

Deteksi Kerusakan Modul Surya Menggunakan *Faster R-CNN ResNet-50*

¹Fathirul Ikhsan, ^{2*}Rizqia Cahyaningtyas, ³Dwina Kuswardani

^{1,2,3}Teknik Informatika, Fakultas Telematika Energi, Institut Teknologi Perusahaan Listrik Negara
^{1,2,3}Menara PLN, Jl. Lkr. Luar Barat, Duri Kosambi, Cengkareng, Jakarta Barat, DKI Jakarta, Indonesia
¹fathirulikhsan@gmail.com, ²rizqia@itpln.ac.id, ³dwina@itpln.ac.id

Abstract

Solar modules play a crucial role in photovoltaic power generation systems, yet their performance can degrade due to physical and electrical damage. Therefore, automatic inspection is required to improve maintenance efficiency and prevent long-term performance loss. This study aims to implement an object detection approach for identifying solar module defects from visible RGB images using Faster R-CNN with a ResNet-50 backbone. The dataset was obtained from the Kaggle platform and manually annotated into PASCAL VOC format with two defect classes, namely physical damage and electrical damage, and expanded through data augmentation. The model was trained under several training configurations and evaluated using mean Average Precision (mAP), precision, recall, F1-score, and accuracy. The best performance was achieved using a batch size of 8, learning rate of 0.0001, and 30 epochs, resulting in 89% accuracy and 93% mAP. The results indicate that the model consistently detects both defect types and demonstrates potential for automated solar module inspection.

Keywords: Faster R-CNN, object detection, ResNet-50, RGB image, solar module defect detection.

Abstrak

Modul surya merupakan komponen utama pada sistem pembangkit listrik tenaga surya yang kinerjanya dapat menurun akibat kerusakan fisik (*physical damage*) maupun kerusakan listrik (*electrical damage*). Oleh karena itu diperlukan sistem inspeksi otomatis untuk meningkatkan efektivitas pemeliharaan dan mencegah penurunan performa jangka panjang. Penelitian ini bertujuan menerapkan pendekatan *object detection* untuk mendeteksi kerusakan modul surya dari citra visual (citra RGB) menggunakan *Faster R-CNN* dengan *backbone* ResNet-50. *Dataset* diperoleh dari *platform* Kaggle dan dianotasi manual dalam format PASCAL VOC dengan dua kelas kerusakan, yaitu *physical damage* dan *electrical damage*, serta diperluas melalui augmentasi data. Model dilatih menggunakan beberapa konfigurasi pelatihan dan dievaluasi menggunakan metrik *mean Average Precision* (mAP), *precision*, *recall*, *F1-score*, dan *accuracy*. Konfigurasi terbaik diperoleh pada *batch size* 8, *learning rate* 0.0001, dan 30 *epoch* dengan akurasi 89% dan mAP 93%. Hasil menunjukkan model mampu mendeteksi kedua jenis kerusakan secara konsisten dan memiliki potensi sebagai sistem inspeksi modul surya otomatis.

Kata Kunci: citra RGB, deteksi kerusakan modul surya, deteksi objek, *Faster R-CNN*, ResNet-50.

1. Pendahuluan

Pembangkit Listrik Tenaga Surya (PLTS) merupakan salah satu bentuk pemanfaatan energi terbarukan yang memanfaatkan radiasi matahari sebagai sumber utama dalam menghasilkan energi listrik. Proses ini melibatkan konversi energi cahaya menjadi energi

listrik oleh modul surya yang berfungsi mengubah sinar matahari secara langsung menjadi daya listrik. Seiring perkembangan teknologi, penerapan sistem PLTS terus meningkat karena energi surya tersedia melimpah, ramah lingkungan, serta tidak memerlukan biaya bahan bakar [1], [2]. Namun demikian, energi surya memiliki keterbatasan akibat ketergantungan pada intensitas radiasi matahari [3]. Selain itu, performa modul surya dapat menurun akibat berbagai faktor eksternal, seperti suhu operasi yang tinggi, akumulasi debu, bayangan, serta degradasi material akibat paparan radiasi ultraviolet dalam jangka panjang [4]. Di sisi lain, biaya pemeliharaan dan penggantian komponen yang mengalami kerusakan menjadi tantangan tersendiri, khususnya pada sistem berskala kecil dengan keterbatasan anggaran [5]. Kerusakan fisik, seperti retakan sel surya, pecahnya lapisan kaca pelindung, serta dampak hujan es, merupakan permasalahan yang sering dijumpai dan secara signifikan menurunkan kemampuan modul dalam menghasilkan energi listrik [6].

Proses pendeteksian kerusakan modul surya masih menghadapi kendala, khususnya karena beberapa jenis kerusakan, seperti retakan mikro, *hotspot*, maupun degradasi material, tidak selalu dapat diamati secara langsung dari permukaan modul. Metode inspeksi manual membutuhkan waktu, biaya, dan sumber daya manusia yang relatif besar, terutama pada instalasi modul surya dengan skala luas. Kondisi ini menyebabkan kerusakan berskala kecil berpotensi terlewatkan, yang pada akhirnya dapat mengakibatkan penurunan kinerja modul secara bertahap dalam jangka panjang [7]. Oleh karena itu, diperlukan sistem deteksi otomatis yang mampu melakukan identifikasi kerusakan secara lebih cepat dan konsisten.

