menggantikan proses klasifikasi *end-to-end* dengan metode *machine learning* ringan seperti SVM, yang cocok untuk kondisi keterbatasan data atau sumber daya komputasi [14]. Fatih Uysal memanfaatkan empat model CNN yaitu MobileNetV1 serta tiga varian ResNet (ResNet18, ResNet50, ResNet152) untuk mendeteksi debu pada panel surya. Dengan dataset yang terbatas dan tidak seimbang, augmentasi digunakan untuk penyeimbangan, dan data dibagi 80% untuk pelatihan dan 20% untuk pengujian. ResNet18 dengan optimizer AdamW memberikan hasil terbaik dengan akurasi 99,3%. Namun, studi ini terbatas pada MobileNetV1 dan satu keluarga arsitektur ResNet [15].


Onim et al. mengembangkan arsitektur CNN khusus bernama SolNet untuk mendeteksi akumulasi debu, menggunakan kumpulan data citra dari berbagai wilayah di Bangladesh dengan citra berukuran 227 x 227 piksel. SolNet memiliki arsitektur ringan dengan 56 juta parameter dan mencapai akurasi 98,2% melalui validasi silang lima lipatan. Penelitian ini menunjukkan bahwa SolNet mengungguli model-model SOTA seperti VGG16, InceptionV3, ResNet50, dan AlexNet dalam hal akurasi dan efisiensi, serta menyarankan pengembangan lebih lanjut seperti klasifikasi multikelas dan penyesuaian *hyperparameter* [16]. Mamdouh dan Zaghoul menggabungkan pemrosesan citra dan algoritma pembelajaran mesin klasik. Menggunakan dua dataset, studi ini memodelkan hubungan antara variabel lingkungan (suhu, iradiasi matahari, dan debu) dan output daya menggunakan model LSTM, ANN, dan SVR. LSTM dan ANN menunjukkan akurasi tinggi, masing-masing 99,50% dan 98,50% [17]. Mohammed dan Alawi mengusulkan CASolarNet, arsitektur CNN berbasis EfficientNet dengan *Channel Attention Mechanism* dan *focal loss* untuk mendeteksi debu. Pendekatan ini meningkatkan fokus model pada area penting dalam gambar dan menangani ketidakseimbangan kelas, mencapai akurasi deteksi di atas 98% pada kondisi lingkungan yang beragam [18]. Shah et al. menerapkan model InceptionV3 untuk klasifikasi panel surya bersih dan berdebu menggunakan dataset Kaggle berisi 1.200 gambar (100x100 piksel). Studi ini mencapai akurasi 92,34%, menunjukkan potensi penggunaan pembelajaran mendalam berbasis CNN, khususnya arsitektur InceptionV3, dalam mendeteksi akumulasi debu pada permukaan panel surya [19].

Temuan pada penelitian-penelitian terdahulu membentuk dasar untuk mengembangkan pendekatan baru dalam penelitian ini, dengan fokus utama pada peningkatan efisiensi dan akurasi dalam mengklasifikasi gambar panel surya yang tertutup debu. Pendekatan dalam penelitian ini menunjukkan perbedaan signifikan dibandingkan dengan studi-studi sebelumnya, khususnya dari sisi input data, arsitektur model, dan strategi pelatihan. Berbeda dari studi-studi sebelumnya yang sebagian besar terbatas pada penggunaan satu atau dua arsitektur CNN tertentu, atau menggabungkan CNN pra latih hanya sebagai ekstraktor fitur untuk model klasik seperti SVM, penelitian ini secara eksplisit membandingkan empat model deep learning populer (MobileNetV2, DenseNet121, InceptionV3, dan Xception) dengan pendekatan transfer learning dan fine-tuning end-to-end. Berbeda dengan pendekatan yang memodifikasi algoritma optimisasi seperti Adam dengan *warmup* dan *cosine annealing*, penelitian ini mempertahankan konfigurasi pelatihan standar tanpa penyesuaian lanjutan terhadap hyperparameter optimisasi.

Keempat arsitektur CNN dianalisis performanya dalam klasifikasi panel surya dengan kondisi bersih dan berdebu. Penelitian ini dirancang menggunakan konfigurasi pelatihan yang konsisten serta mempertimbangkan keseimbangan kelas, strategi *fine-tuning*, dan penggunaan class weight untuk meningkatkan generalisasi model. Dengan menerapkan pembagian data, metode pra proses, dan parameter pelatihan yang konsisten pada semua model, penelitian ini bertujuan memberikan perbandingan yang adil dan objektif, serta mengidentifikasi arsitektur yang paling optimal dalam mencapai akurasi tinggi dengan mempertimbangkan efisiensi penggunaan sumber daya komputasi. Hasil dari penelitian ini dapat menjadi dasar dalam memilih arsitektur CNN yang paling efisien dan akurat untuk diterapkan pada sistem pemantauan otomatis panel surya berbasis citra, seperti inspeksi berbasis drone atau kamera tetap (*fixed camera*) dalam skala industri. Penelitian ini juga menyediakan pipeline implementasi yang dapat direplikasi dan diadaptasi untuk aplikasi klasifikasi citra lainnya yang memerlukan efisiensi tinggi dengan sumber daya terbatas.

