



Optimalisasi Deteksi Kerusakan Elektrikal Panel Surya dengan Transfer Learning dan Augmentasi Terkontrol berbasis YOLOv8

¹Andi Nur Faisal, ^{2*}Andi Shridivia Nuran

^{1,2}Jurusan Pendidikan Teknik Elektro, Fakultas Teknik, Universitas Negeri Makassar, Indonesia

Email: andi.nur.faisal@unm.ac.id¹, andi.shridivia.nuran@unm.ac.id².

*Corresponding author: andi.shridivia.nuran@unm.ac.id²

ABSTRAK

Deteksi kerusakan elektrikal pada panel surya merupakan tantangan penting dalam menjaga efisiensi sistem energi fotovoltaik skala besar. Studi ini merancang model pengklasifikasi yang bekerja secara otomatis berbasis *deep learning* dengan memanfaatkan arsitektur YOLOv8-CLS yang dioptimalkan melalui *transfer learning* dan augmentasi data terkontrol. Dataset terdiri atas dua kelas kondisi panel, yaitu *clean* dan *electrical-damage*, yang telah melalui proses pra-pemrosesan mencakup normalisasi ukuran citra, transformasi tensor, serta augmentasi berbasis *RandAugment* dan *random erasing*. Model dilatih selama 15 epoch dengan pendekatan *fine-tuning* pada bagian *head*, sementara *backbone* mempertahankan bobot pralatih. Evaluasi performa menunjukkan bahwa model mencapai akurasi *Top-1* sebesar 98,21%, dengan *precision* untuk kelas *electrical-damage* mencapai 100%, *recall* sebesar 94,12%, dan *F₁-score* sebesar 0,9697. Selain itu, waktu inferensi rata-rata sebesar 18,82 ms per citra mengindikasikan efisiensi tinggi dalam pemrosesan *real-time*. Temuan ini menunjukkan bahwa integrasi arsitektur YOLOv8 dengan *transfer learning* dan augmentasi terkontrol efektif untuk deteksi kerusakan elektrikal, serta layak diimplementasikan dalam sistem pemantauan otomatis berbasis *edge* maupun *cloud*.

Kata Kunci: YOLOv8-CLS, Transfer Learning, Augmentasi Citra, Panel Surya, Klasifikasi Citra

ABSTRACT

Electrical fault detection in solar panels is a critical challenge in maintaining the efficiency of large-scale photovoltaic energy systems. This research develops a deep learning-based automated classification model by leveraging the YOLOv8-CLS architecture, refined through transfer learning and systematically applied data augmentation. The dataset consists of two panel condition classes, clean and electrical-damage, which were preprocessed through image size normalization, tensor transformation, and augmentation using RandAugment and random erasing. The model was trained for 15 epochs with fine-tuning applied to the head, while the backbone retained pretrained weights. Performance evaluation showed that the model achieved a Top-1 Accuracy of 98.21%, with precision for the electrical-damage class reaching 100%, recall at 94.12%, and an F₁-score of 0.9697. Furthermore, an average inference time of 18.82 milliseconds per image demonstrates high computational efficiency for real-time deployment. These findings indicate that the integration of the YOLOv8 architecture with transfer learning and controlled augmentation is effective for detecting electrical faults in solar panels and is suitable for implementation in automated monitoring systems based on edge or cloud computing.

Keywords: YOLOv8-CLS, Transfer Learning, Image Augmentation, Solar Panel, Image Classification

1. PENDAHULUAN

Perkembangan teknologi fotovoltaik (PV) sebagai sumber energi terbarukan telah mengalami pertumbuhan eksponensial dalam dekade terakhir, dengan kapasitas global mencapai 1,6 TW setelah lonjakan instalasi sebesar 87% pada tahun 2023 (Balkan Green Energy News, 2024). Sistem panel surya menjadi komponen krusial dalam transisi energi global ke arah pemanfaatan energi yang berkelanjutan dan yang juga ramah lingkungan. Efektivitas kinerja modul fotovoltaik sangat ditentukan oleh kondisi fisik dan elektrikal yang optimal dimana kerusakan atau cacat pada panel dapat menyebabkan penurunan signifikan dalam produksi energi, peningkatan biaya operasional, dan percepatan degradasi sistem secara keseluruhan (Setiawan & Fathurrahman, 2025). Mengingat skala instalasi panel surya yang mencapai ratusan ribu unit dalam satu farm energi, kebutuhan akan sistem deteksi kerusakan yang otomatis, akurat, dan efisien menjadi sangat mendesak untuk memastikan keberlanjutan operasional sistem energi terbarukan.

Deteksi kerusakan elektrikal pada panel surya secara manual melalui inspeksi visual konvensional memiliki keterbatasan signifikan dalam hal efisiensi waktu, akurasi deteksi, dan skalabilitas untuk instalasi besar (Basheer et al., 2024). Berbagai jenis kerusakan elektrikal seperti microcracks, delaminasi, hot spots, dan degradasi material seringkali tidak dapat dideteksi secara kasat mata atau memerlukan peralatan khusus seperti termografi inframerah



atau elektroluminesensi (Pan et al., 2024). Pendekatan manual juga rentan terhadap human error dan inkonsistensi dalam interpretasi hasil, serta membutuhkan tenaga ahli yang berpengalaman dalam jumlah besar (Joshua et al., 2024). Keterbatasan ini mendorong pengembangan sistem deteksi otomatis yang dapat mengidentifikasi kerusakan secara real-time dengan tingkat akurasi tinggi dan biaya operasional yang rendah untuk mendukung pemeliharaan prediktif pada instalasi panel surya skala besar.