Perkembangan teknologi saat ini mendorong pemanfaatan *Artificial Intelligence* (AI) untuk mendeteksi kerusakan modul surya secara otomatis dengan tingkat ketelitian yang lebih tinggi. Pendekatan ini memungkinkan identifikasi *hotspot* maupun pola anomali pada permukaan modul secara lebih cepat dan efisien [8]. Berbagai penelitian menunjukkan bahwa pendekatan *deep learning* berbasis citra telah terbukti efektif dalam mengenali berbagai jenis kerusakan modul surya, seperti akumulasi debu, kotoran burung, retakan, hingga gangguan kelistrikan dengan akurasi tinggi [9], [10]. Pendekatan deteksi objek berbasis *deep learning*, khususnya dengan memanfaatkan *Convolutional Neural Network* (CNN), saat ini banyak diterapkan untuk pendeteksian kerusakan modul surya secara otomatis [11]. Pendekatan ini memungkinkan model untuk mempelajari fitur citra secara otomatis, mulai dari fitur tingkat rendah seperti tepi dan tekstur hingga fitur tingkat tinggi berupa bentuk serta pola yang lebih kompleks, sehingga mampu meningkatkan akurasi deteksi secara keseluruhan [12]. Namun, sebagian besar penelitian tersebut menggunakan metode klasifikasi citra atau citra elektroluminesensi/termografi [11], [12]. Pendekatan tersebut efektif untuk identifikasi jenis kerusakan, namun belum sepenuhnya sesuai untuk kebutuhan inspeksi lapangan berbasis kamera biasa karena tidak menunjukkan area kerusakan secara langsung pada citra visual (citra RGB). Oleh karena itu, masih diperlukan pendekatan deteksi berbasis citra visual yang mampu mengidentifikasi sekaligus melokalisasi area kerusakan tanpa memerlukan sensor khusus.

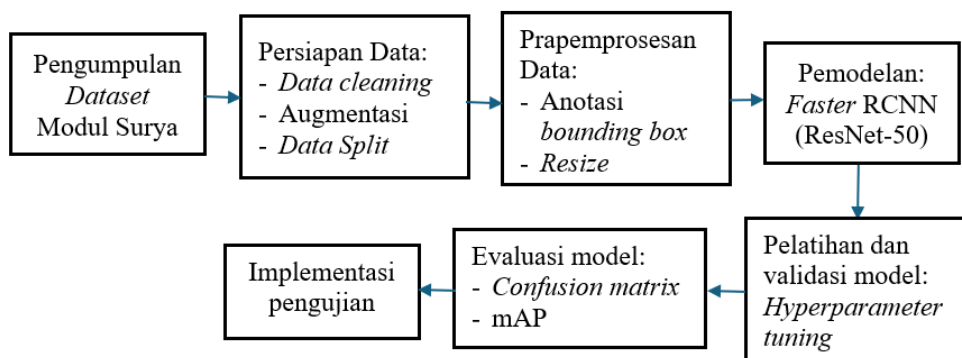
Pendekatan *object detection* memungkinkan model tidak hanya mengenali keberadaan kerusakan tetapi juga menentukan lokasi area kerusakan pada citra. Salah satu metode yang banyak digunakan adalah *Faster R-CNN* yang memiliki kemampuan mendeteksi objek kecil dan kompleks dengan akurasi tinggi [13], [14]. Penggunaan *backbone* ResNet-50 menunjukkan efisiensi komputasi yang baik sekaligus mempertahankan akurasi deteksi [15], [16]. Pada konteks deteksi cacat modul surya, *Faster R-CNN* dengan *backbone* ResNet-50 mampu mencapai nilai *mean Average Precision* (mAP) sebesar 67% dan presisi hingga 85.37% [13]. Keunggulan tersebut terutama berasal dari kemampuan *Faster R-CNN* dalam mendeteksi objek dengan ketelitian tinggi, khususnya pada area citra yang kompleks dan memiliki detail yang halus [13], [14]. Jika dibandingkan dengan metode lain seperti YOLO yang unggul dari sisi kecepatan, *Faster R-CNN* lebih menekankan ketelitian deteksi sehingga

sesuai untuk kebutuhan inspeksi kerusakan [17]. Pemilihan Faster R-CNN pada penelitian ini didasarkan pada karakteristik objek kerusakan modul surya yang berukuran kecil, memiliki bentuk tidak beraturan, dan sering muncul pada latar belakang yang kompleks. Metode deteksi satu tahap seperti YOLO lebih optimal pada kebutuhan *real-time*, sedangkan inspeksi kerusakan menuntut ketepatan lokalisasi objek. Oleh karena itu, pendekatan *two-stage detector* digunakan karena mampu menghasilkan *bounding box* yang lebih presisi pada objek kecil dibandingkan pendekatan *single-stage*. ResNet-50 juga terbukti efisien dari sisi waktu pemrosesan dan mampu mendeteksi objek kecil, terhalang, atau sulit diidentifikasi tanpa mengurangi akurasi [15]. Selain pada modul surya, kombinasi *Faster R-CNN* dan ResNet-50 juga efektif pada berbagai bidang deteksi kesalahan lainnya, misalnya pada deteksi *fault* data seismik dengan akurasi sekitar 90% [18].