2. METODOLOGI PENELITIAN

Proses penelitian ini dirancang secara sistematis untuk mengembangkan dan mengevaluasi model klasifikasi citra panel surya berdasarkan kondisi bersih dan berdebu. Gambar 1 menampilkan tahapan penelitian secara keseluruhan.



Gambar 1. Metode Penelitian

Proses penelitian seperti yang terlihat pada Gambar 1, diawali dengan pengumpulan data, dilanjutkan dengan tahap praproses data, pemilihan model, proses pelatihan, serta evaluasi performa model.

2.1 Pengumpulan Data

Penelitian ini memanfaatkan kumpulan citra panel surya dalam dua keadaan berbeda, yaitu bersih (*clean*) dan berdebu (*dusty*), yang dikategorikan ke dalam dua kelas. Data diperoleh dari *Kaggle*, yang menyediakan berbagai data berkualitas untuk mendukung penelitian dan pengembangan *machine learning*.

2.2 Praproses Data

Setelah dikumpulkan, data terlebih dahulu melalui tahap pra-pemrosesan. *Convolutional Neural Network* (CNN) umumnya membutuhkan citra dengan ukuran yang seragam sebagai input. Oleh karena itu, untuk menyesuaikan dengan arsitektur model *pre-trained*, seluruh citra dalam *dataset* diubah ukurannya menjadi 224x224 piksel agar sesuai dengan input model dan mengurangi beban komputasi.

2.3 Pemilihan Model *Transfer Learning*

Penelitian ini menggunakan beberapa model untuk klasifikasi citra, yaitu MobileNetV2, DenseNet121, InceptionV3, dan Xception.

a. MobileNetV2

MobileNetV2 meningkatkan efisiensi komputasi melalui *inverted residual block* dan *depthwise separable convolution*, sehingga cocok untuk perangkat dengan sumber daya terbatas [20]. *Inverted residual blocks* melakukan kompresi dan ekspansi informasi guna mengurangi jumlah parameter tanpa kehilangan performa signifikan. *Depthwise separable convolution* memisahkan operasi menjadi *depthwise* (menangani tiap kanal secara independen) dan *pointwise* (menggabungkan informasi antar kanal), sehingga meningkatkan efisiensi [21].

b. DenseNet121

DenseNet121 menggunakan konektivitas padat (*dense connectivity*) untuk mengurangi jumlah parameter dan mempercepat aliran gradien [9]. Dengan menerapkan *dense connectivity*, setiap lapisan mendapatkan informasi dari seluruh lapisan sebelumnya, yang membantu meningkatkan kemampuan dalam mengenali pola debu secara lebih rinci dan efisien. Parameter yang mengatur penambahan informasi baru ini memungkinkan model untuk mendeteksi perubahan halus pada warna dan tekstur [22].

c. InceptionV3

InceptionV3 memproses informasi multi-skala secara efektif melalui *convolution factorization* dan *auxiliary classifier* [23]. InceptionV3 mengelola fitur multi-skala melalui *inception blocks* yang menerapkan konvolusi 1x1, 3x3, dan 5x5 secara bersamaan. *Factorized convolution* mengurangi jumlah parameter sehingga meningkatkan efisiensi tanpa mengorbankan akurasi. Selain itu, *auxiliary classifiers* membantu menstabilkan pelatihan dan mempercepat konvergensi [10].

d. Xception

Xception menyempurnakan arsitektur Inception untuk pemrosesan yang lebih efisien tanpa mengurangi akurasi [11]. Xception mengembangkan arsitektur Inception dengan menggantikan modul-modulnya secara penuh menggunakan *depthwise separable convolution* dan menambahkan *residual connections* untuk meningkatkan efisiensi dan akurasi. Berbeda dengan InceptionV3 yang menggabungkan filter berukuran berbeda, Xception memisahkan pemrosesan spasial dan antar-kanal, sehingga mampu mendeteksi detail halus dan tekstur kompleks secara lebih efisien [24].

2.4 Pelatihan Model

Setiap model dilatih menggunakan *dataset* yang telah melalui tahap praproses. Model dasar (base model) yang dimanfaatkan berasal dari hasil pelatihan sebelumnya menggunakan *dataset* berskala besar, seperti ImageNet. Melalui pendekatan *transfer learning*, model ini dapat langsung mengenali fitur-fitur dasar tanpa harus mempelajarinya dari awal, seperti pola tekstur dasar. Setelah menerapkan model pra latih, dilakukan tahap *fine-tuning*, yaitu penyesuaian lebih lanjut terhadap parameter model agar sesuai dengan karakteristik *dataset* panel surya. Proses ini meningkatkan performa model dalam tugas klasifikasi spesifik dengan jumlah kelas yang terbatas [25].

2.5 Evaluasi Model

Model dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* untuk menilai sejauh mana model bekerja secara efektif. Metrik tersebut diperoleh dari hasil prediksi model pada data uji dengan menggunakan rumus (1),

(2), (3), dan (4), yang melibatkan empat komponen utama, yaitu *True Positives* (TP), *True Negatives* (TN), *False Positives* (FP), dan *False Negatives* (FN) [26].