Kemajuan dalam bidang pembelajaran mendalam (deep learning) dan computer vision telah membuka peluang besar untuk mengotomatisasi deteksi kerusakan pada panel surya dengan tingkat akurasi yang tinggi (Mohamed Ameerudin et al., 2024). Arsitektur Convolutional Neural Networks (CNN) seperti ResNet telah terbukti efektif dalam ekstraksi fitur kompleks dari citra digital (He et al., 2016), sementara algoritma deteksi objek real-time seperti You Only Look Once (YOLO) versi 8 menunjukkan performa superior dalam kecepatan dan akurasi deteksi (Zhao, 2024). Transfer learning sebagai teknik pembelajaran yang memanfaatkan model pre-trained telah memungkinkan adaptasi model yang efisien untuk domain spesifik dengan dataset terbatas. Selain itu, teknik augmentasi data terkontrol, termasuk Generative Adversarial Networks (GAN), telah terbukti efektif dalam meningkatkan kualitas dan kuantitas data training untuk meningkatkan generalisasi model (Lekavičius & Gružauskas, 2024).

Meskipun berbagai penelitian telah mengeksplorasi penerapan deep learning untuk deteksi kerusakan panel surya, masih terdapat gap penelitian yang signifikan dalam optimalisasi kinerja model untuk deteksi kerusakan elektrik spesifik dengan mengintegrasikan transfer learning dan augmentasi data terkontrol berbasis YOLOv8 (Joshua et al., 2024). Penelitian sebelumnya umumnya fokus pada deteksi kerusakan fisik umum seperti retak permukaan atau deformasi struktural, atau menggunakan arsitektur *neural network* yang lebih sederhana tanpa memanfaatkan potensi penuh dari teknik transfer learning dan augmentasi data yang canggih (Basheer et al., 2024). Keterbatasan ini mengakibatkan kurangnya sistem yang dapat secara spesifik mendeteksi kerusakan elektrik seperti hot spots, degradasi sel, atau gangguan konduktivitas yang memerlukan analisis fitur yang lebih kompleks dan representasi data yang lebih kaya.

Sebagai respons terhadap permasalahan tersebut, studi ini difokuskan pada perancangan sistem deteksi kerusakan elektrik pada panel surya yang optimal dengan mengintegrasikan arsitektur YOLOv8 sebagai tulang punggung deteksi, teknik transfer learning untuk memanfaatkan pengetahuan dari model yang telah dilatih sebelumnya, serta implementasi augmentasi data terkontrol untuk meningkatkan generalisasi model. Sistem yang dikembangkan dirancang untuk mencapai akurasi deteksi yang unggul dengan efisiensi komputasi yang tinggi, sehingga dapat diimplementasikan dalam sistem pemantauan real-time untuk instalasi panel surya skala komersial. Pendekatan ini diantisipasi mampu memberikan peran yang berarti dalam memperkuat keandalan deteksi kerusakan elektrik dan mendukung pemeliharaan prediktif yang lebih efektif pada sistem fotovoltaik.

2. METODE PENELITIAN

Penelitian ini difokuskan pada upaya untuk membangun sistem klasifikasi kondisi panel surya berdasarkan citra visual menggunakan pendekatan *deep learning*. Model yang dikembangkan menggunakan arsitektur YOLOv8-CLS yang dikombinasikan dengan teknik *transfer learning* untuk mengoptimalkan proses pelatihan dengan data terbatas. Penelitian ini berfokus pada dua kelas utama kondisi panel surya, yaitu *clean* dan *electrical-damage*. Sistem yang dirancang diharapkan mampu mengidentifikasi kondisi tersebut dengan cepat dan akurat melalui citra yang telah diproses dan dilatih menggunakan model klasifikasi terkini.

YOLOv8 dipilih karena keunggulannya dalam efisiensi komputasi dan akurasi tinggi dalam tugas klasifikasi citra. Versi klasifikasi dari YOLOv8, yaitu YOLOv8-CLS, mendukung pelatihan model dengan struktur dataset yang sederhana namun fleksibel, serta memberikan dukungan penuh terhadap *transfer learning*. Seluruh proses penelitian dibangun secara sistematis, dimulai dari pra-pemrosesan data, pembagian dataset, pelatihan model, hingga evaluasi awal terhadap performa model berdasarkan arsitektur serta data yang digunakan.

