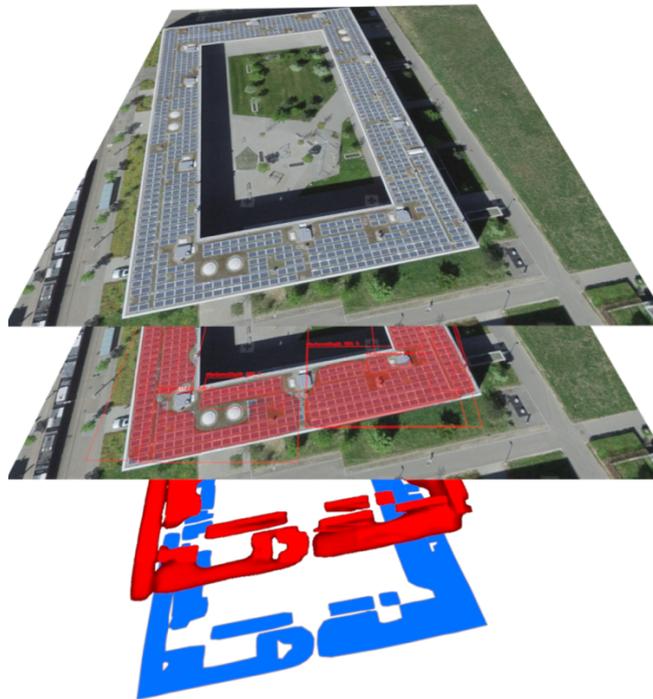


Zusammenfassung Bachelor-Thesis 2020

Detektion von Solarzellen mit Hilfe von maschinellem Lernen

**Autor:** Elia Ferrari**Examinator:** Prof. Dr. Denis Jordan**Experte:** Prof. Martin Christen**Betreuer:** Adrian Meyer

Detektion von Solarzellen mit Hilfe von maschinellem Lernen

Der Solarindustrie-Markt zeichnet sich durch anhaltend hohe Wachstumsraten aus. Für die Energiestrategie 2050 des Schweizer Bundesamts für Energie (BFE) sind Solarmarkt-Daten sehr wichtig. Bisher fehlen in der Schweiz noch zuverlässige Lage- und Flächendaten der bereits installierten Photovoltaik- und Solarthermie-Anlagen. Das laufende *SolAI*-Projekt (*Solar Artificial Intelligence*) des Instituts Geomatik an der FHNW zielt darauf ab, mit Hilfe von maschinellem Lernen (insbesondere Deep-Learning-Modellen) landesweit Solaranlagen aus Orthophotos zu detektieren und zu klassifizieren. In dieser Arbeit wird untersucht, wie der Workflow des *SolAI*-Prototyps verbessert und die Ergebnisse in einem GIS weiterverarbeitet und dargestellt werden können.

Schlagnworte: Maschinelles Lernen, Deep Learning, Objektdetektion, Photovoltaik, Solarthermie, Python, Mask R-CNN, GIS

1. Ausgangslage und Datenanalyse

Eine erste Implementierung des *SolAI*-Prototyps steht für die Untersuchung zur Verfügung. Es handelt sich dabei um Hardware-Infrastruktur im Rechenzentrum des Campus Muttenz, Software-Komponenten wie die Basisversion eines «Mask-RCNN»-Deep-Learning-Modells auf einem Jupyter-Notebook, sowie beschriftete Datensätze («Labels») aus einem *Crowd Contribution Webservice*. Als Eingabedaten wurde das 10cm-Orthophotomosaik *SWISSIMAGE* der *swisstopo* verwendet. Eine erste Analyse der Label-Daten zeigt die Verteilung in der Schweiz und die Zuverlässigkeit der drei Klassen: «Photovoltaik», «Solarthermie» und «Sonstige» (verwechselbare Dachstrukturen). Letztere Klasse wurde gesondert geprüft, da in vielen Fällen entweder Solaranlagen oder beispielsweise Glas-Dachfenster enthalten sind, was einen grossen Einfluss auf das Training haben kann.