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

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

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

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

Accuracy mengukur persentase prediksi yang benar dari total data uji [27]. *Precision* menunjukkan ketepatan model dalam mengklasifikasikan data ke kelas positif, yaitu perbandingan antara jumlah *True Positives* dengan total prediksi positif. Sedangkan *recall* mengukur kemampuan model dalam mengidentifikasi seluruh data yang termasuk kelas positif, yaitu perbandingan antara *True Positives* dengan total kasus positif sebenarnya. Untuk menggabungkan keunggulan *precision* dan *recall*, digunakan metrik *F1-score* yang merupakan rata-rata harmonis keduanya [28].

3. HASIL DAN PEMBAHASAN

3.1 Pengolahan Data

Dataset yang digunakan terdiri dari dua kategori utama, yakni citra panel surya dalam kondisi bersih dan berdebu. Contoh citra untuk masing-masing kelas ditampilkan pada Gambar 2.




Gambar 2. Contoh Gambar Panel Surya Bersih Dan Panel Surya Berdebu

Dataset terdiri dari 3.582 citra, dengan 1.799 citra panel surya bersih dan 1.783 citra panel surya berdebu. *Dataset* kemudian dibagi menjadi tiga subset menggunakan metode *stratified split*, menjadi data latih (60%), validasi (25%), dan uji (15%). Jumlah citra menjadi 2149 untuk data latih, 895 untuk data validasi, dan 538 untuk data uji. Semua subset dimuat menggunakan *ImageDataGenerator* dengan skala piksel pada rentang [0, 1] untuk normalisasi input ke model. Ukuran semua citra diubah menjadi 224×224 piksel agar sesuai dengan arsitektur model *deep learning*.

3.2 Pelatihan Model

Pelatihan model dilakukan dengan menggunakan TensorFlow *MirroredStrategy* sebagai pendekatan *multi-GPU* guna mempercepat proses komputasi. Untuk mendukung proses klasifikasi citra, model *transfer learning* diperluas dengan beberapa lapisan tambahan. Rangkaian arsitektur yang digunakan dapat dilihat pada Gambar 3.




Gambar 3. Arsitektur Model

Arsitektur yang digunakan dalam penelitian ini merupakan kombinasi model pre-trained dan lapisan tambahan, seperti ditunjukkan pada Gambar 3. Sebanyak 50 lapisan terakhir dari setiap model pre-trained diaktifkan, sementara sisanya dibekukan untuk mempertahankan fitur yang telah dipelajari. Model diperluas dengan Global Average Pooling,

dua lapisan Dense (128 dan 64 unit) dengan aktivasi ReLU, Dropout (0,4 dan 0,2), serta output layer dengan aktivasi sigmoid untuk klasifikasi biner. Optimizer AdamW dengan learning rate $1e-3$ digunakan bersama loss function binary crossentropy. Pelatihan berlangsung selama 30 epoch atau hingga early stopping aktif, dengan class weights untuk menangani ketidakseimbangan data. Model menggunakan bobot awal dari ImageNet untuk mengekstraksi fitur dasar seperti tepi, tekstur, dan pola visual, yang membantu membedakan antara dua kelas citra..

3.2.1 Pelatihan MobileNetV2

Kinerja model MobileNetV2 selama proses pelatihan divisualisasikan dalam bentuk grafik untuk mengevaluasi akurasi dan nilai kerugian (*loss*) pada data latih dan validasi. Grafik akurasi dan *loss* tersebut ditampilkan pada Gambar 4. Hasil pelatihan MobileNetV2 menunjukkan pola peningkatan akurasi yang signifikan, terutama pada lima epoch pertama, serta peningkatan bertahap dan stabil pada fase selanjutnya setelah penyesuaian *learning rate*.



Gambar 4. Grafik Accuracy dan Loss MobileNetV2

Hasil pelatihan model MobileNetV2 seperti yang terlihat pada Gambar 4, menunjukkan peningkatan signifikan, terutama dalam lima epoch awal saat akurasi pelatihan naik dari 62,84% ke 95,47%. Akurasi validasi sempat fluktuatif namun mencapai 78,88% pada epoch ke-5. Pada epoch ke-11, mekanisme *ReduceLROnPlateau* secara otomatis menurunkan *learning rate* dari 0.001 menjadi 0.0001, yang kemudian berdampak positif terhadap stabilitas dan peningkatan performa validasi. Setelah penyesuaian tersebut, akurasi validasi terus meningkat secara konsisten dan mencapai 88,04% pada epoch ke-30, dengan *validation loss* yang juga menunjukkan tren penurunan dan stabil di bawah nilai 1,0. Sementara akurasi pelatihan mencapai 99%, perbedaan yang masih terlihat antara *training loss* dan *validation loss* masih terlihat, namun tidak mengganggu generalisasi model. Secara keseluruhan, proses pelatihan menunjukkan hasil yang sangat baik, dengan performa validasi yang stabil dan peningkatan bertahap setelah penyesuaian laju pembelajaran. Selanjutnya dilakukan analisis untuk hasil pengujian model MobileNetV2 berdasarkan *confusion matrix* yang disajikan dalam Tabel 1.