2.1 Akuisisi Data

Pada tahap awal penelitian ini, data dikumpulkan dengan fokus pada citra panel surya yang diperoleh dari dataset publik yang tersedia di platform Kaggle. Dataset tersebut berjudul "Solar Panel Images Clean and Faulty Images" dan mencakup enam kategori kerusakan yang menggambarkan berbagai kondisi permukaan panel surya, yaitu *clean*, *dusty*, *bird-drop*, *electrical-damage*, *physical-damage*, dan *snow-covered*. Dataset ini terdiri dari lebih dari 870 citra yang dikumpulkan melalui *scraping* gambar dari internet, dan dirancang untuk mendukung pengembangan model *machine learning* dalam mendeteksi gangguan yang mempengaruhi kinerja panel surya. Dalam penelitian ini, eksperimen hanya menggunakan dua kelas, yaitu kelas normal (*clean*) dan *electrical-damage*. Pemilihan dua kelas ini didasarkan pada pertimbangan strategis: pertama, sebagai tahap awal,

pembatasan kelas memudahkan proses pelatihan dan evaluasi model secara terkendali; kedua, jumlah data untuk kelas *electrical-damage* relatif lebih sedikit dibandingkan kelas lain, sehingga penyederhanaan label diperlukan untuk mengurangi ketidakseimbangan data yang dapat menurunkan performa model. Dengan demikian, eksperimen ini juga bertujuan mengevaluasi efektivitas transfer learning dan augmentasi data dalam mengatasi keterbatasan data pada kelas minoritas.

Seluruh citra dari kedua kelas tersebut kemudian melalui proses kurasi awal untuk memastikan kualitas dan relevansi visual terhadap kondisi panel surya. Citra yang buram, duplikat, atau tidak representatif dihapus guna menjaga integritas dataset. Setelah seleksi, jumlah citra yang digunakan untuk pelatihan adalah 194 citra *clean* dan 104 citra *electrical-damage*. Meskipun terdapat ketimpangan jumlah, penggunaan augmentasi data dan model dengan bobot pralatih diharapkan dapat mengurangi potensi bias dalam klasifikasi. Dataset kemudian diorganisasi ke dalam dua subdirektori berdasarkan label kelas agar sesuai dengan format input ImageFolder dari pustaka *torchvision.datasets*.

2.2 Pra-Pemrosesan Data

Tahap awal dalam proses pelatihan model adalah transformasi data citra agar sesuai dengan format input model dan mendukung proses pelatihan yang efisien. Setiap citra panel surya yang dikumpulkan menjalani beberapa transformasi sebagai berikut:

- **Resize:** Semua citra RGB yang awalnya memiliki ukuran dan nama file acak diubah ukurannya menjadi resolusi tetap 128×128 piksel dengan format RGB ($128 \times 128 \times 3$). Proses ini dilakukan untuk menyeragamkan dimensi input dan menyederhanakan pemrosesan komputasi. Selain itu, nama file juga dinormalkan, misalnya dari *image1.jpg* menjadi *Clean_00001.png*, untuk mencerminkan kelas dan mempermudah pengelolaan dataset.
- **Random Horizontal Flip:** Augmentasi ini dilakukan secara acak dengan probabilitas 0.5, bertujuan meningkatkan keragaman data dan memperkecil kemungkinan *overfitting*.
- **ToTensor:** Citra dalam format PIL dikonversi ke bentuk tensor PyTorch, sehingga dapat diproses oleh model. Proses transformasi ini dirancang menggunakan pipeline dari *torchvision.transforms*. Setelah transformasi, data berada dalam bentuk tensor tiga dimensi (*channel, height, width*) yang siap untuk digunakan dalam pipeline pelatihan. Transformasi juga diterapkan secara otomatis saat pemuatan data melalui loader.

Selanjutnya, dataset dimuat dari direktori lokal menggunakan fungsi ImageFolder dari pustaka *torchvision.datasets*, yang mengenali label kelas berdasarkan nama subdirektori. Dataset terdiri dari dua kelas: *Clean*: citra panel surya dalam kondisi baik; dan, *Electrical-damage*: citra panel surya yang menunjukkan kerusakan elektrik.

Setelah dimuat, dataset dibagi secara acak menjadi tiga subset:

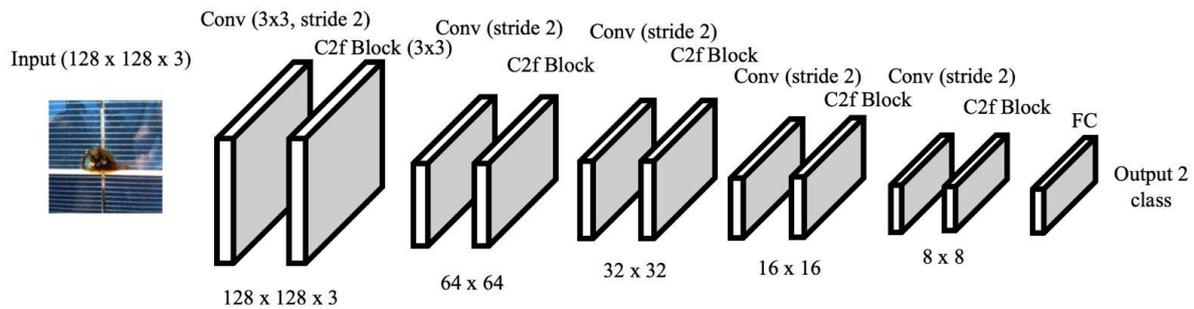
- **Train Set (70%):** Dialokasikan untuk proses pelatihan model.
- **Validation Set (20%):** Dialokasikan untuk mengevaluasi performa model selama proses pelatihan.
- **Test Set (10%):** Digunakan untuk evaluasi akhir menggunakan data yang sepenuhnya baru bagi model.

