

SISTEM DETEKSI KERUSAKAN PANEL PLTS APUNG DI EMBUNG SIDOBANDUNG BERBASIS CONVOLUTIONAL NEURAL NETWORK DENGAN VISUALISASI AUGMENTED REALITY (DAMAGE DETECTION SYSTEM FOR FLOATING SOLAR PANELS AT SIDOBANDUNG POND BASED ON CONVOLUTIONAL NEURAL NETWORKS WITH AUGMENTED REALITY VISUALIZATION)

Thomas Brian¹⁾, Immanuel Freddy Augustino²⁾, Parman³⁾, Muhamad Sukarno⁴⁾

¹⁾Teknik Kelistrikan Kapal, Politeknik Perkapalan Negeri Surabaya

²⁾Teknik Permesinan Kapal, Politeknik Perkapalan Negeri Surabaya

^{3,4)}Teknik Bangunan Kapal, Politeknik Perkapalan Negeri Surabaya

Jl. Teknik Kimia, Kampus ITS, Keputih, Sukolilo. Surabaya 60111

e-mail: thomasbrian@ppns.ac.id¹⁾, immanuelfreddy@ppns.ac.id²⁾, parman@ppns.ac.id³⁾,

muhamadsukarno@student.ppns.ac.id⁴⁾

ABSTRAK

Penelitian ini bertujuan mengembangkan aplikasi Augmented Reality (AR) yang terintegrasi dengan Convolutional Neural Network (CNN) sebagai sistem deteksi kerusakan panel Pembangkit Listrik Tenaga Surya (PLTS) apung di Embung Sidobandung secara interaktif untuk menjaga efisiensi sistem energi fotovoltaik. Metode inspeksi konvensional yang dilakukan secara manual dinilai kurang efisien serta berisiko mengalami kesalahan akibat faktor manusia. Oleh karena itu, pendekatan deep learning digunakan untuk melakukan deteksi dan klasifikasi kerusakan panel surya secara otomatis dan interaktif. Teknologi AR dimanfaatkan untuk menampilkan informasi kondisi panel secara langsung melalui kamera perangkat bergerak, sehingga memungkinkan pemantauan kerusakan secara real-time. Dataset terdiri 615 citra panel surya, dengan 472 citra kerusakan fisik (physical damage) dan 143 citra kerusakan elektrik (electrical damage). Ketidakseimbangan dataset terjadi karena kerusakan fisik lebih mudah didokumentasikan secara visual dibandingkan kerusakan elektrik yang memerlukan pencitraan khusus sehingga jumlah datanya lebih terbatas. Hasil pengujian dengan metode cross-validation menunjukkan sistem mampu melakukan klasifikasi jenis kerusakan panel secara real-time dengan tingkat precision 93,48%, recall 89,58%, F1-Score 91,49% untuk physical damage dan precision 70,59%, recall 80,00%, F1-Score 75,00% untuk electrical damage dengan accuracy total 87,30%. Secara keseluruhan, integrasi CNN dan AR berpotensi menjadi solusi yang efektif dan efisien dalam pengembangan sistem deteksi kerusakan panel PLTS apung.

Kata Kunci: Augmented Reality, Convolutional Neural Network, Deteksi Kerusakan, Embung, PLTS Apung

ABSTRACT

This study aims to develop an Augmented Reality (AR) application integrated with a Convolutional Neural Network (CNN) as an interactive system for detecting damage in floating solar power plant (PLTS) panels at Embung Sidobandung in order to maintain the efficiency of the photovoltaic energy system. Conventional manual inspection methods are considered inefficient and prone to errors due to human factors. Therefore, a deep learning approach is employed to automatically and interactively detect and classify solar panel damage. AR technology is utilized to display panel condition information directly through a mobile device camera, enabling real-time damage monitoring. The dataset consists of 615 solar panel images, including 472 images of physical damage and 143 images of electrical damage. The dataset imbalance occurs because physical damage is easier to document visually, whereas electrical damage requires specialized imaging, resulting in more limited data availability. Experimental results with cross-validation method show that the system is capable of classifying solar panel damage types in real time, achieving a precision of 93.48%, recall of 89.58%, and an F1-score of 91.49% for physical damage, and a precision of 70.59%, recall of 80.00%, and an F1-score of 75.00% for electrical damage, with an overall accuracy of 87.30%. Overall, the integration of CNN and AR has the potential to serve as an effective and efficient solution for developing damage detection systems for floating solar power plant (PLTS) panels.

Keywords: Augmented Reality, Convolutional Neural Network, Damage Detection, Floating Photovoltaics, Small Reservoir

I. PENDAHULUAN

Dalam beberapa tahun terakhir, pemanfaatan Pembangkit Listrik Tenaga Surya (PLTS) sebagai sumber energi terbarukan tidak hanya dilakukan di daratan, tetapi juga dikembangkan dalam bentuk PLTS apung (*floating photovoltaic*) yang dipasang di atas permukaan air seperti laut, danau, maupun embung. Konsep PLTS apung dinilai memiliki keunggulan dalam efisiensi penggunaan lahan, peningkatan performa modul akibat efek pendinginan air, serta potensi reduksi evaporasi air [1]. Embung Sidobandung merupakan salah satu infrastruktur air yang dimanfaatkan sebagai lokasi pengembangan PLTS apung di Desa Sidobandung, Kecamatan Balen, Kabupaten Bojonegoro. Keberadaan sistem PLTS apung di embung tersebut berperan penting dalam mendukung penyediaan energi listrik berbasis energi terbarukan di tingkat lokal. Namun demikian, sistem PLTS, khususnya yang beroperasi di lingkungan terbuka dan lembap seperti perairan, sangat rentan terhadap berbagai jenis kerusakan panel surya, baik kerusakan fisik maupun elektrik. Kerusakan tersebut meliputi *hot spot*, *microcrack*, degradasi sel, delaminasi, hingga gangguan konduktivitas yang dapat menyebabkan penurunan efisiensi daya, peningkatan *losses*, serta mempercepat degradasi modul surya secara keseluruhan [2]. Metode inspeksi panel surya yang umum digunakan saat ini masih didominasi oleh inspeksi visual manual dan pengukuran konvensional. Pendekatan ini memiliki keterbatasan dari sisi efisiensi waktu, ketergantungan pada keahlian operator, serta kurang optimal untuk instalasi PLTS skala besar maupun lokasi yang sulit dijangkau, seperti PLTS apung. Selain itu, beberapa jenis kerusakan elektrik tidak selalu dapat teridentifikasi secara kasat mata dan memerlukan pendekatan berbasis citra serta analisis pola visual yang lebih kompleks [3]. Berbagai studi menunjukkan bahwa modul PV mengalami laju degradasi tahunan rata-rata sebesar 0,5–1% per tahun, dengan kegagalan dini (*early failure*) dapat terjadi pada 0,5–2% modul dalam

lima tahun pertama operasi [4]. Selain itu, lebih dari 30% kasus kerusakan modul di lapangan dikaitkan dengan *hotspot*, *microcrack*, dan degradasi sel yang sering kali sulit terdeteksi melalui inspeksi visual konvensional [5].

