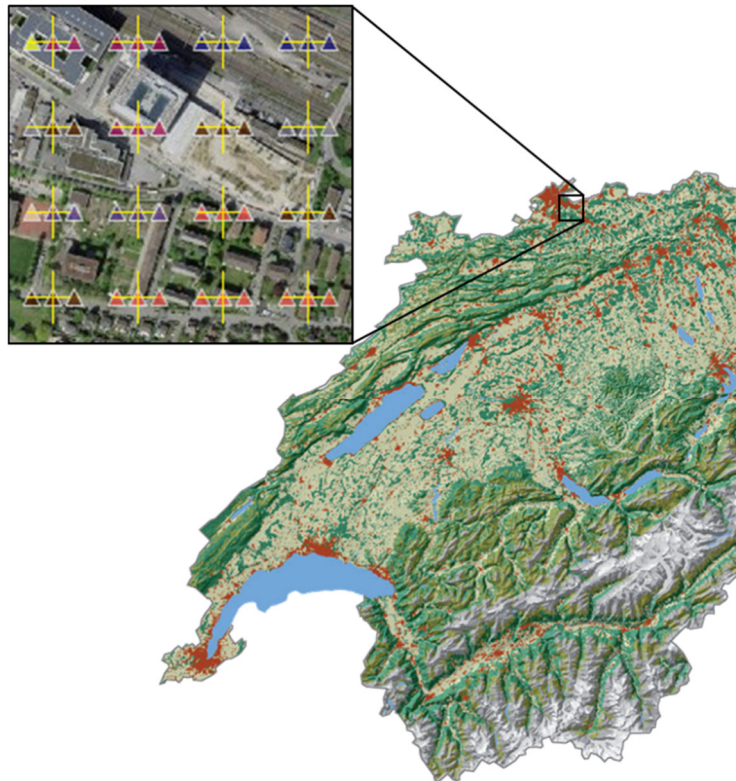


Bachelor-Thesis 2019 - 05

Deep Learning für die Arealstatistik der Schweiz: Ein multimodaler Zugang mit maschinellern Lernen

**Autor:****Nicolas Lutz****Examinator/In:****Prof. Dr. Denis Jordan
Natalie Lack****Experte:****Claudio Facchinetti****Betreuer:****Adrian Meyer**

Deep Learning für die Arealstatistik der Schweiz: Ein multimodaler Zugang mit maschinellem Lernen

Die Arealstatistik der Schweiz ist ein zentrales Instrument, mit welchem die Bodennutzung der Schweiz langfristig und raumbezogen beobachtet wird. Die Erhebung der Arealstatistik durch das Bundesamt für Statistik (BFS) erfolgt aktuell alle sechs Jahre. Dabei wird den 4.2 Millionen Stichprobenpunkten aufgrund von Luftbild- und Zusatzdaten eine Landnutzungs- und Landbedeckungsklasse zugewiesen. Um für diesen manuell durchgeführten und deshalb äusserst aufwändigen Klassifikationsprozess eine (Teil-) Automatisierung zu erreichen, wurde für das BFS ein Software Prototyp auf der Basis künstlicher Intelligenz (KI) implementiert und untersucht. Mit diesem lassen sich Stichprobenelemente in Abhängigkeit ihrer Klassen bereits mit guter Zuverlässigkeit maschinell zuordnen. Mit dem Ziel, die Klassifikationsgenauigkeit weiter zu erhöhen, erfolgte im Rahmen vorliegender Arbeit eine Weiterentwicklung des bestehenden KI Frameworks, das nun in der Lage ist, Bildkachelgrössen unterschiedlicher Grösse parallelisiert für die Klassifikation zu nutzen. Die Ergebnisse zeigen, dass die Verwendung von zusätzlichen Kachelgrössen die Klassifikationsgenauigkeit verbessert.

Schlagworte: Arealstatistik, maschinelles Lernen, Deep Learning, Fernerkundung, Satellitenbilder, Luftbilder

1. Grundlagen der Arealstatistik

Seit den 1980er Jahren führt das BFS die Arealstatistik der Schweiz nach (Abb.1). Mit der Arealstatistik werden die Punkte einer von 46 Landnutzungs- und 27 Landbedeckungsklassen zugeordnet. In dieser Arbeit soll ein Ansatz zur Verbesserung der automatisierten Erhebung der Arealstatistik geprüft und die Ergebnisse sinnvoll dargestellt werden. Untersucht wurde, ob und wie sich die Klassifikationsgenauigkeiten mit der Integration von verschiedenen Kachelgrössen (Abb. 2) verbessern lassen.