Tabel 1. Hasil Evaluasi Model Mobilenetv2 pada Confusion Matrix

True Label	Predicted: Clean	Predicted: Dusty
Clean (bersih)	236	30
Dusty (berdebu)	35	237

Berdasarkan hasil evaluasi yang diperoleh model MobileNetV2 dengan menggunakan *confusion matrix* seperti yang terlihat pada Tabel 1, model ini mampu mengklasifikasikan dengan benar sebanyak 236 sampel citra panel surya bersih (*True Negatives*) dan 237 sampel citra panel surya berdebu (*True Positives*). Namun, masih terdapat sejumlah kesalahan prediksi, yaitu 30 citra panel bersih yang salah diklasifikasikan sebagai berdebu (*False Positives*) dan 35 citra panel berdebu yang keliru diprediksi sebagai bersih (*False Negatives*). Secara keseluruhan, model MobileNetV2 menunjukkan kinerja klasifikasi yang cukup baik dan seimbang antara kedua kategori. Meskipun jumlah kesalahan tergolong kecil, peningkatan pada aspek generalisasi model dapat dilakukan untuk lebih meminimalisasi kesalahan klasifikasi, terutama dalam konteks penerapan di dunia nyata yang membutuhkan tingkat presisi tinggi.

3.2.2 Pelatihan DenseNet121

Untuk mengetahui efektivitas proses pelatihan pada arsitektur DenseNet121, dilakukan visualisasi akurasi dan loss terhadap data pelatihan dan validasi. Gambar 5 menyajikan perkembangan akurasi dan loss selama 30 epoch pelatihan untuk model DenseNet121. Evaluasi DenseNet121 menunjukkan performa pelatihan yang baik dengan peningkatan akurasi yang pesat pada awal pelatihan, dan akurasi validasi yang relatif stabil.



Gambar 5. Grafik *Accuracy* dan *Loss* DenseNet121

Hasil pelatihan model DenseNet121 seperti yang terlihat pada Gambar 5, akurasi pelatihan meningkat pesat dari 70% ke 97% dalam lima epoch pertama, menunjukkan kemampuan awal model mengenali pola data. Akurasi validasi juga naik meski berfluktuasi di kisaran 84–88%. Seiring bertambahnya epoch, akurasi pelatihan terus naik hingga 99% dengan penurunan loss pelatihan yang sangat signifikan, sementara akurasi validasi tampak stabil namun sedikit naik-turun, menunjukkan adanya perbedaan dalam performa terhadap data pelatihan dan data validasi. Pola ini mengindikasikan bahwa model mulai belajar secara sangat mendalam terhadap data pelatihan, yang dapat memunculkan gejala *overfitting* ringan. Namun, hal ini berhasil diatasi melalui mekanisme *ReduceLROnPlateau* yang menurunkan *learning rate* setelah epoch ke-17, sehingga proses pelatihan menjadi lebih stabil dan performa terhadap data validasi pun terjaga. Pada akhir pelatihan, model memperoleh tingkat akurasi validasi sebesar 90,28%, yang mengindikasikan meskipun ada perbedaan performa antara data latih dan validasi, model tetap dapat menggeneralisasi dengan baik pada data baru. Hasil pengujian model DenseNet121 pada *confusion matrix* ditunjukkan pada Tabel 2.


Tabel 2. Hasil Evaluasi Model Densenet121 pada *Confusion Matrix*

<i>True Label</i>	<i>Predicted: Clean</i>	<i>Predicted: Dusty</i>
<i>Clean</i> (bersih)	241	25
<i>Dusty</i> (berdebu)	30	242

Berdasarkan hasil evaluasi yang diperoleh model DenseNet121 dengan menggunakan *confusion matrix* seperti yang terlihat pada Tabel 2, model ini berhasil mengklasifikasikan dengan benar 241 sampel citra panel surya bersih (*True Negatives*) dan 242 sampel citra panel berdebu (*True Positives*). Namun, masih terdapat beberapa kesalahan prediksi, yaitu sebanyak 25 citra panel bersih salah dikenali sebagai berdebu (*False Positives*), dan 30 citra panel berdebu diprediksi sebagai bersih (*False Negatives*). Secara umum, hasil ini mencerminkan bahwa DenseNet121 memiliki performa klasifikasi yang sangat baik dan seimbang, dengan jumlah kesalahan yang relatif kecil pada kedua kelas. Tingkat presisi dan sensitivitas yang tinggi membuat model ini cukup andal untuk diterapkan dalam skenario nyata. Meskipun demikian, optimalisasi lebih lanjut tetap diperlukan guna mengurangi kesalahan klasifikasi, terutama pada panel berdebu yang terdeteksi sebagai bersih, agar mendukung keakuratan sistem dalam jangka panjang.

3.2.3 Pelatihan InceptionV3

Untuk memahami performa pelatihan model InceptionV3, grafik akurasi dan loss selama proses pelatihan disajikan seperti yang terlihat pada Gambar 6. InceptionV3 menunjukkan peningkatan akurasi pelatihan yang pesat pada awal pelatihan, namun dengan akurasi validasi yang cenderung stagnan.



