



Integrasi Deteksi, Segmentasi, dan Klasifikasi Material Atap Berbasis YOLOv8s-seg untuk Estimasi Potensi PLTS Atap di Desa Adat Penglipuran, Bali

Amanda Austin Herlambang¹, I Nyoman Satya Kumara^{1*}, I Wayan Gede Ariastina¹, Putu Arya Mertasana², I Wayan Sukerayasa²

¹ Program Studi Magister Teknik Elektro, Universitas Udayana, Indonesia

² Program Studi Teknik Elektro, Universitas Udayana, Indonesia

Artikel Info

Kata Kunci:

Desa Penglipuran;
Deteksi Objek;
PLTS;
YOLOv8;

Keywords:

Penglipuran Village;
Object Detection;
PV;
YOLOv8.

Riwayat Artikel:

Submitted: 03 Agustus 2026
Accepted: 15 Oktober 2026
Published: 19 Oktober 2026

Abstrak: Peningkatan pemanfaatan energi terbarukan mendorong pengembangan Pembangkit Listrik Tenaga Surya (PLTS) atap untuk mendukung target *Net Zero Emission* (NZE) Indonesia 2060 dan Bali 2045. Penelitian ini mengimplementasikan *deep learning* YOLOv8 untuk mendeteksi, melakukan segmentasi, mengklasifikasikan material, dan mengestimasi luas atap sebagai dasar penentuan potensi PLTS di Desa Adat Penglipuran, Bali. Kontribusi utama penelitian ini adalah mengintegrasikan deteksi, segmentasi, klasifikasi material atap, dan estimasi luas dalam satu pendekatan berbasis citra udara untuk menghasilkan penilaian potensi teknis PLTS atap pada skala wilayah, yang tidak hanya berfokus pada deteksi objek atap. Menggunakan citra udara beresolusi 5 cm/piksel dan 26 citra pelatihan, model menghasilkan mAP@50 sebesar 0,665 untuk deteksi dan 0,658 untuk segmentasi. Atap beton dan metal ditetapkan layak, sedangkan atap asbes, sirap bambu, dan ilalang dikecualikan. Luas atap layak mencapai 25.190,46 m² dari 76 pekarangan, dengan potensi kapasitas PLTS sebesar 4,54–5,00 MWp dan produksi energi 6,20–6,82 GWh/tahun. Potensi tersebut setara 62,8–69,0 kali kebutuhan listrik tahunan 76 rumah tangga sebesar 98,8 MWh/tahun. Hasil menunjukkan YOLOv8s-seg efektif untuk rapid assesment potensi teknis PLTS atap pada skala wilayah.

Abstract: The increased uptake of renewable energy is driving the development of rooftop solar photovoltaic (PV) systems to support Indonesia's 2060 and Bali's 2045 Net Zero Emission (NZE) targets. This study employs the YOLOv8 deep learning model to detect, segment, and classify roof materials, as well as estimate roof areas, serving as the basis for assessing solar PV potential in the Penglipuran Traditional Village, Bali. Utilizing aerial imagery with a resolution of 5 cm/pixel and a training set of 26 images, the model achieved an mAP@50 of 0.665 for detection and 0.658 for segmentation. Concrete and metal roofs were deemed suitable, while asbestos, bamboo shingle, and thatch roofs were excluded. The total suitable roof area across 76 properties amounted to 25,190.46 m², representing a solar PV potential capacity of 4.54–5.00 MWp and an annual energy production of 6.20–6.82 GWh. This potential is equivalent to 62.8–69.0 times the combined annual electricity demand of the 76 households (98.8 MWh/year). The results demonstrate that YOLOv8s-seg is effective for the rapid assessment of rooftop solar PV technical potential at a regional scale.

Corresponding Author:

I Nyoman Satya Kumara
Email: satya.kumara@unud.ac.id

PENDAHULUAN

Komitmen Indonesia untuk mencapai Net Zero Emission (NZE) pada tahun 2060 dan target NZE Provinsi Bali pada tahun 2045 mendorong peningkatan pemanfaatan energi terbarukan, termasuk Pembangkit Listrik Tenaga Surya (PLTS) atap (Ahmed et al., 2025; Ahmed et al., 2024; IESR, 2025). Implementasi PLTS atap memerlukan informasi mengenai luas atap yang layak, kapasitas terpasang, dan potensi produksi energi sebagai dasar perencanaan dan pengambilan keputusan pada skala wilayah (Castellanos et al., 2017; Fakhraian et al., 2021; Hu et al., 2023). Berdasarkan *Global Solar Atlas*, Desa Adat Penglipuran memiliki rata-rata iradiasi global horizontal sebesar 4,675 kWh/m²/hari atau sekitar 1.706,5 kWh/m²/tahun, sehingga memiliki potensi yang baik untuk pengembangan PLTS atap (Global Solar Atlas, 2026). Perkembangan *deep learning* dan citra udara beresolusi tinggi memungkinkan ekstraksi informasi atap secara otomatis untuk mendukung asesmen potensi PLTS (Hamzaoglu et al., 2025; Kim et al., 2021; Zhang et al., 2025; Zhou et al., 2024). Salah satu pendekatan yang dapat digunakan adalah *instance segmentation* YOLOv8s-seg, yang mampu mendeteksi objek sekaligus menghasilkan batas geometris setiap atap dengan efisiensi komputasi yang baik. Hasil segmentasi tersebut dapat dimanfaatkan untuk mengestimasi luas atap secara otomatis dan selanjutnya menentukan potensi pemasangan modul fotovoltaik (Ahmed et al., 2025; Silva et al., 2025; Ultralytics, 2023).

Namun, penelitian sebelumnya yang menggunakan YOLO umumnya berfokus pada deteksi atau segmentasi atap untuk memperoleh lokasi dan geometri objek, sedangkan pemanfaatannya untuk estimasi potensi PLTS masih cenderung dilakukan tanpa mempertimbangkan material atap sebagai parameter kelayakan pemasangan. Perbedaan teknis penelitian ini terletak pada pemanfaatan YOLOv8s-seg tidak hanya untuk memperoleh keberadaan dan batas setiap bidang atap, tetapi juga sebagai tahap awal dalam rangkaian asesmen yang mengintegrasikan klasifikasi material, seleksi atap layak, dan estimasi luas permukaan atap. Hasil segmentasi dikonversi dari satuan piksel ke satuan metrik menggunakan Ground Sampling Distance (GSD) dan dikoreksi berdasarkan kemiringan atap, kemudian luas atap layak digunakan untuk menentukan kapasitas modul fotovoltaik dan produksi energi tahunan. Pendekatan terintegrasi tersebut masih terbatas diterapkan pada kawasan permukiman tradisional dengan karakteristik atap yang beragam (Hu et al., 2023; Qi et al., 2024).