Seiring berkembangnya teknologi kecerdasan buatan, *Convolutional Neural Network* (CNN) telah terbukti efektif dalam melakukan ekstraksi fitur dan klasifikasi citra secara otomatis dengan tingkat akurasi yang tinggi. CNN banyak digunakan dalam berbagai penelitian untuk mendeteksi dan mengklasifikasikan kerusakan panel surya, baik menggunakan pendekatan *transfer learning* maupun model CNN kustom [4]. Penelitian sebelumnya menunjukkan bahwa CNN mampu mengidentifikasi kerusakan modul surya secara lebih akurat dibandingkan metode konvensional, serta dapat diimplementasikan secara efisien dalam sistem pemantauan berbasis citra [6]. Di sisi lain, teknologi *Augmented Reality* (AR) menawarkan pendekatan visualisasi yang interaktif dengan menggabungkan objek virtual ke dalam lingkungan nyata secara *real-time*. Integrasi AR dengan sistem berbasis CNN memungkinkan hasil deteksi kerusakan panel surya divisualisasikan secara langsung di atas objek panel yang diamati, sehingga memudahkan teknisi atau operator dalam memahami kondisi panel, lokasi kerusakan, serta jenis gangguan yang terdeteksi. Penelitian terkait integrasi AR dan CNN telah menunjukkan potensi besar dalam meningkatkan pemahaman visual, efektivitas inspeksi, serta pengalaman pengguna dalam berbagai domain, termasuk sistem inspeksi dan edukasi berbasis visual [7]. Dibandingkan dengan metode *non deep learning* seperti ekstraksi fitur manual dan klasifikasi berbasis SVM atau *K-Nearest Neighbor* (KNN), pendekatan CNN mampu melakukan ekstraksi fitur secara otomatis dan menunjukkan performa klasifikasi yang lebih stabil pada variasi pencahayaan dan sudut pengambilan citra [8].

Meskipun berbagai penelitian telah membahas deteksi kerusakan panel surya menggunakan CNN

maupun visualisasi berbasis AR secara terpisah, kajian yang mengintegrasikan CNN sebagai sistem deteksi kerusakan panel PLTS apung dengan visualisasi *Augmented Reality* secara interaktif masih relatif terbatas. Selain itu, sebagian besar penelitian sebelumnya masih berfokus pada analisis citra tanpa menyediakan antarmuka visual yang intuitif bagi pengguna di lapangan. Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan sistem deteksi kerusakan panel PLTS apung berbasis *Convolutional Neural Network* dengan visualisasi *Augmented Reality*. Sistem yang dikembangkan diharapkan mampu mendeteksi dan mengklasifikasikan kondisi panel surya secara akurat, serta menyajikan hasil deteksi dalam bentuk visualisasi AR yang interaktif dan mudah dipahami. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi dalam peningkatan efektivitas pemantauan, pemeliharaan dan menjaga performa dari sistem PLTS apung di Embung Sidobandung, serta menjadi referensi pengembangan sistem serupa di masa mendatang.

II. STUDI PUSTAKA

Pembangkit Listrik Tenaga Surya (PLTS) apung merupakan sistem fotovoltaik yang dipasang di atas permukaan badan air seperti waduk atau embung dengan memanfaatkan struktur terapung [1], sehingga mampu mengatasi keterbatasan lahan sekaligus meningkatkan kinerja panel melalui efek pendinginan alami dari air. Panel surya bekerja dengan menyerap sinar matahari untuk menghasilkan listrik. Meskipun memiliki berbagai keunggulan, PLTS apung beroperasi pada lingkungan dengan tingkat kelembapan tinggi dan paparan cuaca ekstrem yang dapat mempercepat degradasi serta meningkatkan risiko kerusakan panel surya. Jenis kerusakan yang umum terjadi meliputi kerusakan fisik seperti *microcrack*, delaminasi, pecahnya kaca pelindung, serta korosi pada rangka dan komponen panel, serta kerusakan elektrik seperti *hot spot*, degradasi sel surya, dan gangguan konduktivitas [9]. Kerusakan-kerusakan tersebut berdampak langsung pada penurunan efisiensi dan keandalan sistem PLTS apung serta sering kali sulit terdeteksi secara dini melalui inspeksi visual konvensional, sehingga diperlukan pendekatan pemantauan dan deteksi berbasis

teknologi yang lebih akurat dan efisien [10]. Gambar 1 memperlihatkan lokasi PLTS apung di Embung Sidobandung. Pendekatan deteksi kerusakan sebelumnya umumnya menggunakan inspeksi manual, pengukuran *I-V curve*, atau analisis citra berbasis ekstraksi fitur tradisional seperti GLCM dan *edge detection* yang dikombinasikan dengan SVM atau KNN [11].



