


Segmentierung von PV-Panels mittels Deep Learning in Thermalbildern einer Drohnenbefliegung eines Solarparks

Bearbeiter: Alexander Müller

Betreuer: Prof. Dr.-Ing. Danilo Schneider, M. Sc. Ricardo Kroll

ZIELSTELLUNG

Für die automatisierte pixelgenaue Segmentierung von Photovoltaikmodulen ist die Nutzung eines Deep Learning-Modells derzeit einer der vielversprechendsten Ansätze. Ausgehend von der steigenden Bedeutung effizienter Wartungskonzepte nach dem Installationsboom der vergangenen Jahre, war es das Ziel der Arbeit die Machbarkeit und Leistungsfähigkeit dieser Herangehensweise zu untersuchen. Damit eröffnet sich im Vergleich zu konventionellen Verfahren, zeit- und kostensparende Alternative. Um auf Basis eines manuell annotierten Thermalbilddatensatzes die Zuverlässigkeit der Segmentierung zu evaluieren, wurde das Open-Source-Framework YOLOv5 von Ultralytics im darauf zugeschnittenen Segmentierungsmodus genutzt. Neben der reinen Machbarkeit standen quantitative Metriken (Precision, Recall, mAP) sowie qualitative Analysen an Beispielbildern im Vordergrund. Die Ergebnisse bilden die Grundlage für eine weiterführende Defektdetektion und zeigen Potenziale für eine Integration in automatisierte Wartungsprozesse auf.



Der stabile Verlauf beider Verlustkurven bezeugt dem Modell einen positiven Trainingsprozess mit stetiger Verbesserung vor allem innerhalb der ersten 10 Epochen, ohne dabei Anzeichen auf Overfitting zu liefern. Mit den hohen Werten, die es in Precision und Recall erzielen konnte, findet eine zuverlässige Segmentierung im Trainingsumfeld statt. Die mittlere Genauigkeit mAP@0,5 mit rund 92,5% belegt zudem eine robuste Erkennung der Modulflächen, während der strengere Wert mAP@0,5:0,95 von rund 59% die Grenzen der pixelgenauen Segmentierung aufzeigt.

VORGEHEN

Datengrundlage

- Rund 400 Thermalbilder, DJI Zenmuse H20T, Flughöhe ca. 60m
- Vorteile: charakteristische Wärmeverteilung
- Herausforderung: Rauschen, geringere Auflösung, modulähnliche Objekte

Aufbereitung



- **Manuelle Annotation** in Labelme (Polygone)
- Aufbereitung in YOLOv5-Format
- **Datensatzaufteilung**: 80% Training, 20% Validierung
- **Augmentationen**: Spiegelung, Skalierung, Farb- und Helligkeitsänderung zur künstlichen Erweiterung der Datensatzgröße- und Variation

Modell & Training

- Framework: **YOLOv5s** (Segmentierungsmodus, Open Source)
- Transfer Learning mit **COCO**-Gewichten
- 50 Epochen, Batch Size = 2

Evaluation

- **Quantitativ**: Loss, Precision, mAP
- **Qualitativ**: Inferenz auf Normalfall, Problemfall, externe Daten





Abbildungen zeigen Arbeitsprozess:
Ausgangsbild - Annotation mit Polygonen - binäre Referenzmaske

ERGEBNISSE

Inferenzresultate



Normalfall:



IoU = 0,86

- **Präzise Segmentierung** im Trainingskontext
- **saubere Modulgrenzen**
- robust gegenüber **thermischen Anomalien & variierenden Modulflächen**



Problemfall:



IoU = 0,45

- anfällig für **Bewegungsunschärfe & modulähnliche Objekte**
- Probleme an **Bildrändern**

Externe Daten:




IoU = 0,1

- Stark **eingeschränkte Generalisierungsfähigkeit** (variierende Flughöhe, Aufnahmewinkel, etc.)

ERGEBNIS

Quantitative Metriken im Überblick



AUSBLICK

- **Erweiterung** und **Diversifizierung** des Datensatzes zur Steigerung der Robustheit
- **Kombination** der Segmentierung mit **Hotspot-Detektion** zur **automatisierten Defekterkennung**
- Schrittweise **Erweiterung auf Einzelmodulsegmentierung** für exakte Lokalisierungen
- Integration in **digitale Wartungsprozesse** zur langfristig **effizienteren** und **kostengünstigeren Instandhaltung** von PV-Anlagen