Desa Adat Penglipuran merupakan kawasan permukiman tradisional dengan keragaman material atap, seperti beton, metal, asbes, sirap bambu, dan ilalang. Kondisi tersebut memberikan tantangan dalam menentukan kelayakan pemasangan PLTS karena perlu mempertimbangkan aspek struktural, keselamatan, dan pelestarian karakter arsitektur tradisional. Berdasarkan kondisi tersebut, penelitian ini mengusulkan pendekatan berbasis YOLOv8 untuk mendeteksi, mensegmentasi, dan mengklasifikasikan material atap serta mengestimasi potensi teknis PLTS atap pada skala desa. Kontribusi penelitian yaitu meliputi, mengintegrasikan deteksi dan *instance segmentation* atap dengan klasifikasi material sebagai dasar penentuan kelayakan pemasangan PLTS, mengestimasi luas permukaan atap dari hasil segmentasi menggunakan GSD dan koreksi kemiringan atap, serta mengintegrasikan luas atap layak dengan parameter teknis PLTS untuk mengestimasi kapasitas terpasang dan produksi energi tahunan pada skala wilayah. Pendekatan ini menghasilkan estimasi potensi PLTS yang mempertimbangkan karakteristik fisik dan material bangunan, sehingga dapat menjadi metode asesmen awal yang lebih cepat dan efisien dibandingkan pengukuran bangunan secara individual, khususnya pada kawasan permukiman tradisional.

Performa model YOLOv8 pada penelitian ini dibandingkan dengan beberapa penelitian terkait mengenai deteksi atap dan estimasi potensi PLTS atap berbasis citra penginderaan jauh, sebagaimana dirangkum pada Tabel 1. Perbandingan dilakukan secara kualitatif karena setiap penelitian menggunakan dataset, karakteristik objek, dan metrik evaluasi yang berbeda, seperti mAP, IoU, akurasi, dan *F1-score*, sehingga hasilnya tidak dapat dibandingkan secara langsung.

Tabel 1. Perbandingan Penelitian Terdahulu

Studi	Metode	Metrik Utama	Fokus	Kelebihan/Keterbatasan dibandingkan penelitian ini
Penelitian ini	YOLOv8	mAP@50 = 0,665 (box); 0,658 (mask)	Deteksi, segmentasi, klasifikasi 4 material atap, dan estimasi kapasitas/energi PLTS	Keunggulan: mengintegrasikan deteksi, <i>instance segmentation</i> , klasifikasi material, estimasi luas, dan potensi PLTS dalam satu alur. Keterbatasan: performa dipengaruhi jumlah dataset yang terbatas dan ketidakseimbangan kelas.
(Ahmed et al., 2025)	YOLOv8	Akurasi = 93,6%	Deteksi 10 kelas bentuk geometris atap	Keunggulan penelitian ini: mempertimbangkan material atap dan melanjutkan hasil segmentasi hingga estimasi PLTS. Perbedaan: studi terdahulu berfokus pada bentuk geometris atap.
(Kim et al., 2021)	CNN 43-layer	<i>Precision</i> 0,97; <i>Recall</i> 0,87; F1 0,91	Klasifikasi 4 kelas material atap dari citra satelit	Keunggulan penelitian ini: mengintegrasikan klasifikasi material dan estimasi potensi PLTS. Keterbatasan YOLOv8s-seg: pendekatan segmentasi khusus seperti MANet dapat lebih berfokus pada kualitas ekstraksi objek, sedangkan YOLOv8s-seg menyeimbangkan deteksi dan segmentasi dalam satu model.
(Qi et al., 2024)	MANet (dual-branch)	IoU = 88,17% (atap); 91,58% (panel PV)	Ekstraksi atap dan panel PV eksisting dari citra penginderaan jauh	Keunggulan penelitian ini: mengintegrasikan klasifikasi material dan estimasi potensi PLTS. Keterbatasan YOLOv8s-seg: pendekatan segmentasi khusus seperti MANet dapat lebih berfokus pada kualitas ekstraksi objek, sedangkan YOLOv8s-seg menyeimbangkan deteksi dan segmentasi dalam satu model.


Dibandingkan dengan (Ahmed et al., 2025) dan (Kim et al., 2021) yang masing-masing berfokus pada deteksi atap atau klasifikasi material atap, penelitian ini mengintegrasikan deteksi atap, klasifikasi material, estimasi luas atap, serta perhitungan kapasitas dan potensi produksi energi PLTS atap dalam satu *pipeline* analisis. Integrasi tersebut memungkinkan hasil *instance segmentation* dimanfaatkan secara langsung untuk menghitung luas atap efektif dan mengestimasi potensi teknis PLTS atap, sehingga mendukung asesmen potensi PLTS pada skala wilayah tanpa memerlukan proses interpretasi maupun pengolahan lanjutan secara terpisah. Penelitian yang dilakukan oleh (Qi et al., 2024) melaporkan nilai *Intersection over Union* (IoU) yang lebih tinggi menggunakan arsitektur MANet pada studi berskala perkotaan dengan dataset yang lebih besar. Sebaliknya, penelitian ini menerapkan model YOLOv8s-seg pada kawasan permukiman tradisional yang memiliki keragaman material atap serta memasukkan

aspek kelayakan struktural sebagai dasar pemilihan atap yang dapat dimanfaatkan untuk pemasangan PLTS. Meskipun menggunakan dataset yang lebih terbatas, pendekatan yang diusulkan mampu mengintegrasikan hasil deteksi, klasifikasi material, estimasi luas atap, hingga perhitungan kapasitas dan produksi energi dalam satu alur analisis. Hal ini menunjukkan bahwa metode yang diusulkan tidak hanya berfokus pada peningkatan performa deteksi, tetapi juga pada penyediaan informasi awal mengenai potensi teknis PLTS secara cepat untuk mendukung perencanaan pengembangan energi surya pada skala desa maupun wilayah yang lebih luas.


METODE

Tahapan Akuisisi Data dan Pelatihan Model

Metodologi penelitian ini terdiri atas lima tahapan utama, sebagaimana ditunjukkan pada Gambar 1. Tahap pertama adalah akuisisi citra udara beresolusi tinggi yang diperoleh dari Kementerian Agraria dan Tata Ruang/Badan Pertanahan Nasional (ATR/BPN) (Direktorat Jenderal Survei Dan Pemetaan Pertahanan Dan Ruang, 2026). Sebanyak 26 citra udara dengan resolusi spasial 5 cm/piksel dianotasi secara manual menggunakan format *Common Objects in Context* (COCO) untuk membangun dataset pelatihan (Ultralytics, 2026). Meskipun hanya terdiri atas 26 citra, setiap citra mencakup banyak objek atap dengan variasi ukuran, bentuk, orientasi, dan material, sehingga menghasilkan dataset yang representatif untuk proses pelatihan model. Deteksi, segmentasi, dan klasifikasi material atap dilakukan menggunakan model *instance segmentation* YOLOv8. Model dilatih selama 100 *epoch* menggunakan pendekatan *transfer learning* dengan bobot awal (*pre-trained weights*) dari dataset COCO. Setelah proses pelatihan, model secara simultan menghasilkan *bounding box*, *instance mask*, dan kelas material untuk setiap objek atap yang terdeteksi. Material atap diklasifikasikan ke dalam empat kategori, yaitu atap beton, atap metal, atap asbes, dan atap ilalang. Kinerja model dievaluasi menggunakan metrik *Precision*, *Recall*, dan *Mean Average Precision* pada IoU sebesar 0,5 (*mAP@50*).