Gambar 1. PLTS Apung Embung Sidobandung (<https://ppns.ac.id/peduli-potensi-energi-terbarukan-ppns-hadirkan-plts-apung-di-desa-sidobandung/>)

Convolutional Neural Network (CNN) merupakan metode *deep learning* yang dirancang khusus untuk pengolahan citra dengan kemampuan mengekstraksi fitur visual secara otomatis melalui proses konvolusi dan *pooling* [12][13]. Penggunaan model CNN seperti VGG16, ResNet-50, hingga model terbaru seperti YOLOv8 telah terbukti memberikan akurasi yang sangat tinggi di atas 90% dalam mendeteksi anomali pada panel surya [14]. Teknik *transfer learning* juga sering diterapkan untuk mempercepat proses pelatihan dan meningkatkan akurasi model [15]. CNN mampu mengenali pola kompleks seperti tekstur, bentuk, dan anomali visual tanpa memerlukan perancangan fitur manual, sehingga lebih adaptif terhadap variasi data dan kondisi lingkungan [16]. Keunggulan ini menjadikan CNN banyak digunakan dalam berbagai aplikasi berbasis visi komputer, termasuk deteksi dan klasifikasi kerusakan pada panel surya [17]. Beberapa penelitian menunjukkan bahwa CNN efektif dalam mengidentifikasi kerusakan modul *fotovoltaik* dengan tingkat akurasi yang tinggi, terutama ketika dikombinasikan dengan teknik *transfer learning* dan augmentasi data [18]. Penggunaan arsitektur CNN seperti *Xception* dan *DenseNet* terbukti mampu meningkatkan akurasi dan stabilitas klasifikasi kerusakan panel surya dibandingkan metode konvensional [19][20]. Selain itu, CNN juga bisa diterapkan dalam sistem *Augmented*

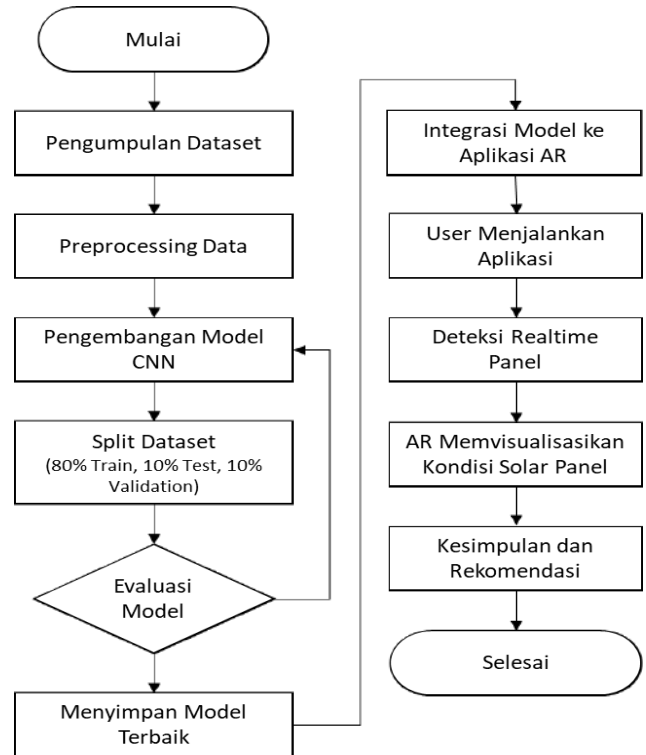
Reality untuk pengenalan objek dan analisis visual secara *real-time*, sehingga memungkinkan hasil deteksi ditampilkan secara langsung pada objek nyata [21][22][23].

Augmented Reality (AR) merupakan teknologi yang mengintegrasikan objek virtual ke dalam lingkungan nyata secara *real-time* dengan tujuan memperkaya persepsi pengguna terhadap dunia fisik [24]. AR banyak dimanfaatkan dalam berbagai bidang seperti edukasi, industri, kesehatan, dan sistem inspeksi karena kemampuannya menyajikan informasi visual secara interaktif dan kontekstual [25][26]. Dalam perkembangannya, AR tidak hanya berfungsi sebagai media visualisasi, tetapi juga dikombinasikan dengan teknologi kecerdasan buatan untuk meningkatkan kemampuan analisis dan pemahaman sistem terhadap lingkungan [27][28]. Salah satu metode yang umum digunakan adalah *Convolutional Neural Network* (CNN), yang berperan dalam melakukan pengenalan objek, klasifikasi citra, dan deteksi pola visual. Integrasi CNN dengan AR memungkinkan sistem untuk menampilkan informasi berbasis hasil analisis citra secara otomatis, seperti identifikasi objek atau kondisi tertentu, langsung pada tampilan AR [29][30]. Pendekatan ini menjadikan AR lebih adaptif dan cerdas karena visualisasi yang ditampilkan tidak bersifat statis, melainkan berdasarkan hasil pemrosesan data visual secara *real-time*. Oleh karena itu, kombinasi AR dan CNN banyak digunakan dalam pengembangan sistem inspeksi dan pemantauan modern yang menuntut akurasi analisis serta kemudahan interpretasi visual oleh pengguna.

III. METODE PENELITIAN

Penelitian ini berfokus pada klasifikasi jenis kerusakan pada panel PLTS apung berdasarkan citra visual dengan menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur model *DenseNet121* dan terintegrasi di aplikasi *Augmented Reality* (AR). Seluruh tahapan penelitian dirancang secara terstruktur, seperti ditunjukkan pada Gambar 2. Proses ini dimulai dari pengumpulan dataset citra panel surya, yang mencakup kategori kerusakan fisik (*physical damage*) dan kerusakan elektrik (*electrical damage*). Selanjutnya dataset citra dilakukan proses normalisasi, *resize*, dan augmentasi untuk meningkatkan kemampuan model terhadap variasi pencahayaan dan sudut pandang lingkungan.

Perancangan arsitektur *Convolutional Neural Network* (CNN) model *DenseNet121* dilakukan dengan menggunakan lapisan konvolusi untuk ekstraksi fitur dan lapisan *fully connected* untuk klasifikasi.