Pembagian dilakukan menggunakan fungsi *random_split* dari PyTorch, yang secara internal menggunakan *random seed* untuk menjamin distribusi acak yang konsisten. Setelah dibagi, citra dari masing-masing subset dikonversi kembali ke format gambar menggunakan *ToPILImage* dan disimpan dalam folder *train, val, dan test*.

2.3 Pelatihan Model

Pendekatan transfer learning menjadi strategi utama dalam proses pelatihan model pada penelitian ini. Model klasifikasi yang digunakan berbasis arsitektur YOLOv8-CLS, yang telah memperoleh bobot pralatih dari dataset berskala besar seperti ImageNet. Dengan pendekatan ini, pelatihan difokuskan hanya pada bagian akhir arsitektur (*head*), sedangkan bagian awal (*backbone*) dipertahankan tanpa perubahan untuk memanfaatkan kemampuan ekstraksi fitur yang telah dimiliki sebelumnya.

Seperti diperlihatkan pada Gambar 1, arsitektur YOLOv8-CLS menerima input berupa citra RGB berukuran $128 \times 128 \times 3$ yang kemudian diproses melalui serangkaian lapisan konvolusi berukuran 3×3 dengan *stride* 2. Setelah setiap konvolusi, diterapkan blok C2f (*Cross-Stage Partial Fusion*) untuk mempertahankan dan memperkaya informasi fitur. Proses ini menurunkan resolusi spasial citra secara bertahap dari 128×128 menjadi 8×8 , sambil meningkatkan kedalaman representasi fitur. Blok-blok ini berperan penting dalam mengekstraksi hierarki informasi visual yang kompleks dari citra panel surya. Di akhir jaringan, lapisan *fully connected* (FC) digunakan sebagai klasifikator untuk memetakan representasi fitur ke dalam dua kelas target, yaitu *clean* dan *electrical-damage*.



Gambar 1. Diagram Arsitektur YOLOv8-CLS

Seluruh arsitektur dilatih menggunakan optimisasi AdamW dengan jumlah epoch sebanyak 15, pemilihan AdamW sebagai optimizer didasarkan pada keunggulannya dalam mengatasi kelemahan Adam standar melalui *decoupled weight decay regularization*. Berbeda dengan Adam yang menggabungkan *weight decay* ke dalam *loss function* (menyebabkan interaksi negatif antara adaptivitas *learning rate* dan regularisasi), AdamW memisahkan langkah *weight decay* dari proses pembaruan gradien (Loshchilov & Hutter, 2019). Mampu menjaga kestabilan pembaruan parameter, mempercepat konvergensi, dan mencegah *overfitting* secara lebih efektif dibandingkan Adam standar, terutama dalam arsitektur deep learning modern seperti YOLOv8. Konfigurasi pelatihan meliputi:

- *Batch size*: 16 (optimal untuk GPU *mid-end*)
- *Dropout*: 0.2 (regularisasi tambahan)
- *Learning rate*: Tuning dinamis berbasis kinerja validation set
- *Augmentasi*: RandAugment dan random erasing 40% untuk meningkatkan variasi data

Pelatihan *end-to-end* dilakukan dengan mempertahankan bobot *backbone* sambil menyesuaikan parameter head. Strategi ini memanfaatkan fitur generik dari dataset besar sekaligus mengadaptasi pengetahuan ke domain spesifik panel surya.

2.4 Evaluasi Model

Setelah model selesai dilatih, dilakukan penyiapan komponen evaluasi untuk mengukur performa awal sistem klasifikasi. Evaluasi dirancang untuk menilai keakuratan prediksi, keandalan model, serta efisiensi proses secara keseluruhan. Metrik yang digunakan mencakup:

1. *Fitness Score*, metrik ini digunakan sebagai agregat performa klasifikasi berdasarkan akurasi top-1, yang merupakan persentase prediksi dengan keyakinan tertinggi (kelas top-1) yang sesuai dengan label sebenarnya. Dalam eksperimen ini, *fitness score* dihitung menggunakan:

$$\text{Fitness Score} = \text{Top} - 1 \text{ Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Dengan:

TN (True Negative): Jumlah data negatif yang diklasifikasikan dengan benar

FP (False Positive): Jumlah data negatif yang diklasifikasikan sebagai positif

FN (False Negative): Jumlah data positif yang diklasifikasikan sebagai negatif

TP (True Positive): Jumlah data positif yang diklasifikasikan dengan benar

2. *Precision*, *Recall*, dan *F₁-Score*. ketiga metrik ini digunakan untuk mengevaluasi ketepatan (*precision*), kelengkapan (*recall*), dan keseimbangan keduanya (*F₁-score*) khususnya pada kelas *electrical-damage* yang menjadi fokus utama. Nilai-nilai ini dihitung berdasarkan hasil confusion matrix sebagai berikut:

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

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

$$F_1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

3. Efisiensi Komputasi, pengukuran waktu pemrosesan, mulai dari *Preprocessing*, *Inference*, *Loss Calculation* dan *Postprocessing*.