Berdasarkan keterbatasan penelitian sebelumnya yang umumnya berfokus pada klasifikasi citra atau memanfaatkan citra elektroluminesensi/termografi, penelitian ini memberikan beberapa kontribusi. Penelitian ini menerapkan pendekatan deteksi objek berbasis *Faster R-CNN* dengan backbone ResNet-50 pada citra visual RGB untuk mengidentifikasi sekaligus melokalisasi kerusakan modul surya tanpa memerlukan sensor khusus. Selain itu, penelitian ini menganalisis pengaruh konfigurasi pelatihan, meliputi variasi pembagian data dan learning rate, terhadap kinerja deteksi menggunakan metrik klasifikasi dan metrik deteksi objek. Evaluasi dilakukan pada dua kategori kerusakan utama, yaitu *physical damage* dan *electrical damage*, sehingga memberikan dasar penggunaan model sebagai sistem inspeksi otomatis berbasis kamera visual.

2. Metode Penelitian

Tahapan penelitian untuk mendeteksi kerusakan pada permukaan modul surya menggunakan arsitektur *Faster R-CNN* dengan backbone ResNet-50 ditunjukkan pada Gambar 1. Penelitian terdiri dari beberapa tahap, yaitu pengumpulan *dataset*, persiapan data, prapemrosesan, pemodelan, pelatihan dan validasi model, evaluasi model, dan implementasi pengujian.



Gambar 1. Metode Penelitian

2.1 Pengumpulan *dataset*

Data penelitian bersumber dari platform Kaggle [19], yang berisi citra modul surya dengan berbagai jenis kerusakan. Total terdapat 885 citra yang mewakili beberapa kerusakan. Penelitian difokuskan pada dua jenis kerusakan utama, yaitu *physical damage* berupa retakan akibat benturan benda keras dan *electrical damage* berupa area terbakar pada permukaan modul surya. *Dataset* awal belum memiliki anotasi lokasi kerusakan, sehingga anotasi *bounding box* dilakukan pada tahap prapemrosesan.

2.2 Persiapan data

Pada tahap ini dilakukan proses persiapan *dataset* sebelum digunakan dalam pelatihan model. Langkah awal adalah pembersihan data (*data cleaning*) untuk memastikan hanya citra yang relevan, berkualitas baik, dan memiliki informasi kerusakan yang jelas yang digunakan.

Selanjutnya, untuk meningkatkan keberagaman data serta mengurangi risiko *overfitting*, diterapkan teknik augmentasi data [20], [21]. Teknik augmentasi yang digunakan meliputi rotasi, pembalikan (*flipping*), dan penyesuaian kontras. Sebagai langkah akhir, *dataset* dibagi menjadi tiga bagian, yaitu data latih (*training set*), data validasi (*validation set*), dan data uji (*testing set*) untuk memastikan proses pelatihan dan evaluasi model berlangsung secara terstruktur.

2.3 Prapemrosesan

Pada tahap ini dilakukan anotasi *bounding box* secara manual untuk menandai lokasi area kerusakan pada setiap citra berdasarkan dua kelas yang telah ditentukan, yaitu *physical damage* dan *electrical damage*. Proses anotasi menghasilkan *file* label dalam format PASCAL VOC yang digunakan sebagai masukan pada proses pelatihan model, serta digunakan untuk pembentukan *dataset* pelatihan, validasi, dan pengujian.

Selanjutnya, seluruh citra diubah ukurannya (*resize*) agar sesuai dengan kebutuhan *input* model *Faster R-CNN* dengan *backbone* ResNet-50. Penyeragaman dimensi citra ini bertujuan menjaga konsistensi masukan sehingga proses pelatihan dapat berlangsung lebih stabil dan optimal.

2.4 Pemodelan

Tahap ini merupakan inti penelitian, yaitu membangun model deteksi objek untuk mengidentifikasi kerusakan pada permukaan modul surya. Penelitian menggunakan arsitektur *Faster R-CNN* dengan *backbone* ResNet-50 yang berperan sebagai pengekstraksi fitur visual dari citra. Pemilihan *Faster R-CNN* dilakukan karena penelitian berfokus pada ketelitian lokalisasi area kerusakan pada citra visual, sehingga pendekatan *two-stage detector* dinilai lebih sesuai dibandingkan metode *one-stage detector* seperti YOLO yang lebih menekankan kecepatan deteksi. Model dikonfigurasi untuk mendeteksi dua kelas utama, yaitu *physical damage* dan *electrical damage*.

Gambar 2 menunjukkan alur kerja arsitektur *Faster R-CNN* yang digunakan. Proses pemodelan meliputi pemuatan *dataset*, penentuan arsitektur, penyesuaian parameter konfigurasi, serta pelatihan model menggunakan data latih yang telah disiapkan. Selanjutnya model yang telah dilatih dievaluasi pada tahap evaluasi menggunakan metrik mAP dan *confusion matrix*.