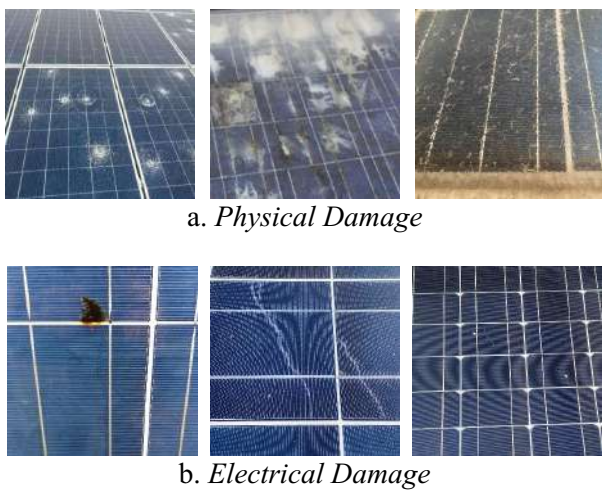
Gambar 2. Alur Penelitian

Dataset sebanyak 615 citra dibagi menjadi tiga bagian dengan proporsi 80% untuk data latih (*train*), 10% untuk data uji (*test*), dan 10% untuk data validasi (*validation*). Model terbaik dipilih setelah melalui tahap evaluasi menggunakan parameter akurasi, presisi, dan *recall* untuk memastikan performa klasifikasi *real-time* yang optimal. Model CNN diintegrasikan ke aplikasi *Augmented Reality* (AR) yang akan dioperasikan di area PLTS apung. Kamera perangkat *mobile* memindai panel surya dan model melakukan klasifikasi jenis kerusakan secara langsung. Hasil klasifikasi diproyeksikan dalam bentuk *bounding box* tepat di atas panel surya untuk memberikan informasi visual yang interaktif.

A. Dataset

Penelitian ini menggunakan dataset citra digital yang bersumber dari *Google Images* dan *Kaggle* (<https://www.kaggle.com/datasets/pythonafroz/solar-panel-images>) untuk mengidentifikasi anomali pada panel surya. Dataset tersebut diklasifikasikan ke dalam dua kategori utama kerusakan, yakni

kerusakan fisik (*physical damage*) dan kerusakan elektrikal (*electrical damage*). Secara keseluruhan, terkumpul 615 citra berformat *.png* yang terdiri dari 472 citra kategori *physical damage* dan 143 citra kategori *electrical damage*. Guna memastikan performa model CNN yang optimal, dilakukan tahap *preprocessing* data untuk mengidentifikasi serta memitigasi masalah teknis seperti resolusi rendah yang berpotensi menghambat akurasi proses klasifikasi. Proses validasi menghasilkan tingkat kesepakatan antar penilai (*Cohen's Kappa*) sebesar 0,89 sehingga dataset dinyatakan valid dan layak digunakan dalam pelatihan model CNN. Beberapa citra dataset yang digunakan dapat dilihat pada Gambar 3.



Gambar 3. Dataset Citra Panel Surya

B. Preprocessing Data

Pada tahap ini, kumpulan dataset citra yang akan digunakan disesuaikan dengan arsitektur model CNN. Selama proses *preprocessing*, dimensi semua citra di dataset diubah menjadi 150 x 150 piksel. Selanjutnya dataset akan dibagi untuk data *training*, *validation* dan *testing* dengan rincian sesuai Tabel 1.

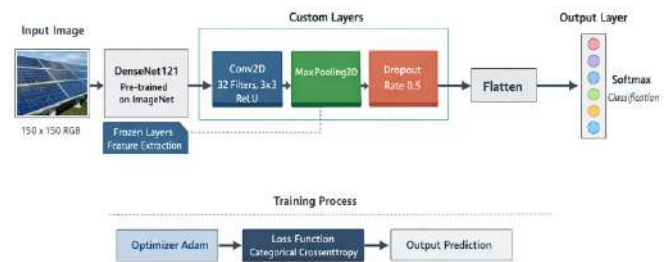
Tabel 1. Detail Pembagian Dataset

Jenis Kerusakan	Citra Asli	Training	Valida-tion	Testing
Physical Damage	472	377	48	47
Electrical Damage	143	114	15	14

C. Arsitektur CNN

Setelah melalui tahapan *preprocessing data*, penelitian dilanjutkan dengan implementasi *deep learning* berbasis CNN untuk menentukan model terbaik melalui desain arsitektur yang variatif. Struktur model yang dikembangkan menggunakan pendekatan *transfer learning* yaitu *DenseNet121*.

Proses *training* kedua arsitektur tersebut menggunakan input citra berukuran 150 x 150 piksel (RGB) yang diproses melalui lapisan dasar yang telah dilatih dengan dataset *ImageNet* untuk mengekstraksi fitur fundamental seperti tepi dan tekstur. Beberapa lapisan *layer* di awal tidak dilakukan perubahan, untuk mempertahankan pengetahuan fitur dasar, kemudian ditambahkan lapisan kustom berupa *Conv2D* (32 filter, kernel 3x3, aktivasi *ReLU*), lapisan *MaxPool2D* untuk reduksi dimensi, serta lapisan *Dropout* (0.5) guna menghindari *overfitting*. Hasil ekstraksi fitur kemudian diratakan melalui lapisan *Flatten* dan diteruskan ke *output layer* yang terdiri dari *neuron* sesuai jumlah kelas target dengan aktivasi *softmax*. Selanjutnya *optimizer Adam* diaplikasikan untuk meminimalkan fungsi kerugian *categorical crossentropy* karena efektivitasnya yang tinggi dalam pembaruan bobot model. Pada Gambar 4 dan Tabel 2 menunjukkan arsitektur model CNN dengan lapisan layer pada model *DenseNet121*.



Gambar 4. Arsitektur Model CNN

Tabel 2. Lapisan Layer Model

Layer	Output Shape 8 Layer
DenseNet121	(None, 5, 5, 2048)
Conv2D	(None, 5, 5, 64)
MaxPooling2D	(None, 2, 2, 64)
Dropout	(None, 2, 2, 64)
Flatten	(None, 512)
Dropout	(None, 128)
Dense	(None, 128)
Dense (Output)	(None, 2)

D. Evaluasi Model

Untuk mengevaluasi kinerja model klasifikasi yang dikembangkan, *confusion matrix* memiliki peran yang sangat penting. Metode ini memungkinkan penilaian performa model secara komprehensif, khususnya pada kasus klasifikasi dengan lebih dari dua kelas atau *multiclass classification*. *Confusion matrix* disajikan dalam bentuk tabel yang merepresentasikan jumlah prediksi benar dan salah, yang terdiri atas *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN). Melalui

parameter-parameter tersebut, tingkat ketepatan dan kesalahan model dapat dianalisis secara lebih mendalam seperti terlihat pada Tabel 3.

