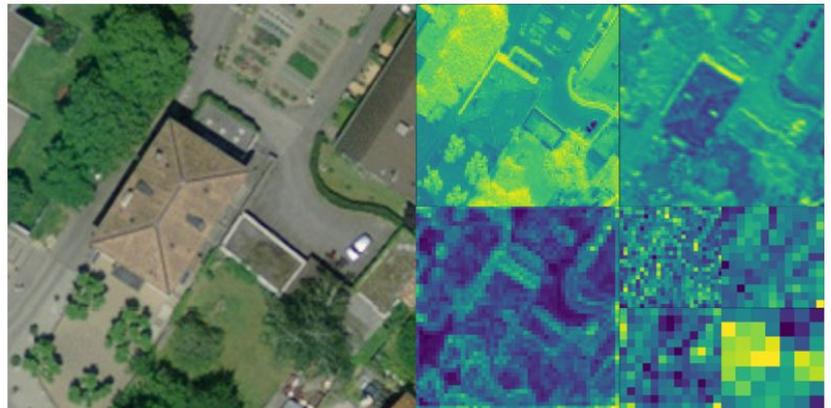


Bachelor-Thesis 2018 - 13

Deep Learning für die Arealstatistik Schweiz: weiterführende Analysen zur automatisierten Erfassung von Veränderungen in der Landnutzung



Autor: Stefan Hochuli

Examinator/in: Prof. Dr. Denis Jordan
Natalie Lack

Experte: Prof. Dr. Stephan Nebiker

Deep Learning für die Arealstatistik Schweiz: weiterführende Analysen zur automatisierten Erfassung von Veränderungen in der Landnutzung

Die Arealstatistik der Schweiz wird periodisch mit grossem personellem Aufwand erfasst. Mit weiterführenden Analysen zur Bachelor-Thesis 2017-10 soll aufgezeigt werden, wie sich die Erfassung der Arealstatistik zuverlässig mittels Deep Learning automatisieren lässt. Mit einem in Python implementierten Framework wurde untersucht, ob der Algorithmus automatisch das Kachelzentrum fokussiert und wie sich Veränderungen zwischen zwei Erfassungsperioden detektieren lassen.

Schlagworte: Deep Learning, Fernerkundung, Arealstatistik, Luftbilder, Klassifikation, Veränderungsanalyse, Python, Keras

1. Einführung

Die *Arealstatistik* der Schweiz wird vom Bundesamt für Statistik (BFS) erfasst. Über ein regelmässiges Gitter von 100x100 Metern sind mehr als 4.2 Millionen Stichproben (Luftbilder swisstopo) über die Schweiz verteilt. Zu jeder Stichprobe wird die Bodennutzung sowie deren Bedeckung bestimmt und einer von 72 Klassen zugeteilt. Der Mittelpunkt jeder Kachel ist entscheidend für die Zuteilung. Allein aus Luftbildern sind Unterschiede zwischen einzelnen Klassen (Abb. 1 & 2) teilweise nicht erkennbar. Deshalb nutzt das BFS weitere Informationen, wie zum Beispiel Daten der Amtlichen Vermessung oder die Landeskarte der Schweiz.



Abb. 1 Naturwiesen



Abb. 2 Alpweiden (alle Luftbilder von swisstopo)

Diese Arbeit baut auf den Erkenntnissen der Bachelor-Thesis 2017 - 10 von M. Schär auf, in der ein geeignetes *neuronales Netz* als Methode des Maschinellen Lernens vorgeschlagen wurde. Seine Erkenntnis war, dass trotz der grossen Menge an Stichproben viele der 72 Kategorien stark untervertreten waren und dadurch nur schlecht detektiert wurden. Ausserdem war nicht klar, ob der Algorithmus die starke Fokussierung auf das Zentrum erlernt, oder ob er zusätzlich darauf hingewiesen werden muss.