Gambar 6. Grafik *Accuracy* dan *Loss* InceptionV3

Hasil pelatihan model InceptionV3 seperti yang terlihat pada Gambar 6, menunjukkan peningkatan akurasi yang sangat cepat pada lima epoch pertama, dari 66% hingga mencapai sekitar 98%, menandakan proses pembelajaran awal yang efektif. Akurasi validasi juga mengalami peningkatan secara umum, meskipun sempat fluktuatif, khususnya pada epoch ke-3, namun kemudian stabil di kisaran 88–90%. Setelah epoch kelima, akurasi pelatihan terus meningkat hingga 99%, sementara akurasi validasi cenderung stagnan. Perbedaan antara kinerja pada data latih dan validasi ini mengindikasikan bahwa model mulai mengalami kecenderungan untuk terlalu menyesuaikan diri terhadap data latih. Mekanisme *ReduceLROnPlateau* secara adaptif menurunkan nilai *learning rate* pada epoch ke-10 dan ke-23, sebagai upaya mengoptimalkan proses pelatihan ketika tidak terjadi peningkatan signifikan pada performa validasi. Meski penyesuaian tersebut membantu menstabilkan pelatihan, peningkatan akurasi validasi tetap terbatas. Secara keseluruhan, model menunjukkan kemampuan pelatihan yang sangat tinggi, namun dengan ruang perbaikan dalam hal generalisasi terhadap data yang tidak terlihat selama pelatihan. Hasil pengujian model InceptionV3 pada *confusion matrix* ditunjukkan pada Tabel 3.


Tabel 3. Hasil Evaluasi Model Inceptionv3 pada *Confusion Matrix*

<i>True Label</i>	<i>Predicted: Clean</i>	<i>Predicted: Dusty</i>
<i>Clean</i> (bersih)	239	27
<i>Dusty</i> (berdebu)	39	233

Hasil evaluasi model InceptionV3, berdasarkan *confusion matrix* seperti yang ditampilkan pada Tabel 3 menunjukkan bahwa model ini mampu mengenali dengan benar 233 sampel citra panel surya berdebu (*True Positives*) dan 239 sampel citra panel bersih (*True Negatives*). Namun demikian, masih ditemukan kesalahan klasifikasi berupa 27 citra panel bersih yang salah diklasifikasikan sebagai berdebu (*False Positives*) dan 39 citra panel berdebu yang keliru dikenali sebagai bersih (*False Negatives*). Secara keseluruhan, kinerja model ini tergolong baik dan cukup seimbang, akan tetapi peningkatan performa perlu dilakukan dan difokuskan pada pengurangan *false negatives* agar model lebih sensitif terhadap panel surya yang berdebu. Hal ini penting dalam konteks implementasi nyata, mengingat kesalahan dalam mengenali panel berdebu dapat berdampak pada efisiensi pemeliharaan sistem tenaga surya.

3.2.4 Hasil Pelatihan Xception

Hasil pelatihan model Xception ditampilkan pada Gambar 7. Xception menunjukkan akurasi tinggi dan kestabilan yang baik, meskipun selisih *loss* antara data latih dan validasi mengindikasikan tantangan dalam generalisasi.



Gambar 7. Grafik *Accuracy* dan *Loss* Xception

Hasil pelatihan model Xception seperti yang terlihat pada Gambar 7, model ini menunjukkan proses pelatihan yang sangat baik dengan peningkatan akurasi pelatihan yang konsisten hingga mencapai hampir 100%. Pada lima epoch awal, akurasi meningkat tajam dari sekitar 74% menjadi lebih dari 95%, dan terus meningkat hingga mendekati sempurna setelah epoch ke-10. Akurasi validasi juga menunjukkan tren positif, stabil di kisaran 89–91% meskipun disertai fluktuasi kecil. Namun, nilai *validation loss* cenderung tinggi dan kurang stabil dibandingkan *training loss*, yang menunjukkan bahwa model sangat memahami pola pada data latih, namun belum sepenuhnya mampu melakukan generalisasi secara optimal terhadap data validasi. Hal ini ditandai dengan selisih cukup besar antara *training loss* dan *validation loss*. Penurunan *learning rate* secara otomatis oleh mekanisme *ReduceLROnPlateau* terjadi pada epoch ke-15 dan ke-20 sebagai upaya untuk menyesuaikan kecepatan pembelajaran saat model mulai stagnan dalam meningkatkan performa pada data validasi. Pelatihan berhenti lebih awal pada epoch ke-20 karena diterapkannya *early stopping*, yang menghentikan proses pelatihan secara otomatis saat tidak ada peningkatan signifikan pada metrik validasi dalam sejumlah epoch berturut-turut, sehingga menghindari *overfitting* dan penggunaan sumber daya yang tidak efisien. Hasil pengujian model Xception pada *confusion matrix* ditunjukkan pada Tabel 4.

Tabel 4. Hasil Evaluasi Model Xception pada *Confusion Matrix*

<i>True Label</i>	<i>Predicted: Clean</i>	<i>Predicted: Dusty</i>
<i>Clean</i> (bersih)	241	25
<i>Dusty</i> (berdebu)	26	246

Evaluasi berbasis *confusion matrix* pada model Xception seperti yang ditampilkan pada Tabel 4 menunjukkan performa klasifikasi yang sangat baik dalam membedakan citra panel surya bersih dan berdebu. Model ini berhasil mengidentifikasi dengan benar 241 sampel citra panel bersih (*True Negatives*) serta 246 sampel citra panel berdebu (*True Positives*). Namun, masih terdapat sejumlah kecil kesalahan prediksi, yaitu 25 citra panel bersih yang salah diklasifikasikan sebagai berdebu (*False Positives*) dan 26 citra panel berdebu yang keliru dikenali sebagai bersih (*False Negatives*). Hasil ini mencerminkan kinerja klasifikasi yang sangat seimbang dan akurat, dengan jumlah kesalahan prediksi yang relatif kecil di kedua kategori. Dengan demikian, model Xception dapat diandalkan untuk tugas klasifikasi citra panel surya dalam konteks praktis, namun tetap ada ruang untuk perbaikan guna lebih meminimalkan kesalahan klasifikasi dan meningkatkan keandalan sistem secara keseluruhan.