Tabel 3. *Confusion Matrix*

	<i>Positive</i>	<i>Negative</i>
<i>Positive</i>	True Positive (TP)	False Positive (FP)
<i>Negative</i>	False Negative (FN)	True Negative (TN)

Berdasarkan tabel *confusion matrix*, berbagai metrik evaluasi kinerja model dapat dihitung, antara lain:

a. Akurasi (*accuracy*)

Metrik akurasi digunakan untuk mengukur tingkat ketepatan prediksi model dengan menghitung proporsi prediksi yang benar, yaitu *True Positive* dan *True Negative*, terhadap keseluruhan jumlah data uji yang digunakan dalam pengujian. Rumus perhitungan *accuracy* dapat dinyatakan sebagai berikut:

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100 \% \quad (1)$$

b. Presisi (*precision*)

Presisi merupakan metrik evaluasi yang digunakan untuk menilai tingkat ketepatan model dalam menghasilkan prediksi positif yang benar. Metrik ini dihitung sebagai perbandingan antara jumlah prediksi positif yang benar (*True Positive*) terhadap seluruh prediksi positif yang dihasilkan oleh model. Presisi menggambarkan kemampuan model dalam mengidentifikasi kelas positif secara tepat tanpa mengklasifikasikan kelas negatif sebagai positif. Rumus perhitungan *precision* dapat dinyatakan sebagai berikut:

$$precision = \frac{TP}{TP + FP} \times 100 \% \quad (2)$$

c. Sensitivitas atau *recall*

Sensitivitas atau *recall* merupakan metrik evaluasi yang menunjukkan kemampuan model dalam mengidentifikasi kelas positif secara benar. Metrik ini dihitung dengan membandingkan jumlah prediksi positif yang benar (*True Positive*) terhadap total prediksi positif yang seharusnya terdeteksi, yaitu jumlah *True Positive* dan *False Negative*. Rumus perhitungan *recall* dapat dinyatakan sebagai berikut:

$$recall = \frac{TP}{TP + FN} \times 100 \% \quad (3)$$

d. *F1-score*

F1-score merupakan metrik evaluasi yang merepresentasikan keseimbangan antara presisi (*precision*) dan sensitivitas (*recall*). Metrik ini digunakan untuk menilai kemampuan model dalam mengklasifikasikan prediksi positif dan negatif secara akurat dengan mempertimbangkan kedua aspek tersebut secara simultan. Rumus perhitungan *F1-score* dapat dinyatakan sebagai berikut:

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

Metrik-metrik tersebut digunakan untuk memberikan gambaran yang lebih komprehensif mengenai performa model klasifikasi.

IV. HASIL DAN PEMBAHASAN

Dalam proses *training* model *Convolutional Neural Network* (CNN) untuk deteksi kerusakan pada panel surya menggunakan komputer dengan spesifikasi *processor Intel Core i7-12700 Gen-12*, *RAM 16GB* dan *VGA RTX 4060*. Pembahasan mencakup arsitektur model *DenseNet121*, proses *training* model menggunakan *framework TensorFlow*, analisis kinerja model dengan *confusion matrix* dan implementasinya dengan aplikasi *Augmented Reality*. Selama proses *training*, model *DenseNet121* dilatih hingga *75 epoch*. Penentuan *epoch* terbaik dilakukan berdasarkan nilai akurasi tertinggi pada data validasi, yang merepresentasikan kondisi optimal ketika model mencapai kinerja terbaik tanpa mengalami *overfitting*. Berdasarkan hasil analisis, nilai *loss* dan *validation loss* menunjukkan tren penurunan yang konsisten hingga mendekati epoch ke 68, yang menandakan peningkatan kemampuan model dalam meminimalkan kesalahan prediksi. Nilai *accuracy* dan *validation accuracy* juga mengalami peningkatan bertahap, kondisi ini menunjukkan bahwa model mencapai performa optimal pada *epoch* tersebut sebelum mulai menunjukkan kecenderungan stagnasi dan penurunan ringan pada akurasi validasi di *epoch-epoch* selanjutnya. Berdasarkan hasil *training*, selisih antara *accuracy* dan *validation accuracy*

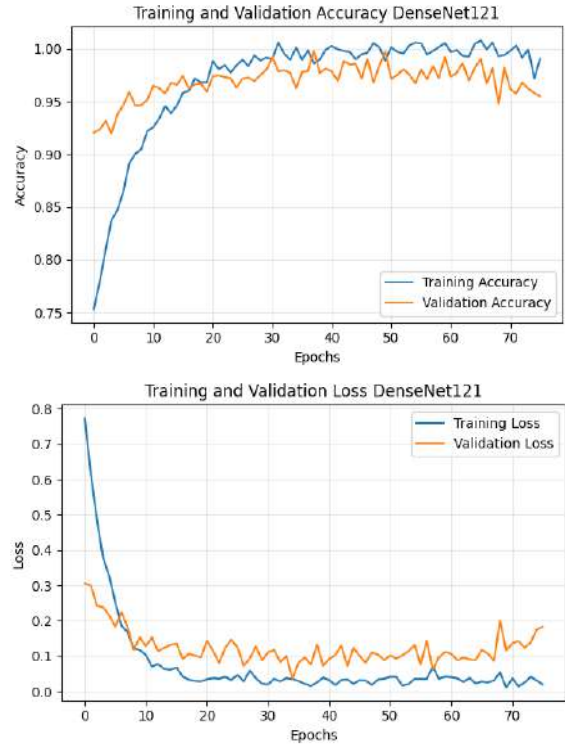
relatif kecil ($\pm 4-5\%$), yang menunjukkan bahwa model *DenseNet121* memiliki kemampuan generalisasi yang cukup baik dan tidak mengalami *overfitting* secara signifikan. Dibandingkan dengan *baseline CNN* tanpa *transfer learning*, *DenseNet121* menunjukkan konvergensi lebih stabil dan akurasi validasi yang lebih tinggi karena memanfaatkan bobot pra-latih dari *ImageNet*. Variasi waktu pelatihan pada setiap *epoch*, yang berada pada rentang 5–7 detik per langkah (*s/step*), dipengaruhi oleh proses komputasi dan manajemen *batch* selama pelatihan. Berikut hasil dari proses *training* model *DenseNet121* mulai *epoch* ke 60 hingga 75, disajikan pada Tabel 4.