2.5 Pelatihan dan validasi model

Setelah konfigurasi arsitektur model ditetapkan, dilakukan proses pelatihan menggunakan *dataset* yang telah dipersiapkan. Proses pelatihan melibatkan pengaturan parameter pelatihan seperti *batch size*, *learning rate*, dan jumlah *epoch* agar model mampu mempelajari pola kerusakan secara optimal serta menghasilkan deteksi yang presisi.

Pada penelitian ini digunakan *epoch* sebanyak 30 dan *batch size* sebesar 8. Pengujian dilakukan melalui beberapa skenario percobaan dengan memvariasikan pembagian *dataset* serta nilai *learning rate*. Dua skema pembagian data digunakan, yaitu 80:10:10 dan 70:15:15 (data latih : data validasi : data uji). Pada masing-masing skema, dilakukan percobaan menggunakan dua nilai *learning rate*, yaitu 0,0001 dan 0,00001. Pengaturan ini bertujuan untuk menganalisis pengaruh konfigurasi pelatihan terhadap performa model *Faster R-CNN* ResNet-50 dalam mendeteksi dua kelas kerusakan, yaitu *physical damage* dan *electrical damage*.

Tabel 1. Konfigurasi Skenario Pelatihan Model *Faster R-CNN* ResNet-50

Percobaan	Pembagian data	Learning rate
1	80:10:10	0,0001
2		0,00001
3	70:15:15	0,0001
4		0,00001

Gambar 2. Tahap Pemodelan dan Evaluasi *Faster R-CNN* ResNet-50

2.6 Evaluasi model

Kinerja model dievaluasi menggunakan *confusion matrix* dan metrik klasifikasi yaitu akurasi, *precision*, *recall*, dan *F1-score* [22]–[24]. Rumus perhitungan dari metrik klasifikasi ditunjukkan pada Persamaan (1)–(4).

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

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

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

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

dengan:

- TP (*True Positive*): objek kerusakan pada kelas tertentu (*physical damage* atau *electrical damage*) yang terdeteksi dengan benar dan memiliki kecocokan lokasi ($IoU \geq threshold$)
- TN (*True Negative*): tidak digunakan secara dominan karena area latar belakang pada deteksi objek tidak terdefinisi secara eksplisit seperti pada klasifikasi citra.
- FP (*False Positive*): prediksi objek pada suatu kelas yang tidak sesuai dengan *ground truth* atau tidak memiliki pasangan objek sebenarnya
- FN (*False Negative*): objek kerusakan pada kelas tertentu yang ada pada *ground truth* tetapi tidak terdeteksi oleh model

Selain metrik klasifikasi, digunakan juga mAP [25] untuk mengevaluasi ketepatan prediksi *bounding box* terhadap objek sebenarnya dalam berbagai kondisi citra. Rumus perhitungan mAP ditunjukkan pada Persamaan (5) dan (6).

$$AP = \int_0^1 p(r) dr \quad (5)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (6)$$

dengan:

- $p(r)$: nilai *precision* pada tingkat *recall* tertentu
- AP (*Average Precision*): luas area di bawah kurva *precision–recall* untuk satu kelas objek
- N : jumlah kelas objek (pada penelitian ini $N = 2$)
- mAP: rata-rata nilai AP dari seluruh kelas objek

2.7 Implementasi pengujian

Model diuji menggunakan lingkungan Google Colab. Hasil deteksi divisualisasikan melalui antarmuka Gradio untuk menampilkan *bounding box* dan *confidence score* pada citra uji.

3. Hasil dan Pembahasan

Penelitian ini menerapkan algoritma *Faster R-CNN* dengan *backbone* ResNet-50 untuk mendeteksi dua jenis kerusakan modul surya, yaitu *physical damage* dan *electrical damage*. Evaluasi kinerja model dilakukan menggunakan metrik klasifikasi (*precision*, *recall*, *F1-score*, *accuracy*) dan metrik deteksi objek (mAP) [26].

3.1 Hasil

3.1.1 Hasil persiapan data

Tahap persiapan data meliputi proses pembersihan data (*data cleaning*), augmentasi data (*data augmentation*), serta pembagian data (*data splitting*). Pada tahap awal dilakukan pemeriksaan *dataset* dan ditemukan beberapa citra duplikat serta citra dengan objek kerusakan tidak terlihat jelas, sehingga dilakukan proses pembersihan data untuk mempertahankan hanya citra yang relevan. Sebelum pembersihan, jumlah citra pada kelas *physical damage* sebanyak 69 citra dan *electrical damage* sebanyak 103 citra. Setelah proses seleksi kualitas data, masing-masing kelas diseragamkan menjadi 50 citra guna mengurangi ketidakseimbangan kelas (*class imbalance*) yang berpotensi menyebabkan bias model.