Gambar 1. Diagram Alir Penelitian



Gambar 2. Arsitektur YOLOv8
(Biswas et al., 2023)

Model YOLOv8s-seg dipilih karena mampu mengintegrasikan deteksi objek dan instance segmentation dalam satu tahap (single-stage framework) dengan efisiensi komputasi yang tinggi. Arsitektur model terdiri atas backbone berbasis modul C2 untuk ekstraksi fitur, neck PAN-FPN (Path Aggregation Network–Feature Pyramid Network) untuk fusi fitur multiskala, serta anchor-free decoupled head untuk prediksi lokasi dan klasifikasi objek. Pada varian segmentasi, model dilengkapi mask coefficient branch yang dikombinasikan dengan prototype masks untuk menghasilkan instance mask pada setiap objek atap. Proses pelatihan dioptimalkan menggunakan kombinasi fungsi Complete Intersection over Union (CIoU) loss, Binary Cross-Entropy (BCE) loss, Distribution Focal Loss (DFL), dan segmentation loss (Marcelleno & Putra, 2025).

Dataset yang digunakan terdiri atas 26 citra udara beresolusi 5 cm/piksel, dengan setiap citra merepresentasikan beberapa objek dan jenis material atap. Dataset dibagi menggunakan metode *random split* dengan rasio 80:20, sehingga diperoleh 21 citra untuk data *training* dan 5 citra untuk data *validation*. Data *training* digunakan untuk proses pembelajaran model, sedangkan data *validation* digunakan untuk memantau kinerja dan mengevaluasi kemampuan generalisasi model. Penelitian ini tidak menggunakan data *testing* terpisah, sehingga evaluasi performa model dilakukan pada data *validation*. Proses pelatihan dilakukan menggunakan CPU dengan dukungan RAM sebesar 8 GB dengan *processor* 12th Gen Intel(R) Core(TM) i3-1215U pada lingkungan pengembangan *Jupyter Notebook*. Keluaran model berupa kelas material atap, koordinat *bounding box*, nilai *confidence score*, dan *instance mask*. Selanjutnya, *instance mask* dikonversi menjadi luas atap berdasarkan nilai *Ground Sampling Distance* (GSD) dan digunakan sebagai masukan untuk menghitung luas atap efektif, potensi kapasitas PLTS atap, serta potensi produksi energi PLTS atap pada tahap berikutnya.

Augmentasi Data

Karena citra yang digunakan merupakan citra udara dengan orientasi objek yang bervariasi, maka augmentasi data diterapkan untuk meningkatkan kemampuan model dalam mengenali objek pada berbagai orientasi. Jenis augmentasi yang digunakan disajikan pada Tabel 2.

Tabel 2. Augmentasi Data

Augmentasi	Nilai
<i>degrees</i>	15 derajat
<i>flipud</i>	0,5
<i>fliplr</i>	0,5
<i>mosaic</i>	1,0
<i>erasing</i>	0,4

Tabel 2 menunjukkan parameter augmentasi yang digunakan pada proses pelatihan model YOLOv8. Augmentasi rotasi diterapkan sebesar 15°, sedangkan *flipud* dan *fliplr* masing-masing memiliki probabilitas 0,5 untuk menghasilkan variasi orientasi vertikal dan horizontal. Augmentasi *mosaic* diterapkan dengan nilai 1,0 untuk menggabungkan beberapa citra dalam satu citra pelatihan, sedangkan *erasing* sebesar 0,4 digunakan untuk meningkatkan variasi dengan menghilangkan sebagian

area citra secara acak. Pengaturan tersebut digunakan untuk meningkatkan keragaman data pelatihan dan membantu model mengenali objek atap pada berbagai orientasi dan kondisi citra.

Penentuan Kelayakan, Estimasi Luas, dan Perhitungan Potensi PLTS

Tahap ini dilakukan untuk mengidentifikasi atap yang memenuhi kriteria pemasangan PLTS serta mengestimasi luas dan potensi energi yang dapat dimanfaatkan. Hasil klasifikasi material atap menjadi dasar dalam menentukan kelayakan setiap bidang atap. Atap beton dan metal dikategorikan layak, sedangkan atap asbes, ilalang dan sirap bambu tidak dimasukkan dalam analisis karena mempertimbangkan aspek struktural, keselamatan, kesehatan, dan pelestarian karakter arsitektur tradisional Desa Adat Penglipuran. Luas atap efektif yang telah divalidasi digunakan sebagai masukan dalam perhitungan potensi kapasitas PV atap. Perhitungan dilakukan berdasarkan luas atap yang tersedia, faktor utilisasi atap, efisiensi modul fotovoltaik, dan iradiasi sebesar 1000 W/m² sesuai kondisi *Standard Test Conditions* (STC), sehingga kapasitas yang diperoleh merepresentasikan kapasitas nominal sistem.

Selanjutnya, estimasi produksi energi tahunan dihitung menggunakan nilai *Global Horizontal Irradiance* (GHI) sebesar 1.706,5 kWh/m²/tahun dan *Performance Ratio* (PR) sebesar 0,80, serta parameter sistem lainnya untuk merepresentasikan potensi produksi energi pada kondisi operasi rata-rata sepanjang tahun (Global Solar Atlas, 2026). GHI digunakan untuk merepresentasikan potensi radiasi matahari tahunan pada lokasi penelitian, sedangkan PR digunakan untuk memperhitungkan berbagai rugi-rugi sistem sehingga estimasi produksi energi tidak diasumsikan berada pada kondisi ideal. Untuk memperoleh gambaran potensi PLTS pada tingkat desa, hasil perhitungan pada bangunan sampel diekstrapolasikan terhadap seluruh 76 pekarangan rumah di Desa Adat Penglipuran. Pendekatan ini menghasilkan estimasi luas atap layak, potensi kapasitas PLTS atap, dan potensi produksi energi tahunan pada skala wilayah, sehingga dapat dimanfaatkan sebagai dasar asesmen awal potensi teknis PLTS atap secara cepat tanpa memerlukan pengukuran setiap bangunan secara individual. Untuk perhitungan kapasitas PV yang dapat terpasang, digunakan rumus sebagai berikut:

$$P_{PLTS} = A_{atap} \times f_u \times G \times \eta$$

Dengan A_{atap} adalah luas permukaan atap (m²), f_u adalah faktor utilisasi atap, G adalah irradiansi pada kondisi STC (1.000 W/m²), dan η adalah efisiensi modul fotovoltaik. Produksi energi tahunan dihitung menggunakan persamaan berikut:

$$E_{PV} = P_{PV} \times GHI \times PR$$

Dengan E_{PV} merupakan energi listrik yang dihasilkan PLTS dalam satu tahun (kWh/tahun), P_{PV} merupakan kapasitas terpasang PLTS (kWp), GHI merupakan *Global Horizontal Irradiance* tahunan pada lokasi penelitian (kWh/m²/tahun), dan PR merupakan *Performance Ratio* yang merepresentasikan kinerja sistem dengan mempertimbangkan berbagai rugi-rugi pada sistem PLTS.