Tabel 4. Hasil *Training Model DenseNet121*

Epoch	Loss	Val Loss	Accuracy	Val Accuracy	Training Time
60/75	0.1245	0.2614	0.9412	0.8921	85 s (6 s/step)
61/75	0.1132	0.2541	0.9528	0.8984	92 s (7 s/step)
62/75	0.1196	0.2479	0.9485	0.9058	80 s (5 s/step)
63/75	0.1013	0.2396	0.9617	0.9130	88 s (6 s/step)
64/75	0.1079	0.2312	0.9564	0.9203	95 s (7 s/step)
65/75	0.0894	0.2235	0.9729	0.9276	82 s (5 s/step)
66/75	0.0947	0.2178	0.9681	0.9348	90 s (6 s/step)
67/75	0.0735	0.2106	0.9816	0.9419	97 s (7 s/step)
68/75	0.0367	0.2013	0.9938	0.9482	84 s (5 s/step)
69/75	0.0399	0.2074	0.9912	0.9419	88 s (6 s/step)
70/75	0.0423	0.2141	0.9896	0.9348	95 s (7 s/step)
71/75	0.0462	0.2199	0.9871	0.9348	86 s (6 s/step)
72/75	0.0498	0.2256	0.9854	0.9276	80 s (5 s/step)
73/75	0.0531	0.2304	0.9832	0.9276	92 s (6 s/step)
74/75	0.0564	0.2369	0.9817	0.9203	97 s (7 s/step)
75/75	0.0589	0.2425	0.9801	0.9203	89 s (6 s/step)

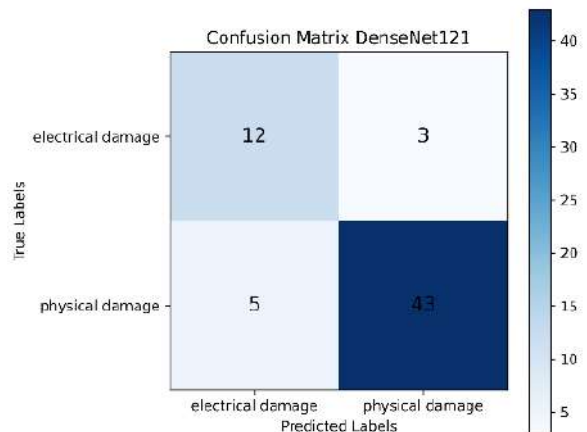
Gambar 5 menunjukkan model *accuracy* dan *loss* dari kinerja model *DenseNet121* selama proses *training* dan *validation* mulai *epoch* ke 0 hingga 75. Nilai *training accuracy* meningkat signifikan pada awal *training* dan mencapai kondisi stabil dengan performa terbaik mendekati *epoch* terakhir, sementara *validation accuracy* mengikuti tren yang serupa dengan selisih yang relatif kecil, menandakan kemampuan generalisasi model yang baik. Sementara nilai *training loss* dan *validation*

loss mengalami penurunan hingga mencapai nilai minimum.



Gambar 5. Model Accuracy dan Model Loss

Pada Gambar 6 menunjukkan bahwa model *DenseNet121* mampu mengklasifikasikan kerusakan panel surya dengan baik. Dari total 15 data *electrical damage*, sebanyak 12 data berhasil diklasifikasikan dengan benar, sedangkan 3 data salah diklasifikasikan sebagai *physical damage*. Sementara itu, dari 48 data *physical damage*, sebanyak 43 data berhasil dikenali dengan benar dan 5 data salah diklasifikasikan sebagai *electrical damage*. Sehingga akurasi keseluruhan model *DenseNet121* yang diperoleh adalah 87,30%, yang menunjukkan bahwa model ini mampu mengklasifikasikan sebagian besar data kerusakan panel surya dengan tepat.

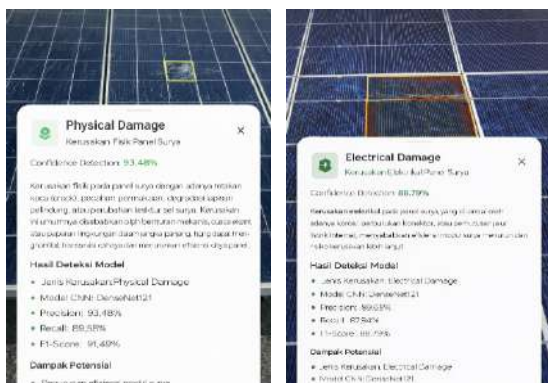


Gambar 6. Confusion Matrix Model DenseNet121

Tabel 5. Hasil Pengujian Model DenseNet121

Kelas	Precision (%)	Recall (%)	F1-Score (%)
Physical Damage	93.48%	89.58%	91.49%
Electrical Damage	70.59%	80.00%	75.00%
Accuracy Total	-	-	87,30%

Hasil evaluasi pada Tabel 5 menunjukkan bahwa model *DenseNet121* memperoleh akurasi keseluruhan sebesar 87,30%. Model memiliki performa yang lebih baik dalam mengklasifikasikan kelas *physical damage* dengan nilai *precision* 93,48%, *recall* 89,58%, dan *F1-score* 91,49%, yang dipengaruhi oleh dominasi jumlah data pada kelas tersebut. Pada kelas *electrical damage*, model masih menunjukkan kinerja yang cukup baik dengan *F1-score* 75,00%, meskipun terdapat beberapa kesalahan klasifikasi akibat kemiripan karakteristik visual antar kelas kerusakan. Model CNN dengan arsitektur *DenseNet121* yang telah melalui tahap pelatihan dan evaluasi selanjutnya diimplementasikan ke dalam aplikasi *Augmented Reality* (AR) sebagai sistem pendukung inspeksi kerusakan panel surya. Model CNN yang telah terlatih diintegrasikan ke dalam aplikasi AR berbasis *mobile*, sehingga mampu melakukan proses inferensi secara *real-time* terhadap citra panel surya yang ditangkap oleh kamera. Pada tahap ini, CNN berperan sebagai modul analisis visual untuk mengklasifikasikan kondisi panel surya ke dalam kategori *physical damage* atau *electrical damage*. Hasil klasifikasi tersebut kemudian divisualisasikan melalui teknologi AR dengan menampilkan informasi digital berupa label jenis kerusakan langsung pada objek panel surya di lingkungan nyata. Gambar 7 menunjukkan contoh ujicoba aplikasi AR menggunakan model CNN untuk mendeteksi kerusakan panel yang nantinya akan diterapkan di PLTS apung Sidobandung.