Penggunaan berbagai metrik evaluasi memungkinkan penilaian performa model secara lebih komprehensif dan mendalam. Setiap indikator memberikan sudut pandang yang berbeda dalam menilai kemampuan model, sehingga hasil evaluasi dapat menggambarkan kinerjanya secara lebih akurat di berbagai kondisi data. Secara keseluruhan, ringkasan hasil evaluasi untuk tiap model berdasarkan metrik disajikan pada Tabel 5.

Tabel 5. Evaluasi Performa Model

<i>Model</i>	<i>Accuracy</i>	<i>F1-score</i>	<i>Precision</i>	<i>Recall</i>
MobileNetV2	87,92%	87,94%	88,76%	87,13%
DenseNet121	89,78%	89,80%	90,64%	88,97%
InceptionV3	87,73%	87,59%	89,62%	85,66%
Xception	90,52%	90,61%	90,77%	90,44%

Berdasarkan hasil evaluasi performa model seperti yang ditampilkan pada Tabel 5, keempat model CNN menunjukkan performa yang baik dalam mengklasifikasikan citra, dengan *accuracy* yang melebihi 87%. Model Xception mencatat performa terbaik dengan *accuracy* sebesar 90,52%, *F1-score* 90,61%, *precision* 90,77%, dan *recall* 90,44%. Hal ini menunjukkan bahwa model Xception lebih unggul dalam mempertahankan kestabilan dan akurasi dibandingkan model-model lain. Model DenseNet121 juga mendapatkan hasil yang baik dengan *accuracy* 89,78%, *F1-score* 89,80%, serta *precision* tinggi sebesar 90,64% dan *recall* 88,97%. Hasil ini mencerminkan kinerja yang konsisten dan mendekati Xception, terutama dalam hal presisi dan *F1-score*. Model InceptionV3 menunjukkan kinerja yang cukup baik dengan *accuracy* 87,73%, *F1-score* 87,59%, dan *precision* yang cukup tinggi sebesar 89,62%. Namun, model ini memiliki nilai *recall* paling rendah yaitu 85,66%, yang mengindikasikan bahwa model ini sedikit kurang sensitif dalam mendeteksi semua kelas secara benar. Sementara itu, MobileNetV2 memperoleh *accuracy* sebesar 87,92%, *F1-score* 87,94%, *precision* 88,76%, dan *recall* 87,13%. Meskipun hasilnya sedikit lebih rendah dibandingkan model lainnya, MobileNetV2 tetap menunjukkan kinerja yang solid dan seimbang antara metrik-metrik evaluasi. Secara umum, semua model menunjukkan kinerja yang cukup baik. Hal ini mengindikasikan bahwa model-model *pre-trained* yang digunakan telah berhasil diadaptasi untuk tugas klasifikasi panel surya. Beberapa kesalahan klasifikasi yang terjadi selama pengujian kemungkinan besar disebabkan oleh kondisi pencahayaan atau sudut pengambilan gambar yang tidak konsisten. Sebagai contoh, pantulan cahaya pada panel bersih terkadang menyerupai tekstur buram dari debu ringan, yang dapat menyebabkan model kesulitan dalam membedakan kelas.

4. KESIMPULAN

Berdasarkan hasil eksperimen dan evaluasi performa model dalam klasifikasi citra panel surya bersih dan berdebu, bisa disimpulkan bahwa seluruh arsitektur CNN yang digunakan, yaitu MobileNetV2, DenseNet121, InceptionV3, dan Xception, mampu memberikan performa klasifikasi yang sangat baik dengan akurasi di atas 87%. Dari keempat model yang diuji, Xception menunjukkan performa terbaik, dengan *accuracy* sebesar 90,52%, *F1-score* sebesar 90,61%, *precision* sebesar 90,77%, dan *recall* sebesar 90,44%. Hasil ini menunjukkan bahwa arsitektur Xception unggul dalam mempelajari representasi visual utama dari citra panel surya. Model DenseNet121 juga menunjukkan performa yang baik dengan *accuracy* 89,78% dan *F1-score* 89,80%, menandakan arsitektur ini mampu menangkap pola visual secara efisien. Sementara itu, MobileNetV2, yang dikenal ringan dan efisien, mencatat *accuracy* 87,92%, menjadikannya pilihan potensial untuk implementasi pada perangkat dengan keterbatasan sumber daya. Model InceptionV3, meskipun memiliki *accuracy* sedikit lebih rendah yaitu 87,73%, tetap menunjukkan performa yang solid dan konsisten. Dengan demikian, keempat model dapat dijadikan dasar dalam pengembangan sistem deteksi otomatis kebersihan panel surya berbasis citra. Untuk aplikasi industri atau sistem pemantauan otomatis, akurasi yang sebaiknya dicapai harus di atas 90%. Di sisi lain, dalam konteks pembelajaran berbasis citra untuk sistem pemantauan panel surya, akurasi di atas 85% sudah cukup memberikan hasil yang andal. Ke depan, peningkatan performa dapat difokuskan pada pengujian model *pre-trained* tambahan, optimalisasi metode *fine-tuning*, serta integrasi teknik augmentasi dan regularisasi yang lebih kompleks untuk