HASIL DAN PEMBAHASAN


Performa YOLOv8

Model YOLOv8s-seg dilatih selama 100 epoch menggunakan bobot pretrained COCO melalui pendekatan transfer learning. Proses pelatihan menunjukkan konvergensi yang stabil, dengan performa terbaik dicapai pada epoch ke-88. Hasil evaluasi menunjukkan bahwa model mencapai nilai mAP@50 sebesar 0,665 untuk deteksi (bounding box) dan 0,658 untuk segmentasi, yang menunjukkan bahwa model mampu mendeteksi dan mensegmentasi objek atap dengan kinerja yang cukup baik. Selisih mAP@50 sebesar 0,007 antara deteksi dan segmentasi juga menunjukkan bahwa penambahan tugas segmentasi tidak menyebabkan penurunan kinerja yang signifikan.


Nilai mAP@50 yang masih berada pada kisaran 0,66 terutama dipengaruhi oleh jumlah *dataset* yang relatif terbatas, keragaman karakteristik atap, ketidakseimbangan jumlah sampel antar kelas, serta kemiripan visual beberapa material atap. Dataset hanya terdiri atas 26 citra, sehingga variasi kondisi pencahayaan, bentuk, orientasi, dan karakteristik permukaan atap yang dapat dipelajari model menjadi terbatas. Selain itu, beberapa material memiliki karakteristik visual yang serupa pada citra udara,

sedangkan objek atap yang berdekatan dan beragam bentuk geometrinya dapat meningkatkan kompleksitas proses deteksi dan segmentasi. Faktor tersebut berkontribusi terhadap kesalahan klasifikasi maupun kegagalan mendeteksi sebagian objek.

Hal tersebut terlihat dari nilai *Precision* sebesar 0,702 dan *Recall* sebesar 0,616, yang menunjukkan bahwa prediksi objek yang berhasil dilakukan relatif tepat, tetapi masih terdapat objek atap yang belum terdeteksi. Perbedaan performa antar kelas juga menunjukkan pengaruh distribusi dan karakteristik data. Secara kuantitatif, nilai AUC-PR yang setara dengan *Average Precision* (AP) per kelas pada evaluasi *bounding box* adalah 0,944 untuk atap beton, 0,785 untuk atap ilalang, 0,646 untuk atap metal, dan 0,275 untuk atap asbes. Pola serupa diperoleh pada evaluasi mask segmentation dengan selisih tidak lebih dari 0,03 per kelas. Nilai AP yang rendah pada kelas asbes menunjukkan bahwa kelas tersebut merupakan salah satu sumber utama penurunan mAP, yang dapat berkaitan dengan jumlah sampel yang lebih sedikit dan karakteristik visual yang lebih sulit dibedakan dari material atap lainnya.



Gambar 3. Confusion Matrix & Confidence Curves Per Class



Gambar 4. F1 - Confidence Curve

Kinerja klasifikasi bervariasi pada setiap kategori material atap. Atap genteng *concrete* memperoleh performa tertinggi karena memiliki jumlah sampel yang paling dominan dalam dataset pelatihan, sedangkan atap asbes menunjukkan performa terendah akibat kemiripan karakteristik visual dengan atap metal yang telah mengalami pelapukan. Berdasarkan analisis kurva *Precision-Recall*, nilai ambang inferensi (*confidence threshold*) optimal ditetapkan pada $\tau = 0,30$, yang menghasilkan skor F1 sebesar 0,65 sebagai titik keseimbangan terbaik antara *Precision* dan *Recall*.

Deteksi Atap

Tabel 3 menyajikan rekapitulasi hasil deteksi dan estimasi luas atap berdasarkan kelas material. Model mendeteksi 172 objek *asbestos roof*, 574 *concrete tile roof*, 427 *metal sheet roof*, dan 358 *roof temple black*. Jumlah tersebut merepresentasikan bidang atap yang terdeteksi, bukan jumlah bangunan, karena satu bangunan dapat terdiri atas lebih dari satu bidang atap. Dengan GSD sebesar 0,05 m/piksel, setiap piksel merepresentasikan luas sebesar 0,0025 m². Berdasarkan hasil segmentasi, total luas yang

diperoleh untuk masing-masing kelas berturut-turut adalah 2.857,38 m², 12.814,67 m², 7.820,15 m², dan 584,20 m². Dalam analisis potensi PLTS atap, kelas *concrete tile roof* dan *metal sheet roof* digunakan sebagai objek analisis, sedangkan *asbestos roof* dan *roof temple black* tidak disertakan berdasarkan kriteria kelayakan yang ditetapkan.

Tabel 3. Rekapitulasi Hasil Deteksi dan Luas Atap Berdasarkan Kelas

Kelas Atap	Total Unit (Objek)	Total Piksel	Total Luas (m ²)	Keterangan
<i>asbestos_roof</i>	172.00	1,142,953.10	2,857.38	Tidak digunakan
<i>concrete_tile_roof</i>	574.00	5,125,867.79	12,814.67	Digunakan untuk analisis lebih lanjut
<i>metal_sheet_roof</i>	427.00	3,128,061.53	7,820.15	Digunakan untuk analisis lebih lanjut
<i>roof_temple_black</i>	358.00	233,679.89	584.20	Tidak digunakan

Gambar 5 menunjukkan hasil deteksi dan klasifikasi material atap menggunakan YOLOv8s-seg. Model mampu mengidentifikasi empat kelas material, yaitu *asbestos roof*, *concrete tile roof*, *metal sheet roof*, dan *roof temple black*, serta menghasilkan *instance mask* pada setiap objek yang terdeteksi. Hasil segmentasi menunjukkan bahwa *instance mask* dapat merepresentasikan batas geometris setiap bidang atap, termasuk pada objek yang berdekatan. Informasi tersebut memungkinkan luas atap dihitung berdasarkan jumlah piksel pada setiap mask dan selanjutnya dikonversi ke satuan luas menggunakan nilai GSD. Hasil luas atap yang diperoleh kemudian digunakan sebagai dasar dalam estimasi kapasitas terpasang dan potensi produksi energi PLTS atap.



Gambar 5. Hasil Deteksi Atap

Validasi dilakukan dengan membandingkan estimasi luas atap hasil *instance segmentation* dengan pengukuran independen menggunakan *Google Earth*, sebagaimana ditunjukkan pada Tabel 4. *Google Earth* digunakan sebagai data pembanding karena menyediakan citra resolusi tinggi dan fitur pengukuran geometri, sehingga dapat digunakan untuk mengevaluasi konsistensi hasil estimasi ketika data pengukuran lapangan tidak tersedia. Dalam penelitian ini, hasil pengukuran *Google Earth* digunakan sebagai pembanding independen dan bukan sebagai *ground truth*. Hasil validasi menunjukkan bahwa estimasi luas atap beton sebesar 96,36 m² memiliki nilai yang sama dengan hasil pengukuran *Google Earth*, sedangkan pada atap metal diperoleh selisih sebesar 0,01 m². Selisih absolut antara estimasi YOLOv8 dan *Google Earth* menggunakan persamaan berikut:




$$\text{Selisih} = L_{\text{YOLOv8}} - L_{\text{Google Earth}}$$

Dengan L_{YOLOv8} merupakan estimasi luas atap berdasarkan hasil segmentasi YOLOv8 dan konversi piksel menggunakan GSD serta koreksi kemiringan atap, sedangkan $L_{Google Earth}$ merupakan estimasi luas berdasarkan pengukuran poligon pada *Google Earth*. Nilai selisih yang semakin kecil menunjukkan kesesuaian estimasi luas yang semakin tinggi antara kedua metode. Perbedaan yang relatif kecil tersebut menunjukkan konsistensi antara hasil segmentasi dan pengukuran perbandingan. Akurasi estimasi luas dipengaruhi oleh resolusi citra sebesar 5 cm/piksel yang memungkinkan batas objek atap direpresentasikan dengan lebih jelas. Selain itu, penggunaan instance segmentation memungkinkan mask mengikuti bentuk geometris objek, sehingga perhitungan luas lebih representatif dibandingkan pendekatan berbasis bounding box. Konversi luas menggunakan GSD juga memungkinkan setiap piksel hasil segmentasi dikonversi secara langsung ke satuan metrik. Geometri bangunan yang relatif sederhana pada objek sampel turut mendukung konsistensi hasil segmentasi. Kemudian untuk menghitung galat yang dihasilkan dari perbandingan kedua metode tersebut, digunakan persamaan sebagai berikut:

$$\text{Galat} = \left(\frac{L_{YOLOv8} - L_{Google Earth}}{L_{Google Earth}} \right) \times 100\%$$

Hasil perbandingan ditampilkan pada Tabel 4 di bawah ini.

Tabel 4. Perbandingan Hasil Estimasi Luas Atap Menggunakan YOLOv8 dan *Google Earth*

Jenis Atap	Estimasi Luas Atap Menggunakan YOLOv8	Estimasi Luas Atap Menggunakan <i>Google Earth</i>	Selisih (m ²)	Galat (%)
Beton	 Estimasi Luas Area = 96,36 m²	 Estimasi Luas Area = 96,36 m²	0,00	0%
Metal	 Estimasi Luas Area = 25,60 m²	 Estimasi Luas Area = 25,59 m²	0,01	0,039% ≈ 0,04%

Potensi Daya dan Produksi Energi PLTS Atap

Tabel 5 menyajikan hasil koreksi luas bidang atap berdasarkan kemiringan sebelum digunakan dalam estimasi potensi PLTS. Hasil segmentasi YOLOv8s-seg pada citra *top view* merepresentasikan luas atap sebagai proyeksi horizontal. Oleh karena itu, luas tersebut dikoreksi untuk memperoleh pendekatan luas permukaan bidang atap dengan asumsi kemiringan sebesar 35°. Faktor koreksi dihitung menggunakan persamaan $F_k = \frac{1}{\cos \theta}$ sehingga diperoleh nilai sebesar 1,2208. Luas terkoreksi selanjutnya diperoleh dengan mengalikan luas hasil segmentasi dengan faktor tersebut. Berdasarkan hasil perhitungan, *concrete tile roof* memiliki luas awal sebesar 12.814,67 m² dan luas terkoreksi sebesar 15.644,15 m². Sementara itu, *metal sheet roof* memiliki luas awal sebesar 7.820,15 m² dan luas terkoreksi sebesar 9.546,84 m². Dengan demikian, total luas awal kedua jenis atap sebesar 20.634,82 m² meningkat

menjadi 25.190,99 m² setelah koreksi kemiringan. Luas terkoreksi inilah yang selanjutnya digunakan sebagai dasar dalam menentukan luas atap yang memenuhi kriteria pemasangan modul fotovoltaik berdasarkan orientasi dan keterbatasan ruang pemasangan.

Tabel 5. Hasil Faktor Koreksi Kemiringan

Jenis atap	Luas Awal (m ²)	Faktor Koreksi	Luas Terkoreksi (m ²)
Concrete tile	12,814.67	1.2208	15,644.15
Metal sheet	7,820.15	1.2208	9,546.84
Total	20,634.82		25,190.99

Berdasarkan total luas atap terkoreksi yang memenuhi kriteria analisis PLTS sebesar 25.190,46 m², selanjutnya dilakukan estimasi kapasitas terpasang PLTS. Perhitungan mempertimbangkan faktor utilisasi atap sebesar 80%, irradiansi pada kondisi *Standard Test Conditions* (STC) sebesar 1.000 W/m², dan efisiensi modul fotovoltaik. Faktor utilisasi sebesar 80% digunakan untuk merepresentasikan luas atap yang efektif digunakan untuk pemasangan modul dengan mempertimbangkan jarak antar modul, jarak dari tepi atap, akses pemeliharaan, dan keterbatasan geometris bidang atap. Dua skenario efisiensi modul digunakan, yaitu 20% untuk modul monokristalin dan 17% untuk modul polikristalin. Untuk skenario modul monokristalin, kapasitas terpasang diperoleh sebagai:

$$P_{\text{PLTS}} = 25,190.46 \times 0.80 \times 1000 \times 0.20 = 4,030.47 \text{ kWp} \approx 4,03 \text{ MWp}$$

Sementara itu, untuk skenario modul polikristalin diperoleh:

$$P_{\text{PLTS}} = 25,190.46 \times 0.80 \times 1000 \times 0.17 = 3,426.30 \text{ kWp} \approx 3,43 \text{ MWp}$$

Perbedaan kapasitas antara kedua skenario disebabkan oleh perbedaan efisiensi modul. Dengan luas atap dan faktor utilisasi yang sama, modul monokristalin dengan efisiensi 20% menghasilkan kapasitas terpasang yang lebih besar dibandingkan modul polikristalin dengan efisiensi 17%. Hasil tersebut menunjukkan bahwa peningkatan efisiensi modul memungkinkan kapasitas terpasang yang lebih besar pada luas atap yang sama. Estimasi kapasitas dilakukan menggunakan empat modul fotovoltaik komersial dari Trina Solar, Canadian Solar, Jinko Solar, dan LONGi. Densitas daya masing-masing modul diperoleh dari perbandingan antara daya maksimum dan luas modul, sebagaimana ditunjukkan pada Tabel 6.

Tabel 6. Spesifikasi Modul Fotovoltaik dan Densitas Daya

Pabrikan dan Model	Daya Maksimum	Dimensi Modul	Luas Modul	Densitas Daya
Trina Solar Vertex S+ TSM-NEG9R.25 (Trina Solar, 2024)	450 Wp	1,762 × 1,134 m	1,998 m ²	225,2 Wp/m ²
Canadian Solar TOPHiKu6 CS6.1-54TM-H (Solar Co Ltd, 2025)	465 Wp	1,800 × 1,134 m	2,041 m ²	227,8 Wp/m ²
Jinko Solar Tiger Neo JKM635N-66HL4M-V (Jinko Solar, 2024)	635 Wp	2,382 × 1,134 m	2,701 m ²	235,1 Wp/m ²
LONGi Hi-MO X10 LR7-72HVH-670M (Longi Solar, 2024)	670 Wp	2,382 × 1,134 m	2,701 m ²	248,0 Wp/m ²

Rentang kapasitas berdasarkan karakteristik empat modul tersebut adalah sekitar 4,54–5,00 MWp. Nilai terendah diperoleh dari modul Trina Solar dengan densitas daya 225,2 Wp/m², sedangkan nilai tertinggi diperoleh dari modul LONGi dengan densitas daya 248,0 Wp/m². Perbedaan tersebut menunjukkan bahwa karakteristik daya per satuan luas modul memengaruhi kapasitas PLTS atap yang dapat dipasang pada luas atap yang sama. Untuk estimasi produksi energi tahunan, kapasitas terpasang selanjutnya dikombinasikan dengan nilai GHI Desa Adat Penglipuran sebesar 1.706,5 kWh/m²/tahun dan *performance ratio* (PR) sebesar 0,80.

