

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

*Zusammenfassung Bachelorarbeit – Alexander Müller*

Photovoltaikanlagen sind ein zentraler Baustein der Energiewende. Subventionierung, Rentabilität und Nachhaltigkeit haben zu dem starken Aufstieg der Branche während des vergangenen Jahrzehnts beigetragen. Mit steigender Anzahl bereits vorhandener Anlagen wächst der Bedarf an effizienter Wartung und Instandhaltung. Konventionelle Verfahren sind oft zeit- und kostenintensiv, weshalb Drohnenbefliegungen in Kombination mit Thermographie eine attraktive Alternative darstellen. Sie erlauben die großflächige Erfassung der Flächen und ihrer Wärmeverteilung. Damit ist die frühzeitige Lokalisierung potenzieller Defekte möglich. Fortschritte im Bereich des maschinellen Lernens, insbesondere durch Deep Learning, eröffnen neue Optionen zur Automatisierung dieser Prozesse. Eine der Schlüsselaufgaben ist die präzise Segmentierung von Modulflächen, die gemeinsam mit der Defekterkennung die Grundlage einer allumfassenden Wartungspipeline bilden. Diese Arbeit untersucht, ob sich Deep Learning als Methode für die Aufgabe eignet, wie zuverlässig PV-Module segmentiert werden können und welche Perspektiven sich daraus für weiterführende Inspektionsketten ergeben.

Convolutional Neuronal Networks bilden das methodische Fundament der Arbeit. Ihr Aufbau und ihre Funktionsweise, sprich wie sie Bildmerkmale (Kanten, Strukturen und Flächen) erkennen, ist im Grundlagenkapitel dargestellt. Mit YOLOv5 wurde ein Open-Source-Framework gewählt, das einen passenden Segmentierungsmodus bereitstellt. Das essenzielle Prinzip des Transfer Learnings ermöglichte die Verwendung vortrainierter Gewichte des COCO-Datensatzes, wodurch das Modell von Beginn an auf ein generelles Bildverständnis zurückgreifen konnte und die Trainingszeit deutlich reduziert wurde.

Als Datengrundlage diente ein Satz Thermalbilder aus einer Drohnenbefliegung eines Solarparks, aufgenommen mit einer DJI Zenmuse H20T aus etwa 60 m Höhe. Thermalbilder bieten durch die Temperaturkomponente Vorteile für die Inspektion, da diese charakteristisch für Modulflächen ist, was nicht nur die Abgrenzung erleichtert, sondern auch Defekte sichtbar macht.

Für das Training wurden manuell die Modulflächen in rund 400 der Bilder annotiert und als Polygone im passenden Format eingespeist. Um den Datensatz bezüglich Varietät aufzuwerten, kamen Augmentationen wie Skalierung, Farbwertänderung und Spiegelungen zum Einsatz, was die Robustheit des Modells begünstigt.

Trainiert wurde über 50 Epochen auf lokalen Hardwareressourcen, wobei der Prozess stabil und ohne Hinweise auf Overfitting verlief. Wichtige Indikatoren wie die Verlustfunktion entwickelten sich positiv. Auch quantitative Metriken für verschiedene Aspekte

der Genauigkeit wie mAP, Recall und Precision lagen im guten Bereich (>90%) und belegten damit ein zuverlässiges Modellverhalten.




Abbildung 1: Ausgangsbild, Inferenzergebnis und Fehlerkarte als Visualisierung des Trainingsprozesses

Unter normalen Bedingungen segmentierte das Modell die Modulflächen mit einer hohen Genauigkeit und klaren Grenzen. Ungenauigkeiten traten vor allem an Bildrändern auf, wo Teilflächen unerkant blieben. Die Inferenz bei Bildern mit höherem Schwierigkeitsgrad zeigte, dass modulähnliche Objekte und Bewegungsunschärfe verstärkt zu Fehlklassifikationen führen, während thermische Anomalien und variierende Modulform robust verarbeitet wurden. Bei externen Datenquellen fiel die Leistung deutlich ab, was aber an fehlender Datenvielfalt im Training lag und damit erwartbar war.

Die Arbeit hat gezeigt, dass bereits mit einem vergleichsweise kleinen Datensatz eine zuverlässige Segmentierung möglich ist. Das Modell überzeugt durch präzise Grenzerkennung und insgesamt guter Performance im Trainingskontext. Schwächen bestehen in der Generalisierbarkeit sowie bei modulähnlichen Strukturen. Für weiterführende Anwendungen zeichnet sich jedoch enormes Potenzial ab. Durch gezielte Datensatzerweiterungen und Integration zusätzlicher Analysetools kann eine automatisierte Auswertungskette realisiert und damit Wartungsvorgänge erheblich effizienter gestaltet werden.