menangani variasi kondisi pencahayaan dan tingkat debu yang lebih luas. Selain itu, penambahan fitur explainability seperti metode LIME dapat memberikan wawasan visual tentang area gambar yang menjadi dasar keputusan model, sehingga meningkatkan transparansi dan kepercayaan pengguna terhadap sistem klasifikasi ini.

REFERENCES

- [1] F. Ferdyson, and J. Windarta, "Overview Pemanfaatan dan Perkembangan Sumber Daya Energi Surya Sebagai Energi Terbarukan di Indonesia," *Jurnal Energi Baru dan Terbarukan*, vol. 4, no. 1, pp. 1-6, 2023, doi: 10.14710/jebt.2023.15714.
- [2] J. Tanesab, D. Parlevliet, J. Whale, and T. Urmee, "Dust Effect and its Economic Analysis on PV Modules Deployed in a Temperate Climate Zone," *Energy Procedia*, vol. 100, pp. 65–68, 2016, doi: 10.1016/j.egypro.2016.10.154.
- [3] E. A. Pratama and R. N. Ahmad, "Analisis Pengaruh Polutan Debu Terhadap Pembangkitan Daya Pada Sistem Pembangkit Listrik Tenaga Surya," vol. 3, pp. 1–19, 2024. [Online]. Available: <https://eprints.ums.ac.id/id/eprint/121708>.
- [4] I. G. Perwati, N. Suarna, and T. Suprati, "Analisis Klasifikasi Gambar Bunga Lily Menggunakan Metode Convolutional Neural Network (CNN) Dalam Pengolahan Citra," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 3, pp. 2908–2915, 2024, doi: 10.36040/jati.v8i3.9193.
- [5] D. C. Febrianto, G. Wibisono, M. A. Fitriani, and M. Afrad, "Transfer Learning model Convolutional Neural Network menggunakan VGG-16 untuk Klasifikasi Tumor Otak pada Citra Hasil MRI," *LEDGER: Journal Informatic and Information Technology*, vol. 3, no. 1, pp. 11–18, 2024, doi: 10.20895/ledger.v3i1.1387.
- [6] A. Andreansyah and J. Supardi, "VGG-16 Accuracy Optimization for Fingerprint Pattern Imager Classification," *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, vol. 14, no. 1, pp. 42–48, 2025, doi: 10.32736/sisfokom.v14i1.2317.
- [7] A. E. Putra, M. F. Naufal, and V. R. Prasetyo, "Klasifikasi Jenis Rempah Menggunakan Convolutional Neural Network dan Transfer Learning," *Jurnal Edukasi dan Penelitian Informatika*, vol. 9, no. 1, p. 12, 2023, doi: 10.26418/jp.v9i1.58186.
- [8] N. W. Kencana, R. Umar, and Murinto, "Implementasi Transfer Learning Untuk Klasifikasi Jenis Ras Ayam," *Jurnal Informatika Polinema*, vol. 11, no. 2, pp. 147–154, 2025, doi: 10.33795/jip.v11i2.6469.
- [9] G. E. P. Purba, S. H. Wijoyo, and N. Y. Setiawan, "Pengaruh Transfer Learning ResNet dan DenseNet terhadap Performa Klasifikasi Ekspresi Wajah Menggunakan Dataset FER-2013," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 8, no. 7, 2024. [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/13931>.
- [10] A. W. Kosman, Y. Wahyuningsih, and F. Mahendrasusila, "Pengujian Metode Inception V3 dalam Mengidentifikasi Penyakit Kanker Kulit," *Jurnal Teknologi Informatika dan Komputer*, vol. 10, no. 1, pp. 132–142, 2024, doi: 10.37012/jtik.v10i1.1940.
- [11] Darmatasia, "Deteksi Penggunaan Masker Menggunakan Xception Transfer Learning," *Jurnal Informatika Sains dan Teknologi*, vol. 5, no. 2, pp. 279–288, 2020, doi: 10.24252/instek.v5i2.20132.
- [12] G. Cipriani, A. D'Amico, S. Guarino, D. Manno, M. Traverso, and V. Di Dio, "Convolutional neural network for dust and hotspot classification in PV modules," *Energies*, vol. 13, no. 23, 2020, doi: 10.3390/en13236357.
- [13] Y. Shao, C. Zhang, L. Xing, H. Sun, Q. Zhao, and L. Zhang, "A new dust detection method for photovoltaic panel surface based on Pytorch and its economic benefit analysis," *Energy and AI*, vol. 16, p. 100349, 2024, doi: 10.1016/j.egyai.2024.100349.
- [14] A. M. Alatwi, H. Albalawi, A. Wadood, H. Anwar, and H. M. El-Hageen, "Deep Learning-Based Dust Detection on Solar Panels: A Low-Cost Sustainable Solution for Increased Solar Power Generation," *Sustainability*, vol. 16, no. 19, pp. 1–16, 2024, doi: 10.3390/su16198664.
- [15] F. UYSAL, "Dust Detection on Solar Photovoltaic Panels Used in Optoelectronics with Convolutional Neural Network-Based Deep Learning Models," *IJCESEN*, vol. 11, no. 1, 2025.
- [16] M. S. H. Onim, Z. M. M. Sakif, A. Ahnaf, A. Kabir, A. K. Azad, A. M. T. Oo, R. Afreen, S. T. Hridy, M. Hossain, T. Jabid, and M. S. Ali, "SolNet: A convolutional neural network for detecting dust on solar panels," *Energies*, vol. 16, no. 1, p. 155, 2023, doi: 10.3390/en16010155.
- [17] M. Mamdouh and Y. A. Zaghloul, "Fusion Between Image Processing and Machine Learning for Dust Detection on Solar Panels," in *2024 Fifteenth International Conference on Ubiquitous and Future Networks (ICUFN)*, IEEE, 2024, pp. 169–174. doi: 10.1109/ICUFN61752.2024.10625232.
- [18] H. M. A. Mohammed and A. E. Ba Alawi, "CASolarNet: Channel Attention EfficientNet-based model for solar panel dust detection," in *2024 4th International Conference on Emerging Smart Technologies and Applications (eSmarTA)*, IEEE, 2024, pp. 1–4. doi: 10.1109/eSmarTA62850.2024.10638876.
- [19] M. Shah, M. Joshi, P. Patel, N. Mevada, R. Baria, and M. Chauhan, "Improving solar power generation with InceptionV3 dust detection on the solar panel energy systems," in *2023 Third International Conference on Ubiquitous Computing and Intelligent Information Systems (ICUIS)*, IEEE, 2023, pp. 448–456. doi: 10.1109/ICUIS60567.2023.00080.
- [20] B. Wijayanto, R. M. Mahendra, M. I. Salam, and T. Informatika, "Identifikasi Jenis Ikan Cupang Menggunakan Metode CNN Dengan Arsitektur MobileNetV2 Berbasis Mobile," *Seminar Nasional Teknologi & Sains*, vol. 4, pp. 519–525, 2025, doi: 10.29407/8k2m1068.
- [21] R. J. H. Butar-Butar and N. L. Marpaung, "Deep Learning untuk Identifikasi Daun Tanaman Obat Menggunakan Transfer Learning MobileNetV2," *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 8, no. 2, pp. 142–148, 2023, doi: 10.30591/jpit.v8i2.5217.
- [22] T. S. Arulananth, S. W. Prakash, R. K. Ayyasamy, V. P. Kavitha, P. G. Kuppasamy, and P. Chinnasamy, "Classification of Paediatric Pneumonia Using Modified DenseNet-121 Deep-Learning Model," *IEEE Access*, vol. 12, pp. 35716–35727, 2024, doi: 10.1109/ACCESS.2024.3371151.
- [23] C. Nisa', E. Y. Puspaningrum, and H. Maulana, "Penerapan Metode Convolutional Neural Network untuk Klasifikasi Penyakit Daun Apel pada Imbalanced Data," *Seminar Nasional Informatika Bela Negara*, vol. 1, pp. 169–175, 2020, doi: 10.33005/santika.v1i0.46.
- [24] D. P. Pamungkas and M. F. Amrulloh, "Analisis Hasil Klasifikasi Penyakit Daun Bawang Merah Menggunakan CNN Arsitektur Exception," *Jurnal Ilmiah Penelitian dan Pembelajaran Informatika*, vol. 10, no. 1, pp. 359–366, 2025, doi: 10.29100/jipi.v10i1.5875.
- [25] F. Hafifah, S. Rahman, and S. Asih, "Klasifikasi Jenis Kendaraan Pada Jalan Raya Menggunakan Metode Convolutional Neural