Selanjutnya diterapkan *data augmentation* menggunakan rotasi, *flipping*, dan penyesuaian kontras untuk meningkatkan variasi data serta mengurangi risiko *overfitting*. Proses augmentasi meningkatkan jumlah citra dan label *bounding box* secara signifikan sehingga model memperoleh representasi pola kerusakan yang lebih beragam. Hasil proses *data augmentation* ditunjukkan pada Tabel 2. Setelah augmentasi, jumlah citra dan label

bounding box meningkat secara signifikan pada masing-masing kelas. Pada kelas *physical damage* jumlah citra meningkat dari 50 menjadi 329 citra dengan total 399 label, sedangkan pada kelas *electrical damage* meningkat menjadi 350 citra dengan 567 label. Peningkatan ini menunjukkan bahwa augmentasi berhasil memperkaya variasi pola kerusakan sehingga dapat membantu meningkatkan kemampuan generalisasi model.

Tabel 2. Jumlah Citra dan Label *Bounding Box* Setelah Proses Augmentasi

Kelas	Citra setelah <i>Cleaning</i>	Total Citra	Total Label
<i>Physical Damage</i>	50	329	399
<i>Electrical Damage</i>	50	350	567

Setelah proses augmentasi, *dataset* kemudian dibagi menjadi data pelatihan (*training*), validasi (*validation*), dan pengujian (*testing*). Penelitian ini menggunakan dua skenario pembagian data, yaitu 80:10:10 dan 70:15:15, untuk menganalisis pengaruh komposisi data terhadap kinerja model. Distribusi jumlah citra pada masing-masing skenario ditunjukkan pada Tabel 3.

Tabel 3. Distribusi Jumlah Citra pada Setiap Skema Pembagian Data

Kelas	Citra setelah <i>Cleaning</i>	Total Citra	Total Label
80:10:10	544	68	67
70:15:15	476	101	102

Berdasarkan Tabel 3, pada skenario 80:10:10, *dataset* terdiri dari 544 citra latih, 68 citra validasi, dan 67 citra uji. Sementara pada skenario 70:15:15 digunakan 476 citra latih, 101 citra validasi, dan 102 citra uji. Perbedaan proporsi ini digunakan untuk mengevaluasi stabilitas pembelajaran model terhadap variasi jumlah data pelatihan dan validasi.

3.1.2 Hasil prapemrosesan

Setelah proses *cleaning*, setiap citra dianotasi secara manual menggunakan *bounding box* untuk menandai area kerusakan berdasarkan dua kelas, yaitu *physical damage* dan *electrical damage*. Anotasi disimpan dalam format PASCAL VOC (.xml) dan digunakan sebagai masukan pada proses pelatihan model.

Pada kelas *physical damage* terdapat 47 citra dengan 57 label, sedangkan pada kelas *electrical damage* terdapat 50 citra dengan 81 label. Perbedaan jumlah citra dan label menunjukkan bahwa satu citra dapat mengandung lebih dari satu objek kerusakan sehingga diperlukan anotasi lokasi yang presisi agar model mampu mempelajari karakteristik objek secara tepat.

Seluruh citra kemudian diubah ukurannya menjadi 800×800 piksel agar sesuai dengan kebutuhan *input* arsitektur *Faster R-CNN* ResNet-50. Penyeragaman resolusi ini dilakukan untuk menjaga konsistensi dimensi masukan serta menstabilkan proses ekstraksi fitur selama pelatihan model.

3.1.3 Hasil pemodelan









Model dilatih selama 30 *epoch* dengan *batch size* 8 pada dua variasi pembagian data dan dua nilai *learning rate*. Ringkasan hasil pelatihan dan pengujian ditunjukkan pada Tabel 4.

Pada konfigurasi pembagian data 80:10:10 dengan *learning rate* 0.0001, nilai *total loss* menurun dari 0.3162 pada *epoch* pertama menjadi 0.0251 pada *epoch* ke-30. *Classification loss* berkurang dari 0.1524 menjadi 0.0079 dan *bounding-box loss* dari 0.1360 menjadi 0,0167. Hasil pengujian menunjukkan performa terbaik dengan *precision* 0.98, *recall* 1.00,

dan *F1-score* 0.99 pada kelas *physical damage*, serta *precision* 0.92, *recall* 0.89, dan *F1-score* 0.90 pada kelas *electrical damage* dengan akurasi 89%.

Pada *learning rate* 0.00001 dengan pembagian data yang sama, *total loss* menurun dari 0.3490 menjadi 0.0305. Nilai *F1-score* kelas *physical damage* sebesar 0.94 dan *electrical damage* sebesar 0.90 dengan akurasi 84%. Meskipun proses pelatihan stabil, performa pengujian lebih rendah dibanding *learning rate* 0.0001.

Tabel 4. Hasil Pelatihan dan Pengujian Model pada Setiap Konfigurasi

Pembagian Data	Learning rate	Hasil Pelatihan	Hasil Pengujian
80:10:10	0.0001		
80:10:10	0.00001		
70:15:15	0.0001		
70:15:15	0.00001		

Pada konfigurasi pembagian data 70:15:15 dengan *learning rate* 0.0001, *total loss* turun dari 0.3269 menjadi 0.0291. Nilai *F1-score* mencapai 0.93 untuk *physical damage* dan 0.90 untuk *electrical damage* dengan akurasi 84%. Sementara itu, pada *learning rate* 0.00001, *total loss* menurun dari 0.4060 menjadi 0.0369 dengan *F1-score* 0.88 untuk *physical damage* dan 0.92 untuk *electrical damage*, serta akurasi 83%.