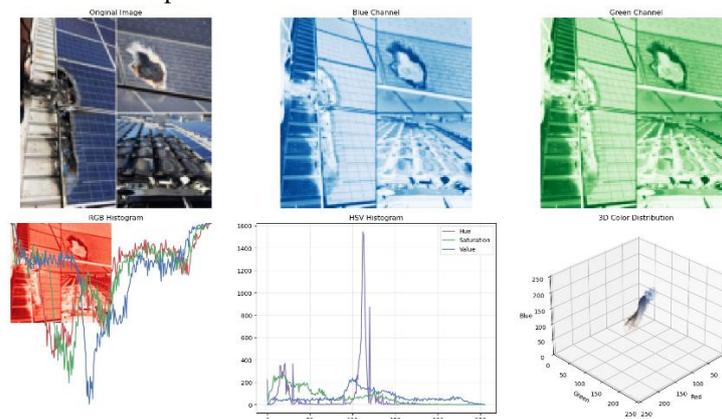
Evaluasi ini disiapkan untuk dapat memberikan gambaran performa awal model terhadap klasifikasi dua kelas.

3. HASIL DAN PEMBAHASAN

Bagian ini menguraikan temuan dari proses pelatihan dan evaluasi model klasifikasi YOLOv8-CLS yang digunakan untuk mengidentifikasi kondisi panel surya. Pembahasan dimulai dengan analisis visual terhadap data citra yang digunakan, guna memberikan konteks terhadap fitur-fitur visual yang relevan dengan kerusakan panel. Selanjutnya, hasil pelatihan dan evaluasi performa model diuraikan secara sistematis untuk menggambarkan kemampuan klasifikasi serta efisiensi komputasinya.

3.1 Analisis Visual Citra Panel Surya

Sebelum mengevaluasi performa model, penting untuk memahami karakteristik visual dari data citra yang digunakan. Panel surya yang mengalami kerusakan elektrik sering kali menunjukkan perbedaan intensitas warna, kontras, dan pola tekstur tertentu yang dapat dideteksi secara visual. Untuk itu, dilakukan eksplorasi awal terhadap kanal warna dan distribusi spektral citra.



Gambar 2. Analisis Kanal Warna dan Distribusi Warna

Gambar 2 memperlihatkan visualisasi kanal warna dan distribusi spektral dari citra panel surya yang rusak. Kanal biru menampilkan kontras yang tinggi pada area kerusakan, sedangkan kanal hijau memperlihatkan struktur permukaan panel. Histogram RGB dan HSV menunjukkan pola distribusi warna yang tidak merata, dengan dominasi spektrum biru dan penyimpangan kejenuhan yang mengindikasikan potensi anomali visual. Distribusi warna dalam ruang RGB 3D juga menunjukkan kluster dominan serta deviasi yang dapat diasosiasikan dengan kerusakan.

Analisis visual ini memperkuat asumsi bahwa informasi warna dan distribusi kanal merupakan fitur penting yang dapat dimanfaatkan oleh model untuk membedakan panel yang bersih dan yang mengalami kerusakan elektrik. Oleh karena itu, strategi augmentasi warna dan normalisasi pada tahap pra-pemrosesan menjadi langkah penting dalam membangun model klasifikasi yang andal.

3.2 Testing Data

Setelah proses pelatihan dan validasi selesai, model yang telah dilatih kemudian diuji pada data uji untuk mengevaluasi performanya terhadap citra yang tidak disertakan dalam proses pelatihan maupun validasi. Pengujian ini bertujuan untuk menilai kemampuan generalisasi model dalam mengklasifikasikan kondisi panel surya di luar data pelatihan, sekaligus mengidentifikasi potensi kesalahan prediksi yang mungkin terjadi dalam implementasi nyata.

Gambar 3 menyajikan sebagian hasil prediksi model terhadap data uji. Cuplikan ini diambil dari salah satu *batch* dalam proses pengujian dan bertujuan memberikan gambaran visual atas kualitas prediksi model. Label prediksi ditampilkan pada bagian atas setiap citra, sementara kotak berwarna merah menandai prediksi yang tidak sesuai dengan label sebenarnya (salah klasifikasi).



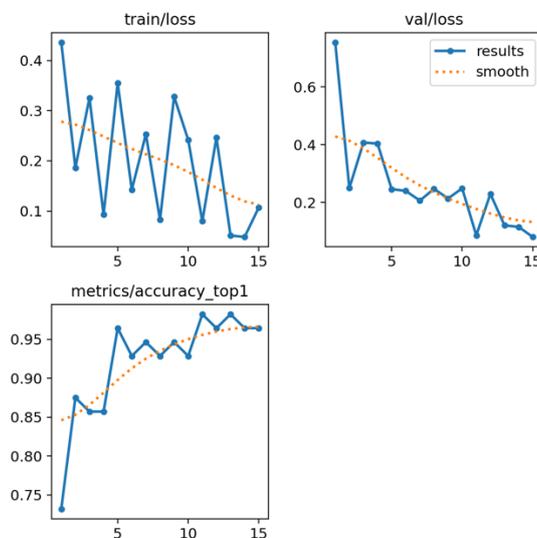
Gambar 3. Hasil Prediksi Model pada Data Uji

Dari hasil yang ditampilkan, terlihat bahwa sebagian besar citra diklasifikasikan secara akurat, baik ke dalam kelas *clean* maupun *electrical-damage*. Namun, terdapat satu kasus *false negative* (FN), yakni citra dengan kerusakan (area hangus) yang terklasifikasi sebagai *clean*. Kasus ini menunjukkan tantangan model dalam mengenali bentuk kerusakan tertentu yang secara tekstur menyerupai panel utuh.