2. Deep Learning für die Arealstatistik

Beim Deep Learning (DL) werden spezielle neuronale Netze mit einer Vielzahl an Schichten verwendet. Dem Netz werden sowohl die Eingangsdaten (hier Luftbilder), als auch die zugehörige Klassenzuordnung (hier die Kategorien der Arealstatistik) präsentiert. Während dem Lernprozess generiert das Netz Regeln, die einen Zusammenhang zwischen Eingangsdaten und deren Klassenzuordnung aufzeigen. Die Aufgabe des Algorithmus besteht darin, neue, ihm unbekannte Daten, automatisch der korrekten Klasse zuzuweisen. Auf dem Titelbild durchläuft das Eingangsbild sämtliche Schichten und wird dabei verändert und abstrahiert um klassenrelevante Eigenschaften zu extrahieren. Das abschliessende Ergebnis einer automatisierten Klassifikation ist die Kategorie des Eingangsbildes, zum Beispiel «Mehrfamilienhaus».

3. Resultate

Wegen den stark unausgeglichenen Kategorien wurde der Datensatz für die Trainings-, Validierungs- und Testdaten drastisch reduziert. Für jede der 72 Kategorien wurden maximal 2000 Stichproben ausgewählt. Dadurch waren die Trainingsdaten homogen über alle Klassen verteilt. Dank dem ausgeglichenen Datensatz stieg die Gesamtgenauigkeit von 36.5% (BTh 2017-10) auf 50.5%. Die höchste Klassengenauigkeit betrug 88.2%.

Zur Fokussierung auf den Bildmittelpunkt wurde eine Zentrumskachel separat zur Bildkachel in ein erweitertes Netz eingeführt und verarbeitet, wie in Abb. 3 dargestellt. Zur Klassifikation wurden sie zusammengeführt und gemeinsam zugeordnet.

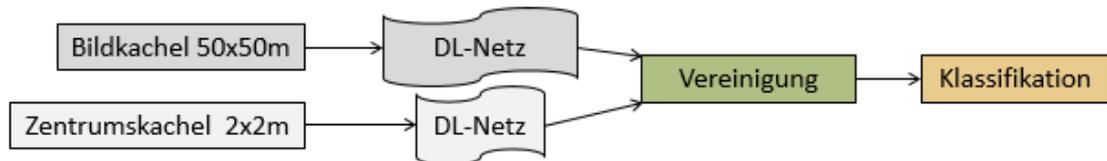


Abb. 3 Separate Verarbeitung der Bild- und Zentrumsinformationen

Sowohl dieser Ansatz wie auch veränderte Bilder führten zu keiner Steigerung der Klassifikationsgenauigkeiten. Dies ist ein Hinweis, dass das neuronale Netz den starken Fokus der Arealstatistik auf den Kachelmittelpunkt erlernen kann.

Für die Veränderungsanalyse wurden Differenzbilder (Abb. 6) der Erfassungsperiode 2004/09 (Abb. 4) und 2013/18 (Abb. 5) erstellt. Veränderungen konnten zuverlässig festgestellt werden, wenn nicht zu viele Störfaktoren die Differenzbilder beeinflussten. Störfaktoren können z.B. unterschiedliche Schattenwürfe oder Vegetationsstände sein.



Abb. 4,5 & 6 Kacheln aus zwei Erfassungsperioden und das Differenzbild

4. Fazit

Ausgeglichene Ausgangsdaten führen zu ausgeglichenen Klassifikationsresultaten. Die Problematik der zu ähnlichen Klassen besteht weiterhin. Zusätzliche Daten, wie Höhenmodelle oder Informationen der Amtlichen Vermessung, lassen sich wie im Workflow in Abb. 4 integrieren und stellen einen vielversprechenden Ansatz dar, die Methodik weiter zu verbessern.

Autor:	Stefan Hochuli	stefanhochuli@gmx.ch
Examinator/in:	Prof. Dr. Denis Jordan Natalie Lack	denis.jordan@fhnw.ch natalie.lack@fhnw.ch
Experte:	Prof. Dr. Stephan Nebiker	stephan.nebiker@fhnw.ch