Secara umum seluruh konfigurasi menunjukkan konvergensi pelatihan yang baik, ditandai dengan penurunan *classification loss* dan *bounding-box loss* pada setiap *epoch*. Namun, konfigurasi *learning rate* 0.0001 dengan pembagian data 80:10:10 menghasilkan performa pengujian paling tinggi dan stabil dibanding konfigurasi lainnya.

3.2 Pembahasan

Model *Faster R-CNN* dengan *backbone* ResNet-50 dilatih menggunakan citra berukuran 800×800 piksel selama 30 *epoch* dengan *batch size* 8. Variasi eksperimen dilakukan pada dua pembagian data (80:10:10 dan 70:15:15) serta dua nilai *learning rate* (0.0001 dan 0.00001). Ringkasan hasil evaluasi ditunjukkan pada Tabel 5, yang memperlihatkan pengaruh konfigurasi pelatihan terhadap kemampuan deteksi dan lokalisasi objek kerusakan.

Tabel 5. Perbandingan Kinerja Deteksi Model pada Setiap Konfigurasi Pelatihan

<i>Pembagian data</i>	<i>Learning rate</i>	<i>Accuracy</i>	<i>mAP</i>	<i>mAP@0.5</i>	<i>mAP@0.75</i>
80:10:10	0.0001	89%	93.15%	96.76%	85.21%
	0.00001	84%	86.83%	94.10%	70.88%
70:15:15	0.0001	84%	92.67%	97.10%	82.54%
	0.00001	83%	83.84%	94.98%	60.32%

Berdasarkan Tabel 5, konfigurasi *learning rate* 0.0001 dengan pembagian data 80:10:10 memberikan performa terbaik dengan akurasi 89% dan *mAP* 93.15%. Nilai *mAP@0.5* sebesar 96.76% menunjukkan model mampu mendeteksi objek secara konsisten, sedangkan *mAP@0.75* sebesar 85.21% menunjukkan kemampuan lokalisasi *bounding box* yang presisi. Hal ini menandakan model tidak hanya mengenali keberadaan kerusakan tetapi juga mampu menentukan posisi kerusakan dengan baik pada citra uji.


Pada *learning rate* yang lebih kecil (0.00001), performa model menurun menjadi akurasi 84% dan *mAP* 86.83%. Penurunan paling terlihat pada *mAP@0.75* (70.88%), yang menunjukkan kemampuan lokalisasi objek berkurang. Hasil ini mengindikasikan bahwa nilai *learning rate* terlalu kecil memperlambat proses pembelajaran sehingga model belum mencapai konvergensi optimal dalam jumlah *epoch* yang sama, walaupun deteksi objek secara umum masih cukup baik.

Pada pembagian data 70:15:15 dengan *learning rate* 0.0001 diperoleh akurasi 84% dan *mAP* 92.67%. Nilai *mAP@0.5* tetap tinggi (97.10%), menunjukkan objek masih terdeteksi dengan baik, namun *mAP@0.75* lebih rendah dibanding konfigurasi terbaik. Hal ini menunjukkan bahwa pengurangan proporsi data latih membatasi kemampuan model dalam mempelajari detail posisi objek sehingga presisi lokalisasi sedikit menurun.

Konfigurasi pembagian data 70:15:15 dengan *learning rate* 0.00001 menghasilkan performa terendah dengan akurasi 83% dan *mAP* 83.84%. Nilai *mAP@0.75* turun hingga 60.32% yang menunjukkan model kurang stabil dalam menentukan posisi *bounding box* secara presisi. Kombinasi data latih lebih sedikit dan *learning rate* rendah menyebabkan pembaruan bobot tidak optimal sehingga model belum mampu mempelajari karakteristik kerusakan secara detail.

Secara keseluruhan, kombinasi *batch size* 8, *learning rate* 0.0001, dan pembagian data 80:10:10 memberikan keseimbangan terbaik antara kemampuan klasifikasi dan lokalisasi

objek. Jumlah data latih yang lebih besar membantu model mempelajari variasi pola kerusakan lebih lengkap, sementara *learning rate* yang sesuai memungkinkan konvergensi tercapai dalam 30 *epoch* tanpa menyebabkan instabilitas pelatihan. Model kemudian diimplementasikan menggunakan antarmuka Gradio untuk menguji kemampuan deteksi pada citra uji seperti pada Gambar 3.



Gambar 3. Visualisasi Hasil Deteksi (a) *Physical Damage* (b) *Electrical Damage*

Pada Gambar 3(a) model mampu mendeteksi kerusakan dengan *confidence score* tinggi hingga 1.00, sedangkan pada Gambar 3(b) terdeteksi beberapa area kerusakan dengan *confidence score* 1.00, 0.99, dan 0.65. Variasi *confidence score* tersebut menunjukkan model tetap mampu mengenali objek meskipun tingkat keyakinannya berbeda tergantung kompleksitas pola kerusakan.