2. Umsetzung des Workflows und der GIS-Darstellung

Für das Training wurden insgesamt 14 verschiedene Modelle mit unterschiedlichen Input-Datensätzen, Parametern und Klassenzusammensetzungen mit *Pytorch* trainiert. So wurden bspw. alle Klassen in einer einzigen zusammengeführt (Pooling), oder etwa jede Klasse einzeln trainiert, um Einflüsse auf die erreichbaren Genauigkeiten abzuschätzen. Um Abweichungen zwischen Prognose und Realität schneller und besser zu minimieren, wurden unterschiedliche Modell-Optimierfunktionen wie z.B. *ASGD*, *Adam* und *Adagrad* implementiert. Ein weiterer massgeblicher Faktor ist die Unterteilungsquote des Datensatzes für Training und Evaluation, die je nach Modelltyp einen grossen Einfluss auf die erreichbare Präzision haben kann. Für die Anwendung auf unbekanntem Daten (Inferenz) wurde das trainierte Modell geladen und auf den Orthophotos eines Testgebietes angewendet. Hier wurde zusätzlich eine eigene *Redetektions-Funktion* programmiert, die versetzte Bildkacheln generiert und eine vollständige Prognose der Solarflächen auch an den Bildrändern ermöglicht. Durch verschiedene automatisierte GIS-Operationen konnten die detektierten Flächen anschliessend noch zusätzlich verbessert werden.

Resultate

Die höchsten Modellgenauigkeiten wurden in einem Trainings-Durchlauf mit gepoolten Klassen erhalten und resultierten in einer Segmentpräzision von 82,5%, bzw. einer Detektionspräzision von 86,1% (IoU=0.5). Durch Labels der Klasse «Sonstige» sind jedoch noch einige Fehldetektionen enthalten. Leichte Verbesserungen können durch Auslassen der Label-Klasse «Sonstige» erreicht werden. *AdamW*- und *SGD*-Optimierungsfunktionen minimieren den Modellverlust so weit, dass alle Solaranlagen im Testgebiet erkannt werden konnten (*Abb. 1*). Die Inferenzergebnisse werden durch die implementierte Kachelversatz-Funktion erheblich verbessert und enthalten somit nur noch wenige falsche Detektionen wie Glasdächer oder ähnliche verwechselbare Dachstrukturen. Mit der GIS-Prozessierung werden die detektierten Solaranlagen nicht nur georeferenziert und durch mehrere Operationen verbessert, sondern auch in standardisierte Polygone umgewandelt, sodass weitere Informationen als Attribute hinzugefügt werden können (*Abb. 2*).



Abb. 1 & 2: links: Detektierte Solaranlagen, rechts: Umwandlung vom Raster zu Polygonen im GIS

3. Fazit und Ausblick

Auf Grundlage der verfügbaren Label-Daten konnte eine verbesserte Zusammensetzung aus den Klassen «Photovoltaik» und «Solarthermie» für das Modelltraining verwendet werden. Um den Workflow zu verbessern, konnten mehrere Modell-Optimierer sowie eine effiziente *Redetektions-Funktion* umgesetzt werden. Die resultierenden Detektionen konnte dank einer Automatisierung in einem GIS bereinigt und georeferenziert werden. In dieser Arbeit wurden alle Solaranlagen in einer einzigen Klasse zusammengefasst. Jedoch könnte ein Postklassifikations-Modell (z.B. mittels Xception-Architektur) trainiert werden sodass eine Aufteilung in Photovoltaik und Solarthermie erreicht wird. Auch neue Datengrundlagen wie etwa Falschfarben-Infrarotbilder könnten weitere Verbesserungen erbringen.

4. Kontakte

Autor:	Elia Ferrari	geom.elia.ferrari@gmail.com
Examinator:	Prof. Dr. Denis Jordan	denis.jordan@fhnw.ch
Experte:	Prof. Martin Christen	martin.christen@fhnw.ch
Betreuer:	Adrian Meyer	adrian.meyer@fhnw.ch