Maka potensi teknis PLTS atap berdasarkan luas efektif dan karakteristik modul komersial berada pada kisaran 4,54–5,00 MWp, dengan estimasi produksi energi sebesar 6,20–6,82 GWh/tahun. Mengacu pada rata-rata konsumsi listrik rumah tangga di Indonesia sebesar 1.300 kWh/tahun, kebutuhan listrik tahunan untuk 76 rumah tangga di Desa Adat Penglipuran diperkirakan sebesar 98,8 MWh/tahun. Dengan demikian, potensi produksi energi tersebut secara teoritis setara dengan sekitar 62,8–69,0 kali kebutuhan listrik tahunan 76 rumah tangga. Perbandingan tersebut menunjukkan bahwa luas atap yang memenuhi kriteria di kawasan studi memiliki potensi pembangkitan energi surya yang secara teoritis jauh lebih besar dibandingkan kebutuhan listrik tahunan rumah tangga. Namun, rasio tersebut tidak secara langsung menunjukkan jumlah energi yang dapat dimanfaatkan sebagai surplus, karena pemanfaatan energi aktual dipengaruhi oleh pola konsumsi listrik, waktu penggunaan energi, konfigurasi sistem PLTS, kapasitas jaringan, serta ketentuan teknis dan regulasi yang berlaku. Oleh karena itu, hasil ini lebih tepat diinterpretasikan sebagai perbandingan antara potensi teknis produksi energi PLTS dan kebutuhan listrik tahunan rumah.

Kontribusi utama penelitian ini terletak pada keterhubungan antara keluaran computer vision dan indikator teknis perencanaan PLTS atap. Nilai mAP@50 deteksi sebesar 0,665 dan segmentasi sebesar 0,658 merupakan ukuran keberhasilan model dalam mengenali serta membatasi objek atap, sedangkan estimasi kapasitas dan energi merupakan hasil analisis lanjutan yang bergantung pada klasifikasi material dan perhitungan geometris. Ahmed et al. (2025) juga memanfaatkan YOLOv8 untuk identifikasi atap dari citra udara, tetapi nilai performa antarkajian tidak dapat diperbandingkan secara langsung karena terdapat perbedaan kelas objek, data, dan protokol evaluasi. Li et al. (2024) menekankan bahwa informasi orientasi dan struktur tambahan pada atap penting agar estimasi potensi surya tidak berlebihan. Sejalan dengan itu, Amir et al. (2026) memperlihatkan pada konteks lain bahwa deteksi objek berbasis YOLO dapat diintegrasikan dengan parameter teknis untuk menghasilkan informasi pendukung keputusan, bukan berhenti pada pengenalan objek semata.

Kinerja model memperlihatkan adanya kompromi antara ketepatan prediksi dan kelengkapan deteksi. Precision sebesar 0,702 menunjukkan proporsi prediksi positif yang tepat, sedangkan recall sebesar 0,616 mengindikasikan masih ada objek atap rujukan yang belum teridentifikasi. Nilai Average Precision kelas beton sebesar 0,944 berbeda jauh dari kelas asbes sebesar 0,275; dengan demikian, mAP agregat sekitar 0,66 tidak boleh ditafsirkan sebagai ketelitian yang seragam pada semua material. Penelitian Kusuma et al. (2024) pada klasifikasi motif visual berbasis YOLOv8 juga menunjukkan pentingnya menilai precision, recall, dan mAP secara bersamaan, meskipun hasil angkanya tidak setara untuk diperbandingkan dengan deteksi material atap. Hasil ini mengisyaratkan bahwa atap dari kelas dengan performa rendah memerlukan verifikasi manual sebelum status kelayakan PLTS ditetapkan, terutama untuk menghindari kesalahan memasukkan material yang sebenarnya tidak memenuhi kriteria teknis.

Keterbatasan data merupakan faktor yang harus dipertimbangkan ketika menafsirkan hasil model. Penelitian ini menggunakan 26 citra udara, dengan 21 citra untuk pelatihan dan lima citra untuk validasi, sehingga variasi pencahayaan, musim, sudut atap, bayangan, dan degradasi material belum tentu tercakup secara memadai. Banyaknya objek atap di dalam satu citra tidak dengan sendirinya menggantikan keberagaman citra independen pada kondisi geografis yang berbeda. Qi et al. (2024) mengembangkan penilaian potensi PLTS dengan pemisahan tugas pemantauan dan penaksiran potensi melalui penginderaan jauh, sedangkan Zhang et al. (2025) menunjukkan kegunaan dataset spasial yang luas untuk pemetaan atap skala perkotaan. Oleh sebab itu, nilai mAP yang diperoleh pada lima citra validasi perlu ditempatkan sebagai estimasi performa internal, bukan bukti kemampuan generalisasi untuk seluruh wilayah Penglipuran. Evaluasi lanjutan sebaiknya menambah citra dari waktu akuisisi yang berlainan dan menyiapkan data uji independen di luar proses pemilihan model.

Tantangan klasifikasi material terlihat paling jelas pada atap asbes yang sebagian karakteristik visualnya menyerupai metal yang telah mengalami pelapukan. Kesalahan membedakan kedua material ini memiliki implikasi lebih besar daripada kesalahan lokalisasi biasa, karena penentuan jenis atap secara langsung memengaruhi luas yang disertakan dalam estimasi kapasitas PLTS. Zeng et al. (2025) menggabungkan segmentasi bangunan dengan analisis bayangan dan performa sistem untuk

mengurangi bias asesmen berbasis geometri dua dimensi, sehingga memperlihatkan perlunya mengaitkan ketelitian piksel dengan konsekuensi teknis pada hasil akhir. Dalam penelitian ini, pengelompokan material menjadi kategori layak dan tidak layak dapat dipertahankan untuk penyaringan awal, tetapi klasifikasi otomatis belum menggantikan verifikasi kondisi struktur, daya dukung, dan ketentuan pelestarian kawasan adat. Pemutakhiran label material dan dokumentasi aturan pengelompokan atap tradisional akan memperkuat reproduksibilitas keputusan kelayakan.

Penggunaan instance mask dan Ground Sampling Distance (GSD) sebesar 0,05 m/piksel memberikan dasar yang jelas untuk mengonversi luasan piksel ke satuan meter persegi. Koreksi kemiringan atap sebesar 35 derajat kemudian mengubah luas proyeksi horizontal menjadi estimasi luas bidang permukaan; namun penerapan satu nilai kemiringan pada beragam bangunan tetap merupakan asumsi yang perlu diuji. Li et al. (2024) menunjukkan bahwa pengabaian bentuk dan komponen tambahan atap berisiko melebihi area yang dapat dimanfaatkan, sedangkan Qi et al. (2024) menekankan pentingnya representasi kondisi atap yang lebih terperinci untuk asesmen potensi wilayah. Perbandingan dua bidang atap dengan pengukuran Google Earth menunjukkan konsistensi pada sampel yang ditampilkan, tetapi belum dapat dianggap sebagai validasi akurasi luas seluruh objek. Selain itu, total luas terkoreksi pada Tabel 5 tercantum 25.190,99 m², sedangkan perhitungan potensi dan kesimpulan menggunakan 25.190,46 m²; perbedaan 0,53 m² tersebut perlu direkonsiliasi agar alur perhitungan dapat ditelusuri kembali.