- Networks (CNN)," *TIN (Terapan Informatika Nusantara)*, vol. 2, no. 5, pp. 292–301, 2021. [Online]. Available: <https://ejurnal.seminar-id.com/index.php/tin/article/view/915>.
- [26] R. Triginandri and E. R. Subhiyakto, "Deteksi Dini Cacar Monyet menggunakan Convolutional Neural Network (CNN) dalam Aplikasi Mobile," *Edumatic: Jurnal Pendidikan Informatika*, vol. 8, no. 2, pp. 516–525, 2024, doi: 10.29408/edumatic.v8i2.27625.
- [27] Sutarti and F. Syaialloh, "Klasifikasi dan Pengenalan Emosi dari Ekspresi Wajah Menggunakan CNN-BiLSTM dengan Teknik Data Augmentation", *Decode :Jurnal Pendidikan Teknologi Informasi*, vol. 5, no. 1, pp. 79–91, 2025, doi: doi.org/10.51454/decode.v5i1.1038.
- [28] M. A. Leonardi and A. Y. Chandra, "Analisis Perbandingan CNN dan Vision Transformer untuk Klasifikasi Biji Kopi Hasil Sangrai," *Jurnal Media Informatika Budidarma*, vol. 8, no. 3, p. 1398, 2024, doi: 10.30865/mib.v8i3.7732.