Gambar 7. Ujicoba Aplikasi AR dengan Model CNN

V. KESIMPULAN

Penelitian ini mengembangkan sistem deteksi kerusakan panel Pembangkit Listrik Tenaga Surya (PLTS) apung berbasis *Convolutional Neural Network* (CNN) dengan visualisasi *Augmented Reality* (AR) untuk mendukung proses inspeksi interaktif di Embung Sidobandung. Model CNN menggunakan *DenseNet121* yang mampu mengklasifikasikan kerusakan panel surya ke dalam kategori *physical damage* dan *electrical damage* secara efektif. Berdasarkan pengujian terhadap 63 data uji, sistem memperoleh akurasi keseluruhan sebesar 87,30%, dengan performa terbaik pada kelas *physical damage* yang mencapai nilai *precision* 93,48%, *recall* 89,58%, dan *F1-score* 91,49%, sementara pada kelas *electrical damage* diperoleh *F1-score* 75,00%. Penelitian ini berkontribusi dalam penerapan *transfer learning* berbasis *DenseNet121* dan visualisasi *Augmented Reality* dalam satu sistem deteksi kerusakan PLTS apung, yang tidak hanya meningkatkan akurasi klasifikasi dibandingkan metode tradisional, tetapi juga menghadirkan visualisasi *real-time* yang belum banyak dibahas pada penelitian sebelumnya. Pengembangan selanjutnya, disarankan penambahan jumlah dan variasi dataset, terutama pada kelas *electrical damage*, guna meningkatkan kemampuan generalisasi model. Selain itu, penelitian mendatang dapat menggunakan lebih dari satu model arsitektur CNN lain seperti *Resnet* dan *Alexnet* untuk mendapatkan akurasi yang lebih baik, serta mengembangkan fitur AR yang menampilkan tingkat keparahan kerusakan dan estimasi penurunan performa panel. Integrasi dengan sistem pemantauan berbasis IoT juga berpotensi memperluas penerapan sistem ini dalam pemeliharaan PLTS apung secara berkelanjutan.

LAMPIRAN

Penelitian ini menggunakan dana DIPA Politeknik Perkapalan Negeri Surabaya tahun anggaran 2026.

UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih kepada BUMDes Sidobandung selaku pengelola embung yang memberikan kesempatan kepada kami untuk melaksanakan penelitian. Apresiasi juga disampaikan kepada semua anggota dan pihak yang berkontribusi dalam menyelesaikan penelitian ini.