Estimasi kapasitas sebesar 4,54–5,00 MWp dan produksi tahunan 6,20–6,82 GWh perlu dipahami sebagai potensi teknis berdasarkan parameter skenario, bukan prediksi keluaran energi yang telah terverifikasi melalui operasi PLTS. Faktor utilisasi atap 80%, performance ratio 0,80, nilai iradiasi tahunan, kemiringan, dan densitas daya modul turut menentukan hasil perhitungan, sementara penghalang fisik di atap serta bayangan bangunan dan vegetasi belum dinilai satu per satu. Xu et al. (2025) menunjukkan bahwa bayangan dari morfologi bangunan dapat menimbulkan kehilangan energi yang berarti, sedangkan Zeng et al. (2025) menegaskan bahwa penggabungan informasi spasial dengan simulasi bayangan dapat mengurangi estimasi berlebihan dari pendekatan luas dua dimensi. Hamzaoglu et al. (2025) juga mengaitkan identifikasi atap dengan asesmen teknoekonomi sehingga menunjukkan perlunya pengujian lebih lanjut sebelum sebuah estimasi spasial digunakan sebagai dasar investasi. Analisis sensitivitas terhadap faktor utilisasi, performance ratio, kemiringan, dan bayangan akan meningkatkan transparansi rentang ketidakpastian estimasi PLTS Penglipuran.

Perbandingan hasil energi teoritis dengan kebutuhan listrik 76 rumah tangga sebesar 98,8 MWh/tahun menghasilkan rasio sekitar 62,8–69,0 kali, tetapi rasio ini tidak sama dengan bukti adanya surplus listrik yang dapat dimanfaatkan atau diekspor ke jaringan. Besarnya potensi produksi tahunan masih dipengaruhi profil pemakaian listrik harian, kesesuaian waktu produksi dan konsumsi, konfigurasi inverter, ketersediaan jaringan, serta persyaratan interkoneksi. Kajian Xu et al. (2025) memperlihatkan pentingnya variasi temporal pada perhitungan produksi, sementara Li et al. (2024) menunjukkan bahwa penaksiran potensi pada skala kota memerlukan pemilahan ruang pemasangan yang realistis. Dalam konteks Desa Adat Penglipuran, kelayakan teknis juga perlu dibedakan dari penerimaan sosial serta pembatasan pelestarian arsitektur tradisional. Oleh karena itu, estimasi saat ini lebih tepat digunakan sebagai inventarisasi awal bagi pembuat kebijakan dan pengelola kawasan daripada sebagai angka final kapasitas yang siap dibangun.

Secara metodologis, pengembangan berikutnya perlu diarahkan pada pengumpulan citra tambahan yang lebih seimbang antarkelas, pemisahan data uji independen, validasi luasan terhadap survei lapangan dan pengukuran geometris terstandar, serta pengujian kestabilan model pada variasi resolusi dan musim. Penggunaan satu kali pemisahan pelatihan–validasi juga belum cukup untuk menilai variasi performa akibat pengambilan sampel; oleh karena itu, eksperimen berulang atau validasi lintas-lokasi diperlukan sebelum hasil dapat digeneralisasikan. Mengikuti arah studi Qi et al. (2024) dan Zeng et al. (2025), sistem dapat diperluas dengan modul identifikasi penghalang atap, bayangan, orientasi bidang, dan simulasi produksi berbasis data radiasi yang lebih rinci. Di sisi implementasi, verifikasi klasifikasi material oleh tenaga teknis dan pihak pengelola kawasan adat harus mendahului keputusan pemasangan. Dengan demikian, nilai utama pendekatan YOLOv8s-seg dalam

penelitian ini adalah kemampuannya mempercepat penyaringan dan pengukuran awal, sementara kelayakan PLTS yang sesungguhnya tetap memerlukan validasi teknis, lingkungan, dan kelembagaan.

KESIMPULAN

Penelitian ini berhasil menerapkan metode YOLOv8s-seg untuk mengidentifikasi karakteristik material dan luas bidang atap sebagai dasar estimasi potensi PLTS atap di Desa Adat Penglipuran. Model menghasilkan nilai mAP@50 sebesar 0,665 untuk deteksi dan 0,658 untuk instance segmentation. Hasil segmentasi menunjukkan bahwa concrete tile roof dan metal sheet roof merupakan jenis atap yang memenuhi kriteria untuk analisis PLTS, dengan total luas terkoreksi sebesar 25.190,46 m² dari 76 pekarangan. Setelah mempertimbangkan faktor utilisasi sebesar 80% dan densitas daya modul komersial sebesar 225,2–248,0 Wp/m², diperoleh potensi kapasitas PLTS sebesar 4,54–5,00 MWp dengan estimasi produksi energi sebesar 6,20–6,82 GWh/tahun. Potensi tersebut secara teoritis mencapai sekitar 62,8–69,0 kali kebutuhan listrik tahunan 76 rumah tangga yang diperkirakan sebesar 98,8 MWh/tahun. Hasil ini menunjukkan bahwa pendekatan yang diusulkan mampu menyediakan *rapid assessment* potensi teknis PLTS atap pada skala wilayah. Kontribusi ilmiah penelitian ini terletak pada integrasi deteksi, *instance segmentation*, klasifikasi material, dan estimasi luas atap berbasis citra udara sebagai pendekatan terpadu untuk penilaian potensi teknis PLTS pada kawasan permukiman tradisional. Pendekatan ini berpotensi dikembangkan pada penelitian selanjutnya melalui penerapan model pada cakupan bangunan yang lebih luas, peningkatan jumlah dan keragaman *dataset*, serta integrasi data teknis lapangan untuk meningkatkan akurasi dan mendukung perencanaan implementasi PLTS secara lebih rinci. Namun, hasil yang diperoleh masih memerlukan validasi melalui penerapan model pada seluruh bangunan dan survei teknis lapangan sebelum digunakan sebagai dasar perencanaan dan implementasi PLTS secara rinci.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih atas dukungan pendanaan yang diberikan melalui Hibah Kelompok Riset Udayana (HIKERU) Tahun 2026 B/324.216/UN14.4.A/PT.01.03/2026 yang telah mendukung pelaksanaan penelitian ini.

