

Bachelor-Thesis 2022 resp. Zusammenfassung Bachelor-Thesis

Automatische Detektion von Solaranlagen in der Schweiz

mit Hilfe von Luftbildern und Deep Learning Verfahren

**Autoren: Thibaud Müller****Examinator: Prof. Dr. Denis Jordan****Betreuer: Adrian Meyer**

Detektion und Segmentation von Solaranlagen in der Schweiz

Viele Forschungsprojekte befassen sich hinsichtlich nationaler Energiestatistiken mit der automatischen Detektion von Solaranlagen. In vorliegender Arbeit wurde das Wissen eines vorangehenden Projektes der FHNW übernommen und die Fähigkeit eines Deep Learning (DL) Workflows auf Basis von hochaufgelösten Luftbildern der Swisstopo hinsichtlich der Detektion von Photovoltaik- und Solarthermieanlagen untersucht.

Schlagerworte: Solaranlagen, Luftbilder, Deep Learning, Objektdetektion, Objektsegmentation

1. Hintergrund

Mit dem Bundesratsentscheid vom August 2019 zur Klimaneutralität bis 2050 steht die Schweizer Energieversorgung vor grossen Herausforderungen. Das Bundesamt für Energie (BFE) führt Energiestatistiken, um die Erzeugung und den Verbrauch elektrischer Energie in der Schweiz zu überwachen. Diese sollen durch eine automatische Detektion und Segmentation von Solaranlagen aus Luftbildern mittels DL ergänzt werden.

2. Datenaufbereitung

Die Vorbereitung der Referenzdaten aus Swisimage Luftbildern (swisstopo, Bern) erfolgt in QGIS, wobei drei Klassen berücksichtigt werden: *Photovoltaik* (Abbildung 1), *Solarthermie* (Abbildung 2) und *Unbekannt*.



Abbildung 2: Photovoltaikanlage



Abbildung 1: Solarthermieanlage

Ein umfangreicher Datensatz von qualitativ hochstehenden und umfassenden Referenzdaten ist die Grundvoraussetzung für eine robuste und zuverlässige Objektdetektion und von hoher Bedeutung für die Qualität des Endergebnisses.

3. Umsetzung mit Deep Learning

Die Scripts des Objektdetektors (Mask R-CNN Architektur) aus dem Swiss Territorial Data Lab (STD Lab) dienen als Grundlage zum Trainingsprozess. Durch die Verwendung des umfangreichen vortrainierten Common Objects in Context (COCO) Datensatzes für die Bilderkennung und Segmentierung in Bildern wird das Modelltraining beschleunigt. Das dadurch verkürzte Training dauerte rund fünf Stunden und wurde für beide Solaranlagentypen berechnet.

4. Ergebnisse

Es wurde ein Deep Learning Modell pro Solaranlagentyp erstellt, wobei die Modelle auf der Basis der Testdaten die in Tabelle 1 dargestellten Ergebnisse erreichen. Bei Betrachtung des F1 Scores (Metrik für die Gesamtgenauigkeit, min. 0 % max. 100 %) wird sichtbar, dass die Photovoltaikanlagen zu einem im Vergleich zu den Solarthermieanlagen geringfügig höheren F1 führen:

Art	Photovoltaikanlagen	Solarthermieanlagen	Alle Solaranlagen
F1-Score	80 %	77 %	82 %

Tab. 1 Die Verschiedenen F1-Scores der Deep Learning Modelle im Vergleich.

Der im Vergleich zu den Einzelscores höhere F1 über alle Solaranlagen lässt sich möglicherweise durch die grössere Anzahl Trainingsdaten und der einfacheren dichotomen Klassifizierung erklären.

5. Vergleich mit dem vorangehenden Projekt der FHNW

Im Gegensatz zum abgeschlossenen Projekt SolAi (Institut Geomatik, FHNW), welches einen F1 Score von ca. 90 % erzielte, sind die Resultate in diesem Projekt niedriger. Dies lässt sich durch den Zeitpunkt der Luftaufnahmen begründen: Im Rahmen von SolAi wurden Sommerluftbilder verwendet, wogegen diese Untersuchung auf Winteraufnahmen basiert, für welche die DL Prozessierung anspruchsvoller zu sein scheint.

6. Schlussfolgerung

Grundsätzlich lassen sich beide Solaranlagentypen mit einer guten Zuverlässigkeit detektieren. Für eine schweizweite Erfassung von Solaranlagen sollte der saisonale Effekt in Betracht gezogen werden.

Kontakt

Autor:	Thibaud Müller	thibaudmueller@gmail.com
Examinator:	Prof. Dr. Denis Jordan	denis.jordan@fhnw.ch
Betreuer:	Adrian Meyer	Adrian.meyer@fhnw.ch