Implementasi ini menunjukkan bahwa *Faster R-CNN ResNet-50* tidak hanya menghasilkan performa evaluasi yang baik, tetapi juga dapat digunakan secara praktis sebagai sistem pendukung inspeksi kerusakan modul surya berbasis citra. Dengan demikian, model berpotensi membantu proses inspeksi lapangan secara lebih sistematis dibanding pemeriksaan visual manual.

4. Kesimpulan

Penelitian ini berhasil menerapkan metode deteksi objek *Faster R-CNN* dengan *backbone* ResNet-50 untuk mendeteksi dua jenis kerusakan modul surya, yaitu *physical damage* dan *electrical damage* pada citra visual. Hasil pengujian menunjukkan bahwa konfigurasi pelatihan berpengaruh terhadap kinerja deteksi, di mana performa terbaik diperoleh pada kombinasi parameter pelatihan *learning rate* 0.0001 dengan pembagian data 80:10:10 menggunakan *batch size* 8 selama 30 *epoch*.

Model mampu mendeteksi keberadaan objek sekaligus melokalisasi area kerusakan dengan tingkat ketelitian yang baik, yang ditunjukkan oleh nilai mAP tinggi pada berbagai ambang IoU. Hal ini menunjukkan bahwa pendekatan *object detection* efektif digunakan untuk inspeksi kerusakan modul surya berbasis citra visual.

Penelitian ini masih memiliki keterbatasan pada jumlah dan variasi *dataset* yang digunakan, serta hanya mencakup dua kategori kerusakan. Kondisi pencahayaan dan sudut pengambilan gambar yang relatif terbatas juga dapat mempengaruhi kemampuan generalisasi model pada kondisi lapangan yang lebih beragam.

Berdasarkan keterbatasan tersebut, penelitian selanjutnya dapat memperluas jenis kerusakan dan menggunakan *dataset* dengan kondisi lingkungan yang lebih variatif. Pengembangan juga dapat diarahkan pada penerapan arsitektur deteksi objek yang lebih ringan atau lebih adaptif, seperti YOLO atau EfficientDet, serta integrasi metode segmentasi seperti *Mask R-CNN* untuk memperoleh informasi area kerusakan yang lebih detail.

Ucapan Terima Kasih

Terima kasih kepada Institut Teknologi Perusahaan Listrik Negara yang memberikan dukungan pada penelitian ini.

Daftar Referensi

- [1] J. Sundah *et al.*, “Solar power generation system at household scale,” *Interdiscip. J. Adv. Res. Innov.*, vol. 2, no. 4, pp. 79–82, 2023, doi: 10.58860/ijari.v2i4.57.
- [2] G. Wang, Z. Zhang, and J. Lin, “Multi-energy complementary power systems based on solar energy: A review,” *Renew. Sustain. Energy Rev.*, vol. 199, p. 114464, Jul. 2024, doi: 10.1016/j.rser.2024.114464.
- [3] S. Gyamfi, B. Aboagye, M. Obeng, and F. Peprah, “Criticality and severity of adverse effects of the sun on performance of solar PV systems,” *Solar Energy Adv.*, vol. 4, p. 100058, 2024, doi: 10.1016/j.seja.2024.100058.
- [4] S. Fuad, I. Setiawan, and T. Andromeda, “Optimasi algoritma firefly pada maximum power point tracking (MPPT) saat kondisi panel surya terhalangi sebagian,” *Multitek Indones. J. Ilm.*, vol. 16, no. 1, pp. 21–36, Jul. 2022, doi: 10.24269/mtkind.v16i1.4844.
- [5] M. E. Emeter and S. A. Afolalu, “Challenges of small-scale standalone solar energy supply in parts of Lagos via 39 years dataset,” *E3S Web Conf.*, vol. 294, p. 01007, 2021, doi: 10.1051/e3sconf/202129401007.
- [6] A. M. Gabor, P. J. Knodle, M. Covino, J. Fioresi, D. J. Colvin, and K. O. Davis, “Electroluminescence analysis and grading of hail damaged solar panels,” *IEEE J. Photovolt.*, vol. 12, no. 6, pp. 1308–1313, Nov. 2022, doi: 10.1109/JPHOTOV.2022.3206906.
- [7] J. A. Dhanraj *et al.*, “An effective evaluation on fault detection in solar panels,” *Energies*, vol. 14, no. 22, p. 7770, Nov. 2021, doi: 10.3390/en14227770.
- [8] E. K. Ukiwe, S. A. Adeshina, T. Jacob, and A. M. Zungeru, “Deep learning model for detection of hotspots using infrared thermographic images of electrical installations,” *J. Electr. Syst. Inf. Technol.*, vol. 11, p. 24, Jun. 2024, doi: 10.1186/s43067-024-00148-y.
- [9] R. Cahyaningtyas, S. Madenda, Bertalya, and D. Indarti, “Solar module defects classification using deep convolutional neural network,” *Int. J. Adv. Intell. Inform.*, vol. 11, no. 3, pp. 499–513, Aug. 2025, doi: 10.26555/ijain.v11i3.1818.
- [10] A. Shaik, A. Balasundaram, L. S. Kakarla, and N. Murugan, “Deep learning-based detection and segmentation of damage in solar panels,” *Automation*, vol. 5, no. 2, pp. 128–150, May 2024, doi: 10.3390/automation5020009.
- [11] C. Bu, T. Liu, T. Wang, H. Zhang, and S. Sfarra, “A CNN-architecture-based photovoltaic cell fault classification method using thermographic images,” *Energies*, vol. 16, no. 9, p. 3749, Apr. 2023, doi: 10.3390/en16093749.
- [12] S. Hassan and M. Dhimish, “A survey of CNN-based approaches for crack detection in solar PV modules: Current trends and future directions,” *Solar*, vol. 3, no. 4, pp. 663–683, Dec. 2023, doi: 10.3390/solar3040036.
- [13] S. P. Pathak, S. Patil, and S. Patel, “Solar panel hotspot localization and fault classification using deep learning approach,” *Procedia Comput. Sci.*, vol. 204, pp. 698–705, 2022, doi: 10.1016/j.procs.2022.08.084.
- [14] X. Zhang, Y. Hao, H. Shangguan, P. Zhang, and A. Wang, “Detection of surface defects on solar cells by fusing multi-channel convolution neural networks,” *Infrared Phys. Technol.*, vol. 108, p. 103334, Aug. 2020, doi: 10.1016/j.infrared.2020.103334.
- [15] P. Ma'rifah, M. Sarosa, and R. Erfan, “Comparison of Faster R-CNN ResNet-50 and ResNet-101 methods for recycling waste detection,” *Int. J. Comput. Appl. Technol. Res.*, vol. 12, no. 12, pp. 26–32, Dec. 2023, doi: 10.7753/IJCATR1212.1006.
- [16] M. A. M. Amin, N. A. A. Jamaludin, and N. F. Awang, “Object detection model based on ResNet-50 within the effective R-CNN framework,” *J. Inf. Syst. Eng. Manag.*, vol. 10, pp. 360–369, 2025, doi: 10.52783/jisem.v10i29s.4487.