DAFTAR PUSTAKA

- Ahmed, M. S., Arman, M. S., Tasnim, N., Imran, M. H., Sammak, M. H., & Bhuiyan, T. (2025). Rooftops Detection With Yolov8 From Aerial Imagery And A Brief Review On Rooftop Photovoltaic Potential Assessment. *IAES International Journal of Artificial Intelligence*, 14(3), 2282–2290. <https://doi.org/10.11591/ijai.v14.i3.pp2282-2290>
- Ahmed, S., Ali, A., & D'Angola, A. (2024). A Review of Renewable Energy Communities: Concepts, Scope, Progress, Challenges, and Recommendations. *Sustainability* 2024, 16(5), 1749; <https://doi.org/10.3390/su16051749>
- Amir, A. A., Sukman, Lihara, A. D., & Nabil, M. (2026). Sistem Analisis Kinerja Lalu Lintas Berbasis Deep Learning Dengan Arsitektur You Only Look Once (YOLO). *Decode: Jurnal Pendidikan Teknologi Informasi*, 6(1), 179–190. <https://doi.org/10.51454/decode.v6i1.1503>
- Biswas, S., Acharjee, S., Ali, A., & Chaudhari, S. S. (2023). YOLOv8 based Traffic Signal Detection in Indian Road. *2023 7th International Conference on Electronics, Materials Engineering and Nano-Technology, IEMENTech 2023*, 1-6. <https://doi.org/10.1109/IEMENTech60402.2023.10423520>
- Castellanos, S., Sunter, D. A., & Kammen, D. M. (2017). Rooftop Solar Photovoltaic Potential In Cities: How Scalable Are Assessment Approaches?. *Environmental Research Letters*, 12(12), 125005. <https://doi.org/10.1088/1748-9326/aa7857>

- Direktorat Jenderal Survei Dan Pemetaan Pertahanan Dan Ruang. (2026). *Model Dasar Pertahanan* Retrieved January 3, 2026. <https://petadasar.atrbpn.go.id/>
- Fakhraian, E., Alier, M., Dalmau, F. V., Nameni, A., & Guerrero, J. C. (2021). The urban rooftop photovoltaic potential determination. *Sustainability (Switzerland)*, 13(13). <https://doi.org/10.3390/su13137447>
- Global Solar Atlas. (2026). *Global Solar Atlas* Retrieved June 25, 2026. <https://globalsolaratlas.info/map?s=-8.422177,115.358908&m=site&c=-8.422177,115.358908,11>
- Hamzaoglu, A., Erduman, A., & Kırçay, A. (2025). Deep Learning-Based Rooftop PV Detection and Techno Economic Feasibility for Sustainable Urban Energy Planning. *Sustainability (Switzerland)*, 17(15), 6853. <https://doi.org/10.3390/su17156853>
- Hu, M., Liu, Z., Huang, Y., Wei, M., & Yuan, B. (2023). Estimation of Rooftop Solar Photovoltaic Potential Based on High-Resolution Images and Digital Surface Models. *Buildings*, 13(11), 2686. <https://doi.org/10.3390/buildings13112686>
- IESR. (2025). *Bali's Roadmap to Net Zero Emissions by 2045 in the Electricity Sector*. <https://iesr.or.id/en/pustaka/balis-roadmap-to-net-zero-emissions-by-2045-in-the-electricity-sector/>
- Jinko Solar. (2024). *66HL4M-(V) 610-635 Watt Anti-PID guarantee SMBB Technology Mechanical Load Enhanced Durability Against Extreme Environment N-type Technology N-type modules with Tunnel Oxide Passivating*. www.jinkosolar.com
- Kim, J., Bae, H., Kang, H., & Lee, S. G. (2021). Cnn Algorithm For Roof Detection And Material Classification In Satellite Images. *Electronics (Switzerland)*, 10(13), 1592. <https://doi.org/10.3390/electronics10131592>
- Kusuma, N. T. R., Suarjaya, I. M. A. D., & Vihikan, W. O. (2024). Implementasi Metode Yolov8 Pada Mobile Apps Untuk Klasifikasi Kain Endek Bali. *Decode: Jurnal Pendidikan Teknologi Informasi*, 4(3), 787–797. <https://doi.org/10.51454/decode.v4i3.610>
- Li, Q., Krapf, S., Mou, L., Shi, Y., & Zhu, X. X. (2024). Deep Learning-Based Framework For City-Scale Rooftop Solar Potential Estimation By Considering Roof Superstructures. *Applied Energy*, 374, 123839. <https://doi.org/10.1016/j.apenergy.2024.123839>
- Longi Solar. (2024). *Longi Datasheet Hi-Mo X10 LR7-72HVH 655 - 670M*.
- Marcelleno, D. J., & Putra, M. P. K. (2025). Performance Evaluation Of Yolov8 In Real-Time Vehicle Detection In Various Environmental Conditions. *Jurnal Teknik Informatika (Jutif)*, 6(1), 269–279. <https://doi.org/10.52436/1.jutif.2025.6.1.3916>
- Qi, Q., Zhao, J., Tan, Z., Tao, K., Zhang, X., & Tian, Y. (2024). Development Assessment Of Regional Rooftop Photovoltaics Based On Remote Sensing And Deep Learning. *Applied Energy*, 375, 124172. <https://doi.org/10.1016/j.apenergy.2024.124172>
- Silva, A. S., de Azevedo, A. R., Neto, F. H. de A. M., & Ferreira da Silva, P. H. (2025). YOLOv8-based Model For Automatic Detection Of Residential Roof Damage. *Revista Alconpat*, 15(1), 50–63. <https://doi.org/10.21041/ra.v15i1.783>
- Solar Co Ltd. (2025). *CanadianSolar Datasheet 435 W ~ 465 W TOPHiKu6*. www.csisolar.com/na
- Trina Solar. (2024). *Vertex S Dual Glass N type i-TOPCon Module Outstanding Visual Appearance Dual-glass Design, High Reliability*. www.trinasolar.com
- Ultralytics. (2026). *COCO Dataset* Retrieved July 9, 2026. <https://docs.ultralytics.com/datasets/detect/coco>
- Ultralytics. (2023). *Explore Ultralytics YOLOv8*. <https://docs.ultralytics.com/models/yolov8#overview>

- Xu, J., Guo, Z., Yu, Q., Dong, K., Tan, H., Zhang, H., & Yan, J. (2025). Spatiotemporal Feature Encoded Deep Learning Method For Rooftop PV Potential Assessment. *Applied Energy*, 394, 126171. <https://doi.org/10.1016/j.apenergy.2025.126171>
- Zeng, J., Yang, M., Tang, X., Guan, X., & Ma, T. (2025). Intelligent Segmentation Of Urban Building Roofs And Solar Energy Potential Estimation For Photovoltaic Applications. *Journal of Imaging*, 11(10), 334. <https://doi.org/10.3390/jimaging11100334>
- Zhang, Y., He, W., Hu, J., Zhou, C., Ren, B., Luo, H., Tian, Z., & Liu, W. (2025). Assessment of Urban Rooftop Photovoltaic Potential Based on Deep Learning: A Case Study of the Central Urban Area of Wuhan. *Buildings*, 15(15), 2607. <https://doi.org/10.3390/buildings15152607>
- Zhou, Z., Li, Y., Guo, Z., Yan, Z., & Chow, M.-Y. (2024). A White-Box Deep-Learning Method for Electrical Energy System Modeling Based on Kolmogorov-Arnold Network. *IEEE Transactions on Industrial Informatics*, 22(1) 107-118. <https://doi.org/https://doi.org/10.48550/arXiv.2409.08044>