Kesalahan semacam ini bisa diminimalkan dengan meningkatkan diversitas data pelatihan melalui augmentasi yang lebih kompleks atau dengan menambahkan data dari berbagai sumber visual kerusakan. Selain itu, pengujian visual ini juga bermanfaat dalam proses validasi manual, karena dapat membantu pengguna akhir atau inspektur teknis untuk melakukan *cross-check* terhadap hasil klasifikasi otomatis dengan kondisi citra sebenarnya.

3.3 Evaluasi Model

Proses pelatihan berlangsung selama 15 epoch. Gambar 4 menunjukkan grafik kurva metrik pelatihan yang mencakup loss, dan top-1 accuracy.



Gambar 4. Kurva Pelatihan dan Validasi Model

Selama pelatihan, terjadi penurunan loss yang konsisten pada data pelatihan dan validasi, dengan peningkatan akurasi yang stabil. Akurasi Top-1 meningkat signifikan sejak awal epoch dan stabil di atas 0.96 setelah epoch ke-10. Berdasarkan **Tabel 1**, terlihat bahwa terdapat perbedaan antara nilai *train loss* dan *val loss* pada beberapa epoch awal, misalnya pada epoch ke-3 dan ke-5. Perbedaan ini menunjukkan indikasi *overfitting* ringan, yaitu

keadaan ketika model menunjukkan kecenderungan untuk belajar terlalu spesifik terhadap pola dalam data pelatihan, namun belum sepenuhnya stabil pada data validasi. Meskipun demikian, perbedaan ini tidak signifikan dan mulai mengecil pada epoch akhir, menandakan proses pelatihan yang membaik seiring waktu.

Tabel 1. Proses Pelatihan per Epoch

Epoch	Train Loss	Val Loss	Top-1 Accuracy
1	0.436	0.754	0.732
2	0.186	0.249	0.875
3	0.325	0.407	0.857
4	0.092	0.404	0.857
5	0.355	0.246	0.964
6	0.142	0.240	0.928
7	0.253	0.206	0.946
8	0.082	0.247	0.928
9	0.328	0.213	0.946
10	0.241	0.248	0.928
11	0.079	0.086	0.982
12	0.246	0.229	0.964
13	0.051	0.120	0.982
14	0.048	0.115	0.964
15	0.107	0.080	0.964

Setelah proses pelatihan, dievaluasi pula nilai fitness sebagai metrik agregat yang mengukur performa keseluruhan model berdasarkan nilai *top-1 accuracy*. Berdasarkan hasil pelatihan, nilai *fitness score* dalam eksperimen ini mencapai 0.9821, yang dihitung berdasarkan rumus berikut:

$$\text{Accuracy}(\%) = \frac{TP + TN}{TP + TN + FP + FN} = \frac{16 + 39}{16 + 39 + 0 + 1} = \frac{55}{56} \approx 98.21\%$$

Selain akurasi, evaluasi performa model diperkuat dengan tiga metrik penting lainnya: precision, recall, dan F₁-score, khususnya untuk kelas *electrical-damage* yang menjadi fokus utama deteksi. Nilai precision sebesar 100% menunjukkan bahwa seluruh citra yang diprediksi sebagai *electrical-damage* merupakan citra yang mengalami kerusakan. Ini mengindikasikan bahwa model tidak menghasilkan false positif:

$$\text{Precision}(\%) = \frac{TP}{TP + FP} = \frac{16}{16 + 0} \approx 100\%$$

Sementara, nilai recall mencapai 94.12%, yang berarti model mendeteksi sebagian besar citra *electrical-damage*, namun masih terdapat satu kasus *false negatif*. Ini mengindikasikan bahwa masih ada kesulitan dalam mengidentifikasi beberapa jenis kerusakan yang tampak mirip dengan panel yang bersih. Tantangan ini sangat krusial untuk diatasi dalam sistem pemantauan, karena satu kerusakan yang terlewat dapat memberikan dampak besar terhadap kinerja dan efisiensi sistem secara keseluruhan:

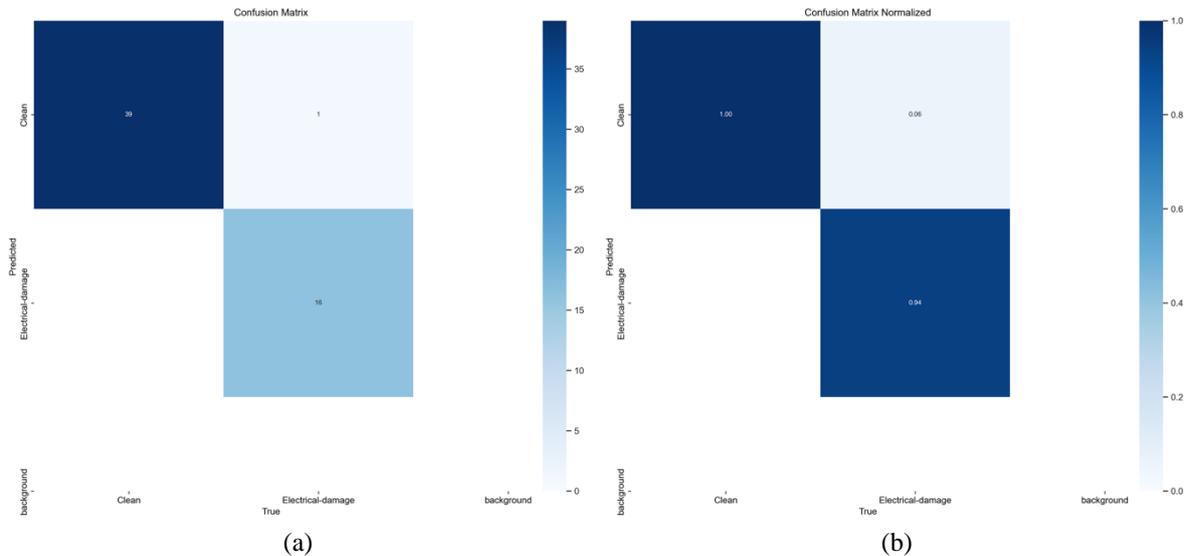
$$\text{Recall}(\%) = \frac{TP}{TP + FN} = \frac{16}{16 + 1} \approx 94.12\%$$

Sebagai metrik harmonisasi antara precision dan recall, nilai F₁-score dihitung untuk memberikan gambaran keseimbangan antara ketepatan dan kelengkapan deteksi. Nilai F₁-score sebesar 0,9697 memperkuat temuan bahwa performa model tidak hanya ditunjukkan melalui tingkat akurasi yang tinggi, tetapi juga seimbang dalam mengenali dan mengklasifikasikan kerusakan:

$$F_1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \approx 2 \times \frac{1.0 \times 0.9412}{1.0 + 0.9412} \approx 0.9697$$

Secara keseluruhan, hasil evaluasi ini menunjukkan bahwa model memiliki kemampuan generalisasi yang sangat baik dan kinerja klasifikasi yang seimbang sehingga layak diterapkan dalam sistem klasifikasi panel surya pada skenario nyata.

Evaluasi model lebih lanjut dilakukan menggunakan *confusion matrix* dan visualisasi prediksi. Gambar 4 dan 5 menunjukkan *confusion matrix* model dalam bentuk absolut dan normalisasi.



Gambar 5. Confusion Matrix (a) Absolut, (b) Ternormalisasi

Dari visualisasi tersebut, terlihat bahwa model mengklasifikasikan sebagian besar data dengan benar. Berdasarkan confusion matrix absolut Gambar 5.a, model menghasilkan 39 prediksi benar dan 0 salah untuk kelas 'clean', serta 16 prediksi benar dan 1 salah untuk kelas 'electrical-damage'. Artinya, terdapat satu kasus di mana model salah mengklasifikasikan citra berlabel 'electrical-damage' sebagai 'clean'. Confusion matrix ternormalisasi Gambar 5.b menunjukkan nilai prediksi benar sebesar 1.00 untuk kelas 'clean' dan 0.94 untuk kelas 'electrical-damage'. Hasil ini menunjukkan bahwa model memiliki akurasi klasifikasi sebesar 98.18% terhadap seluruh data validasi, dengan distribusi prediksi yang relatif seimbang dan kesalahan klasifikasi yang minimal.

Proses pelatihan model juga menunjukkan efisiensi komputasi yang tinggi. Evaluasi terhadap kecepatan proses mencakup empat komponen utama:

- *Preprocessing Time*: sebesar 0.00091 detik per citra, menunjukkan bahwa transformasi awal data berjalan sangat cepat.
- *Inference Time*: sebesar 18.82 milidetik per citra, menggambarkan kecepatan prediksi model yang cukup tinggi dan berpotensi diterapkan dalam sistem pemantauan waktu nyata.
- *Loss Calculation Time*: sekitar 0.00005 detik per citra, menunjukkan efisiensi dalam evaluasi kesalahan selama pelatihan.
- *Postprocessing Time*: sekitar 0.0003 detik per citra, menandakan kecepatan proses akhir setelah prediksi dilakukan.

Nilai-nilai ini memperlihatkan bahwa model tidak hanya akurat dan andal dalam klasifikasi, tetapi juga efisien secara komputasi, sehingga mendukung penerapannya dalam sistem nyata berbasis *edge* maupun *cloud*.

4. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan sistem klasifikasi otomatis untuk mendeteksi kerusakan elektrikal pada panel surya menggunakan arsitektur YOLOv8-CLS. Model dioptimalkan melalui pendekatan *transfer learning* dan augmentasi data terkontrol, memungkinkan pelatihan efisien meskipun dengan data domain-spesifik yang terbatas. Hasil evaluasi menunjukkan bahwa model mencapai akurasi *Top-1* sebesar 98,21%, disertai *precision* sebesar 100%, *recall* sebesar 94,12%, dan *F1-score* sebesar 0,9697 untuk kelas *electrical-damage*. Selain itu, waktu inferensi rata-rata sebesar 18,82 ms per citra menunjukkan efisiensi komputasi yang tinggi, sehingga model layak diterapkan dalam sistem pemantauan waktu nyata baik pada *edge device* maupun *cloud platform*.



Keandalan model ditunjang oleh pipeline pra-pemrosesan yang sistematis dan strategi augmentasi seperti *RandAugment* dan *random erasing* yang mampu meningkatkan keragaman data latih. Evaluasi melalui *confusion matrix* memperlihatkan distribusi prediksi antar kelas yang cukup seimbang. Namun, masih terdapat tantangan dalam mengklasifikasikan citra kerusakan dengan karakteristik visual yang menyerupai panel bersih. Temuan ini menekankan pentingnya peningkatan diversitas citra latih dan kompleksitas augmentasi untuk memperkuat kemampuan generalisasi model terhadap variasi kerusakan di lapangan.

Ke depan, penelitian ini menyarankan perluasan dataset melalui kolaborasi atau data sintetis (misalnya Generative Adversarial Networks), eksplorasi teknik augmentasi lanjutan seperti *mixup* dan *cutmix*, serta uji lapangan dalam kondisi pencahayaan dan lokasi berbeda. Integrasi dengan modul segmentasi atau multi-label detection juga dapat memperkaya diagnosis kerusakan panel secara lebih detail.

Sebagai langkah awal, pendekatan dua kelas dalam penelitian ini digunakan untuk menguji efektivitas dasar arsitektur YOLOv8-CLS sebelum dikembangkan lebih lanjut. Tahapan ini penting dalam mengontrol kompleksitas sistem serta menjaga kestabilan performa model selama pengembangan. Di masa mendatang, pengklasifikasian dapat diperluas ke kelas-kelas tambahan seperti *dusty*, *bird-drop*, dan *physical-damage* guna membangun model klasifikasi yang lebih umum, aplikatif, dan responsif terhadap kerusakan panel surya di lingkungan nyata.

Dengan pendekatan ini, sistem yang dihasilkan berpotensi besar mendukung efisiensi pemeliharaan prediktif pada instalasi fotovoltaik skala besar dan berkontribusi pada keberlanjutan energi terbarukan.

REFERENSI

- Balkan Green Energy News. (2024, June 19). *Global solar power capacity hits 1.6 TW after 87% surge in new installations in 2023*.
- Basheer, M. Y. I., Ali, A. M., Hamid, N. H. A., & Yusoff, M. Z. M. (2024). *Solar Panel Defect Detection and Panel Localization Using Yolov5* (pp. 139–149). Proceedings of the International Conference on Innovation & Entrepreneurship in Computing, Engineering & Science Education (InvENT 2024). https://doi.org/10.2991/978-94-6463-589-8_15
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-December*. <https://doi.org/10.1109/CVPR.2016.90>
- Joshua, S. R., Park, S., & Kwon, K. (2024). Solar Panel Fault Detection: Applying Convolutional Neural Network for Advanced Fault Detection in Solar-Hydrogen System at University. *Proceedings - 2024 IEEE 24th International Conference on Software Quality, Reliability and Security Companion, QRS-C 2024*, 289–298. <https://doi.org/10.1109/QRS-C63300.2024.00045>
- Lekavičius, J., & Gružas, V. (2024). Data Augmentation with Generative Adversarial Network for Solar Panel Segmentation from Remote Sensing Images. *Energies*, 17(13). <https://doi.org/10.3390/en17133204>
- Loshchilov, I., & Hutter, F. (2019). Decoupled weight decay regularization. *7th International Conference on Learning Representations, ICLR 2019*.
- Mohamed Ameerudin, M. I., Jamaluddin, M. H., Shukor, A. Z., & Mohamad, S. (2024). A Review of Deep Learning-Based Defect Detection and Panel Localization for Photovoltaic Panel Surveillance System. *International Journal of Robotics and Control Systems*, 4(4), 1746–1771. <https://doi.org/10.31763/ijrcs.v4i4.1579>
- Pan, W., Sun, X., Wang, Y., Cao, Y., Lang, Y., & Qian, Y. (2024). Enhanced photovoltaic panel defect detection via adaptive complementary fusion in YOLO-ACF. *Scientific Reports*, 14(1), 26425. <https://doi.org/10.1038/s41598-024-75772-9>



- Setiawan, E. A., & Fathurrahman, M. (2025). Exploring insights on deep learning-based photovoltaic fault detection for monofacial and bifacial modules using thermography. *International Journal of Cognitive Computing in Engineering*, 6, 495–507. <https://doi.org/10.1016/j.ijcce.2025.04.001>
- Zhao, N. (2024). Enhancing Object Detection with YOLOv8 Transfer Learning: A VOC2012 Dataset Study. *Proceedings of the 1st International Conference on Engineering Management, Information Technology and Intelligence*, 429–434. <https://doi.org/10.5220/0012939600004508>