REFERENSI

- [1] I. Marupa, I. R. Moe, A. Mardjono, and D. Malindo, "PLTS Terapung: Review Pembangunan dan Simulasi Numerik Untuk Rekomendasi Penempatan Panel Surya di Waduk Cirata," *pengairan*, vol. 13, no. 1, pp. 48–62, Apr. 2022, doi:10.21776/ub.pengairan.2022.013.01.05.
- [2] Y. Seran, N. Nursalim, and S. Kurniati, "Analisis Penurunan Kinerja Daya Keluaran Pada Pembangkit Listrik Tenaga Surya (PLTS) 5 MWP Oelpuah Kupang dengan Menggunakan Software PVSYSY," *JME*, pp. 87–96, Oct. 2022, doi: 10.35508/jme.v0i0.8131.
- [3] M. F. K. Sitorus, R. A. Yuzakhri, H. Alfianza, and D. J. Sinaga, "Evaluasi Kondisi Tahanan Isolasi House Service Transformer Pada Power Station PLTA Peusangan," *JIPM*, pp. 235-242, Dec. 2025, doi: <https://doi.org/10.61722/jipm.v3i6.1637>.
- [4] T. Salameh, Björk, R., Abdelkareem, M. A., and Olabi, A. G., "Detecting the faults of solar photovoltaic modules due to temperature and shading effects using convolutional neural networks," *International Journal of Thermofluids*, 22, 2024, 100643. <https://doi.org/10.1016/j.ijft.2024.100643>.
- [5] IEA-PVPS, "Trends in Photovoltaic Applications 2022. International Energy Agency Photovoltaic Power Systems Programme," 2022.
- [6] T. Salameh, R. Björk, M. A. Abdelkareem, and A. G. Olabi, "Detecting the faults of solar photovoltaic module due to the temperature and shading effect by convolutional neural network," *International Journal of Thermofluids*, vol. 22, p. 100643, May 2024, doi: 10.1016/j.ijft.2024.100643.
- [7] R. G. R. Rajalakshmi, D. S. Manish, and R. N. A., "Fusion-Solar-Net for Solar Panel Fault Detection," *Results in Engineering*, vol. 27, p. 106513, Sep. 2025, doi: 10.1016/j.rineng.2025.106513.
- [8] K. Masita, Hasan, A., Shongwe, T., and Hilal, H. A., "Deep learning in defects detection of PV modules: A review," *Solar Energy Advances*, 5, 100090, 2025, <https://doi.org/10.1016/j.seja.2025.100090>.
- [9] Afis Julianto, Andi Sunyoto, and Ferry Wahyu Wibowo, "Optimasi Hyperparameter Convolutional Neural Network Untuk Klasifikasi Penyakit Tanaman Padi," *teknimedia*, vol. 3, no. 2, pp. 98–105, Dec. 2022, doi: 10.46764/teknimedia.v3i2.77.
- [10] A. Oulefki et al., "Detection and analysis of deteriorated areas in solar PV modules using unsupervised sensing algorithms and 3D augmented reality," *Heliyon*, vol. 10, no. 6, p. e27973, Mar. 2024, doi: 10.1016/j.heliyon.2024.e27973.
- [11] D. I. Al Huneidi, F. Tahir, and Sami G. Al-Ghamdi, "Energy Modeling and Photovoltaics Integration as A Mitigation Measure for Climate Change Impacts on Energy Demand," 2022, *Energy Reports*, Vol. 8, <https://doi.org/10.1016/j.egy.2022.01.105>.
- [12] C. O. Mangatur, I N. Setiawan, I N. S. Kumara, "Studi Potensi dan Perancangan PLTS Apung di Danau Batur Guna Mendukung Bali Clean Energy," *SPEKTRUM*, vol. 10, no. 4, Dec. 2023.
- [13] Ahmad Fariz Fuady, Dwiky Oldi Amsyah, Muhammad Farhan, Rusma Rihsyah, and M. Dayyan Dhiyaul Haq, "Implementasi Algoritma Convolutional Neural Network (CNN) untuk Pengenalan dan Klasifikasi Buah Berdasarkan Citra Digital," *JUPIKOM*, vol. 4, no. 2, pp. 148–159, May 2025, doi: 10.55606/jupikom.v4i2.4116.
- [14] A. N. Faisal and A. S. Nuran, "Optimalisasi Deteksi Kerusakan Elektrikal Panel Surya dengan Transfer Learning dan Augmentasi Terkontrol berbasis YOLOv8", *Micronic*, vol. 3, issue 1, Jun. 2025, doi: 10.61220/912s5p11.
- [15] A. Mufidatuzzainiya, and M. Faisal, "Penggunaan Teknik Transfer Learning pada Metode CNN untuk Pengenalan Tanaman Bunga," *JISKA*, vol. 10, no. 2, May. 2025.
- [16] D. Husen, "Evaluasi Teknik Augmentasi Data untuk Klasifikasi Tumor Otak Menggunakan CNN Pada Citra MRI," *teknimedia*, vol. 5, no. 2, Dec. 2024, doi: 10.46764/teknimedia.v5i2.220
- [17] S. R. Joshua, K. Y. Palilingan, S. P. Lengkong, and S. Park, "Deep Learning-Driven Solar Fault Detection in Solar-Hydrogen AIoT Systems: Implementing CNN VGG16, ResNet-50, DenseNet121, and EfficientNetB0 in a University-Based Framework," *Hydrogen*, vol. 7, no. 1, p. 1, Dec. 2025, doi: 10.3390/hydrogen7010001.
- [18] K. Masita, A. Hasan, T. Shongwe, and H. A. Hilal, "Deep Learning in Defects Detection of PV Modules: A review," *Solar Energy Advances*, vol. 5, p. 100090, 2025, doi: 10.1016/j.seja.2025.100090.
- [19] F. Salim, F. Saeed, S. Basurra, S. N. Qasem, and T. Al-Hadhrani, "DenseNet-201 and Xception Pre-Trained Deep Learning Models for Fruit Recognition," *Electronics*, vol. 12, no. 14, p. 3132, Jul. 2023, doi: 10.3390/electronics12143132.
- [20] Prasetya, B. Hanggara, R. Naufaldihanif, A. C. P. Wijaya, Fathoni, and A. Ibrahim, "Klasifikasi Kondisi Kebersihan Sungai Dari Citra Digital Menggunakan Convolutional Neural Network Dengan Algoritma Inception V3 Dan Xception," *JATI*, .
- [21] Jimmy Pratama, Bayu Syahputra, and Febby Anggellya, "Visualisasi Struktur Organ Anatomi Hewan Ternak Berbasis Augmented Reality," *teknimedia*, vol. 6, no. 1, pp. 36–43, Jun. 2025, doi: 10.46764/teknimedia.v6i1.239.
- [22] M. Saldila, R. K. Dinata, and Said Fadlan Anshari, "Implementasi Augmented Reality untuk Pengenalan Tanaman Toga Menggunakan Metode Convolutional Neural Network," *RABIT*, vol. 11, no. 1, pp. 19-31, Jan 2026, doi: 10.36341/rabit.v11i1.6602.
- [23] M. I. Sa'ad, and H. Pratiwi, "Deteksi Marker Augmented Reality dalam Pengenalan Batik Kalimantan Timur menggunakan Algoritma Convolutional Neural Networks (CNNs)," *MIND*, vol. 9, no. 1, pp. 89-98, Jun 2024, doi: 10.26760/mindjournal.v1i1.49
- [24] Nadzifah Nadzifah, Suprih Widodo, and Nuur Wachid Abdul Majid, "Pengembangan Media Pembelajaran Pengenalan Buah dengan Teknologi Augmented Reality Menggunakan Metode Multimedia Develop Ment Life Cycle," *teknimedia*, vol. 3, no. 1, pp. 1–9, Jun. 2022, doi: 10.46764/teknimedia.v3i1.56.
- [25] Y. Cahyaningrum, "Integrasi Augmented Reality dan Artificial Intelligence untuk Visualisasi Produk sebagai Strategi Inovatif," *Jurnal Pustaka Data*, vol. 5, no. 1, pp. 200–204, Jun. 2025, doi: 10.55382/jurnalpustakadata.v5i1.1004.

- [26] P. Paryanto, R. D. Surya, and R. Rusnaldy, “Prototyping Smart Maintenance System Berbasis Augmented Reality Untuk Steam Turbine Di PLTP,” *Rot.*, vol. 25, no. 4, pp. 31–42, Oct. 2023, doi: 10.14710/rotasi.25.4.31-42.
- [27] Ali, M., R., M., Nuraeni P., & Kuswanto H., “Tinjauan Literatur Sistematis: Penggunaan Teknologi Augmented Reality (AR) Pada Pembelajaran Fisika”, *Jurnal Riset Pendidikan Fisika*, Vol. 09, No. 1, Hal. 08-16. 2024.
- [28] N. Nurrisma, “Perancangan Media Augmented Reality dalam Pembelajaran Mengenal Hardware Dasar pada Multimedia,” *teknimedia*, vol. 6, no. 2, pp. 254–268, Dec. 2025, doi: 10.46764/teknimedia.v6i2.326.
- [29] Rizky Arya Kurniawan, A. Sunyoto, and A. Nasiri, “Pengaruh Arsitektur Convolutional Neural Network untuk Klasifikasi Penyakit Daun Tomat,” *teknimedia*, vol. 4, no. 2, pp. 126–131, Dec. 2023, doi: 10.46764/teknimedia.v4i2.111.
- [30] D. Cortes, B. Bermejo, and C. Juiz, “The use of CNNs in VR/AR/MR/XR: a systematic literature review,” *Virtual Reality*, vol. 28, no. 3, Aug. 2024, doi: 10.1007/s10055-024-01044-6.