Abb. 1: Stichprobenpunkte (gelb), Dreiecke symbolisieren die Erfassungs-perioden 1979/85, 1992/97 und 2004/09 (v. l. n. r.). (map.geo.admin.ch)

2. Multimodaler Zugang zu maschinellem Lernen

Deep Learning Methoden basieren auf neuronalen Netzwerken (hier CNN) mit verschiedenen Abstraktionsschichten. Das Netz erlernt selbstständig Regeln zur Unterscheidung der Eingangsdaten aufgrund deren Merkmalen. Diese Regeln können auf weitere, neue Daten angewendet und die Bilder automatisiert der korrekten Klasse zugeordnet werden.


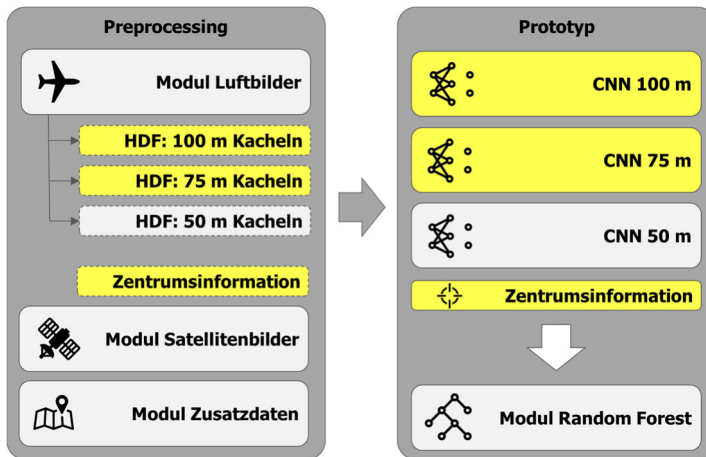


Abb. 2: Unterschiedliche Kachelgrössen

Durch die Abstraktion werden die wesentlichen Eigenschaften der Bilder extrahiert. Das Resultat einer automatischen Klassifikation ist eine Kategorie pro Eingangsbild, beispielsweise «Befestigte Flächen». Diese Klassifikation erfolgte für unterschiedliche Konstellationen der Inputvektoren.



Die Klassifikationsergebnisse und Zentrumsinformation sowie weitere Satelliten- und Hilfsdaten werden gemeinsam als Merkmalsvektor einem Random Forest (RF) präsentiert. Die Strukturveränderungen des Prototyps (Abb. 3) beziehen sich vorwiegend auf die parallele Nutzung der CNNs zur Erstellung der RF Inputs.

Abb. 3: Struktur des Prototyps AI mit den neuen (gelb), parallel genutzten Convolutional Neural Network und dem Preprocessing Modul

3. Klassifikationsresultate

Innerhalb des Untersuchungsrahmens wird mit dem bisherigen Vorgehen (Referenz) eine Gesamtgenauigkeit von 76.7 % erreicht. Durch die Verwendung aller Kacheln und der neuen Zentrumsinformation steigt die Genauigkeit auf 79.7 % und liegt damit signifikant über der Bisherigen.

Modellbezeichnung	Referenz (50 m CNN)	75 m CNN	100 m CNN	Alle CNN	Alle CNN + Zentrum
Gesamtgenauigkeit	76.7 %	77.6 %	77.5 %	79.3 %	79.7 %
Konfidenzniveau 95%	[75.1, 78.2]	[76.0, 79.1]	[75.9, 79.0]	[77.7, 80.7]	[78.2, 81.2]

Tab. 1: Gesamtgenauigkeiten der verschiedenen RF Modelle basierend auf unterschiedlichen Kachelgrößen

4. Schlussfolgerungen

Für die meisten Klassen lässt sich, mit der Nutzung von unterschiedlichen Kachelgrößen, die Klassifikationsgenauigkeit erhöhen, dies gilt auch für die bereits gut klassifizierten Klassen. Die Klassifikationsergebnisse der getesteten CNNs unterscheiden sich nur geringfügig. Durch deren Kombination in einem RF Modell wird ein komplementäres Verhalten der Netzwerke erwirkt, was letztlich zu einer Leistungsverbesserung führt.

Autor:	Nicolas Lutz	nicolaslutz@gmx.ch
Examinator/in:	Prof. Dr. Denis Jordan Natalie Lack	denis.jordan@fhnw.ch natalie.lack@fhnw.ch
Experte:	Claudio Facchinetti	claudio.facchinetti@bfs.admin.ch
Betreuer:	Adrian Meyer	adrian.meyer@fhnw.ch