- [17] N. Bilous, V. Malko, M. Frohme, and A. Nechyporenko, "Comparison of CNN-based architectures for detection of different object classes," *AI*, vol. 5, no. 4, pp. 2300–2320, Dec. 2024, doi: 10.3390/ai5040113.
- [18] X. Renjun, Y. Junliang, W. Yi, and S. Mengcheng, "Fault detection method based on improved Faster R-CNN: Take ResNet-50 as an example," *Geofluids*, vol. 2022, p. 7812410, 2022, doi: 10.1155/2022/7812410.
- [19] Afroz, "Solar panel images," *Kaggle*, 2023. [Online]. Available: <https://www.kaggle.com/datasets/pythonafroz/solar-panel-images>. (Accessed: 22-May-2025).
- [20] Z. Luo, S. Y. Cheng, and Q. Y. Zheng, "GAN-based augmentation for improving CNN performance of classification of defective photovoltaic module cells in electroluminescence images," in *IOP Conf. Ser.: Earth Environ. Sci.*, vol. 354, no. 1, 2019, Art. no. 012106, doi: 10.1088/1755-1315/354/1/012106.
- [21] N. A. M. Roslan, N. M. Diah, Z. Ibrahim, Y. Munarko, and A. E. Minarno, "Automatic plant recognition using convolutional neural network on Malaysian medicinal herbs: The value of data augmentation," *Int. J. Adv. Intell. Inform.*, vol. 9, no. 1, pp. 136–147, Mar. 2023, doi: 10.26555/ijain.v9i1.1076.
- [22] S. Hassan and M. Dhimish, "Dual spin max pooling convolutional neural network for solar cell crack detection," *Sci. Rep.*, vol. 13, no. 1, Dec. 2023, doi: 10.1038/s41598-023-38177-8.
- [23] A. Ratnakar, "Evaluating speech analysis techniques for Parkinson's disease detection: A comparison of machine learning and deep learning algorithms," *Int. J. Adv. Res.*, vol. 12, no. 5, pp. 1118–1137, May 2024, doi: 10.21474/IJAR01/18827.
- [24] D. P. Lestari *et al.*, *Komputer Vision, Kecerdasan Artifisial, dan Sistem Tertanam*. Depok, Indonesia: Penerbit Gunadarma, 2024.
- [25] L. Hakim, A. Hendrawan, and R. Khoiriyah, "Traffic vehicle detection using Faster R-CNN: A comparative analysis of backbone architectures," *Int. J. Artif. Intell. Sci.*, vol. 1, no. 1, pp. 50–62, Sep. 2024, doi: 10.63158/ijais.v1.i1.5.
- [26] T. T. Habe, K. Haataja, and P. Toivanen, "Efficiency meets accuracy: Benchmarking object detection models for pathology detection in wireless capsule endoscopy," *IEEE Access*, vol. 12, pp. 126793–126817, 2024, doi: 10.1109/ACCESS.2024.3456100.