

Substratkartierung in alpinen Ökosystemen mit Deep-Learning-Objektdetektoren

Die Bedeutung von Gewässern ist unbestritten, entweder als Wasserlieferant für die Stromproduktion und die Landwirtschaft oder als Lebensraum für Tiere und als Naherholungsgebiet für den Menschen. Besonders alpine Gewässer sind durch ausserordentliche Ereignisse wie Sturzfluten und Hochwasser einem ständigen Wandel unterworfen. Als Schlüsselindikator für den Zustand eines Gewässers dient die Verteilung des Flussgeschiebes, dem sogenannten Substrat. In dieser Arbeit werden bildbasierte Deep-Learning-Ansätze zur Kartierung von Substratflächen untersucht und mit Referenzerhebungen verglichen. Mit automatisierten Workflows werden Daten des Projektpartners Kraftwerke Oberhasli AG verarbeitet, neuronale Netzwerke trainiert und Substratflächen detektiert.

Ausgangslage und vorhandene Ansätze

Konventionelle Substratkartierungen basieren auf manuellen Feldkartierungen und Linienzahlanalysen. Ansätze für die Erfassung mit Laserscanning und Luftbildaufnahmen bestehen, stützen sich aber für die Substratableitung meistens auf geometrische Eigenschaften wie die Rauigkeit und selten auch auf Einzelbildklassifikationen ab. Grossflächige Kartierungen mit automatisierten bildbasierten Verfahren sind nicht vorhanden.

Zielsetzung

In dieser Arbeit wurden Deep-Learning-Detektoren zur Substratkartierung mit georeferenzierten Bilddaten untersucht. Zwei durchgängige Workflows mit unterschiedlichen Detektionsansätzen (Workflow A Objektdetektion / Workflow B Semantische Segmentation) konnten erstellt, die Netzwerke trainiert und angewendet werden. Weiter wurden die Anforderungen an das Bildmaterial getestet und die Detektionsresultate mit Referenzverteilungen verglichen.

Entwicklung Workflows

Georeferenziertes Bildmaterial von lokal gespeicherten Orthophotos oder vom WMS-Dienst SWISSIMAGE werden zusammen mit Trainingsdaten aufbereitet und in ein neuronales Netzwerk für das Training und die Detektion eingespeist. Die Detektionen werden als georeferenzierte Flächen im Shape-Format ausgegeben und können direkt weiterverwendet werden. Die Workflows sind als geodaten- und MultiClass-fähige open-source Anwendung in Python und auf Google Colaboratory umgesetzt.

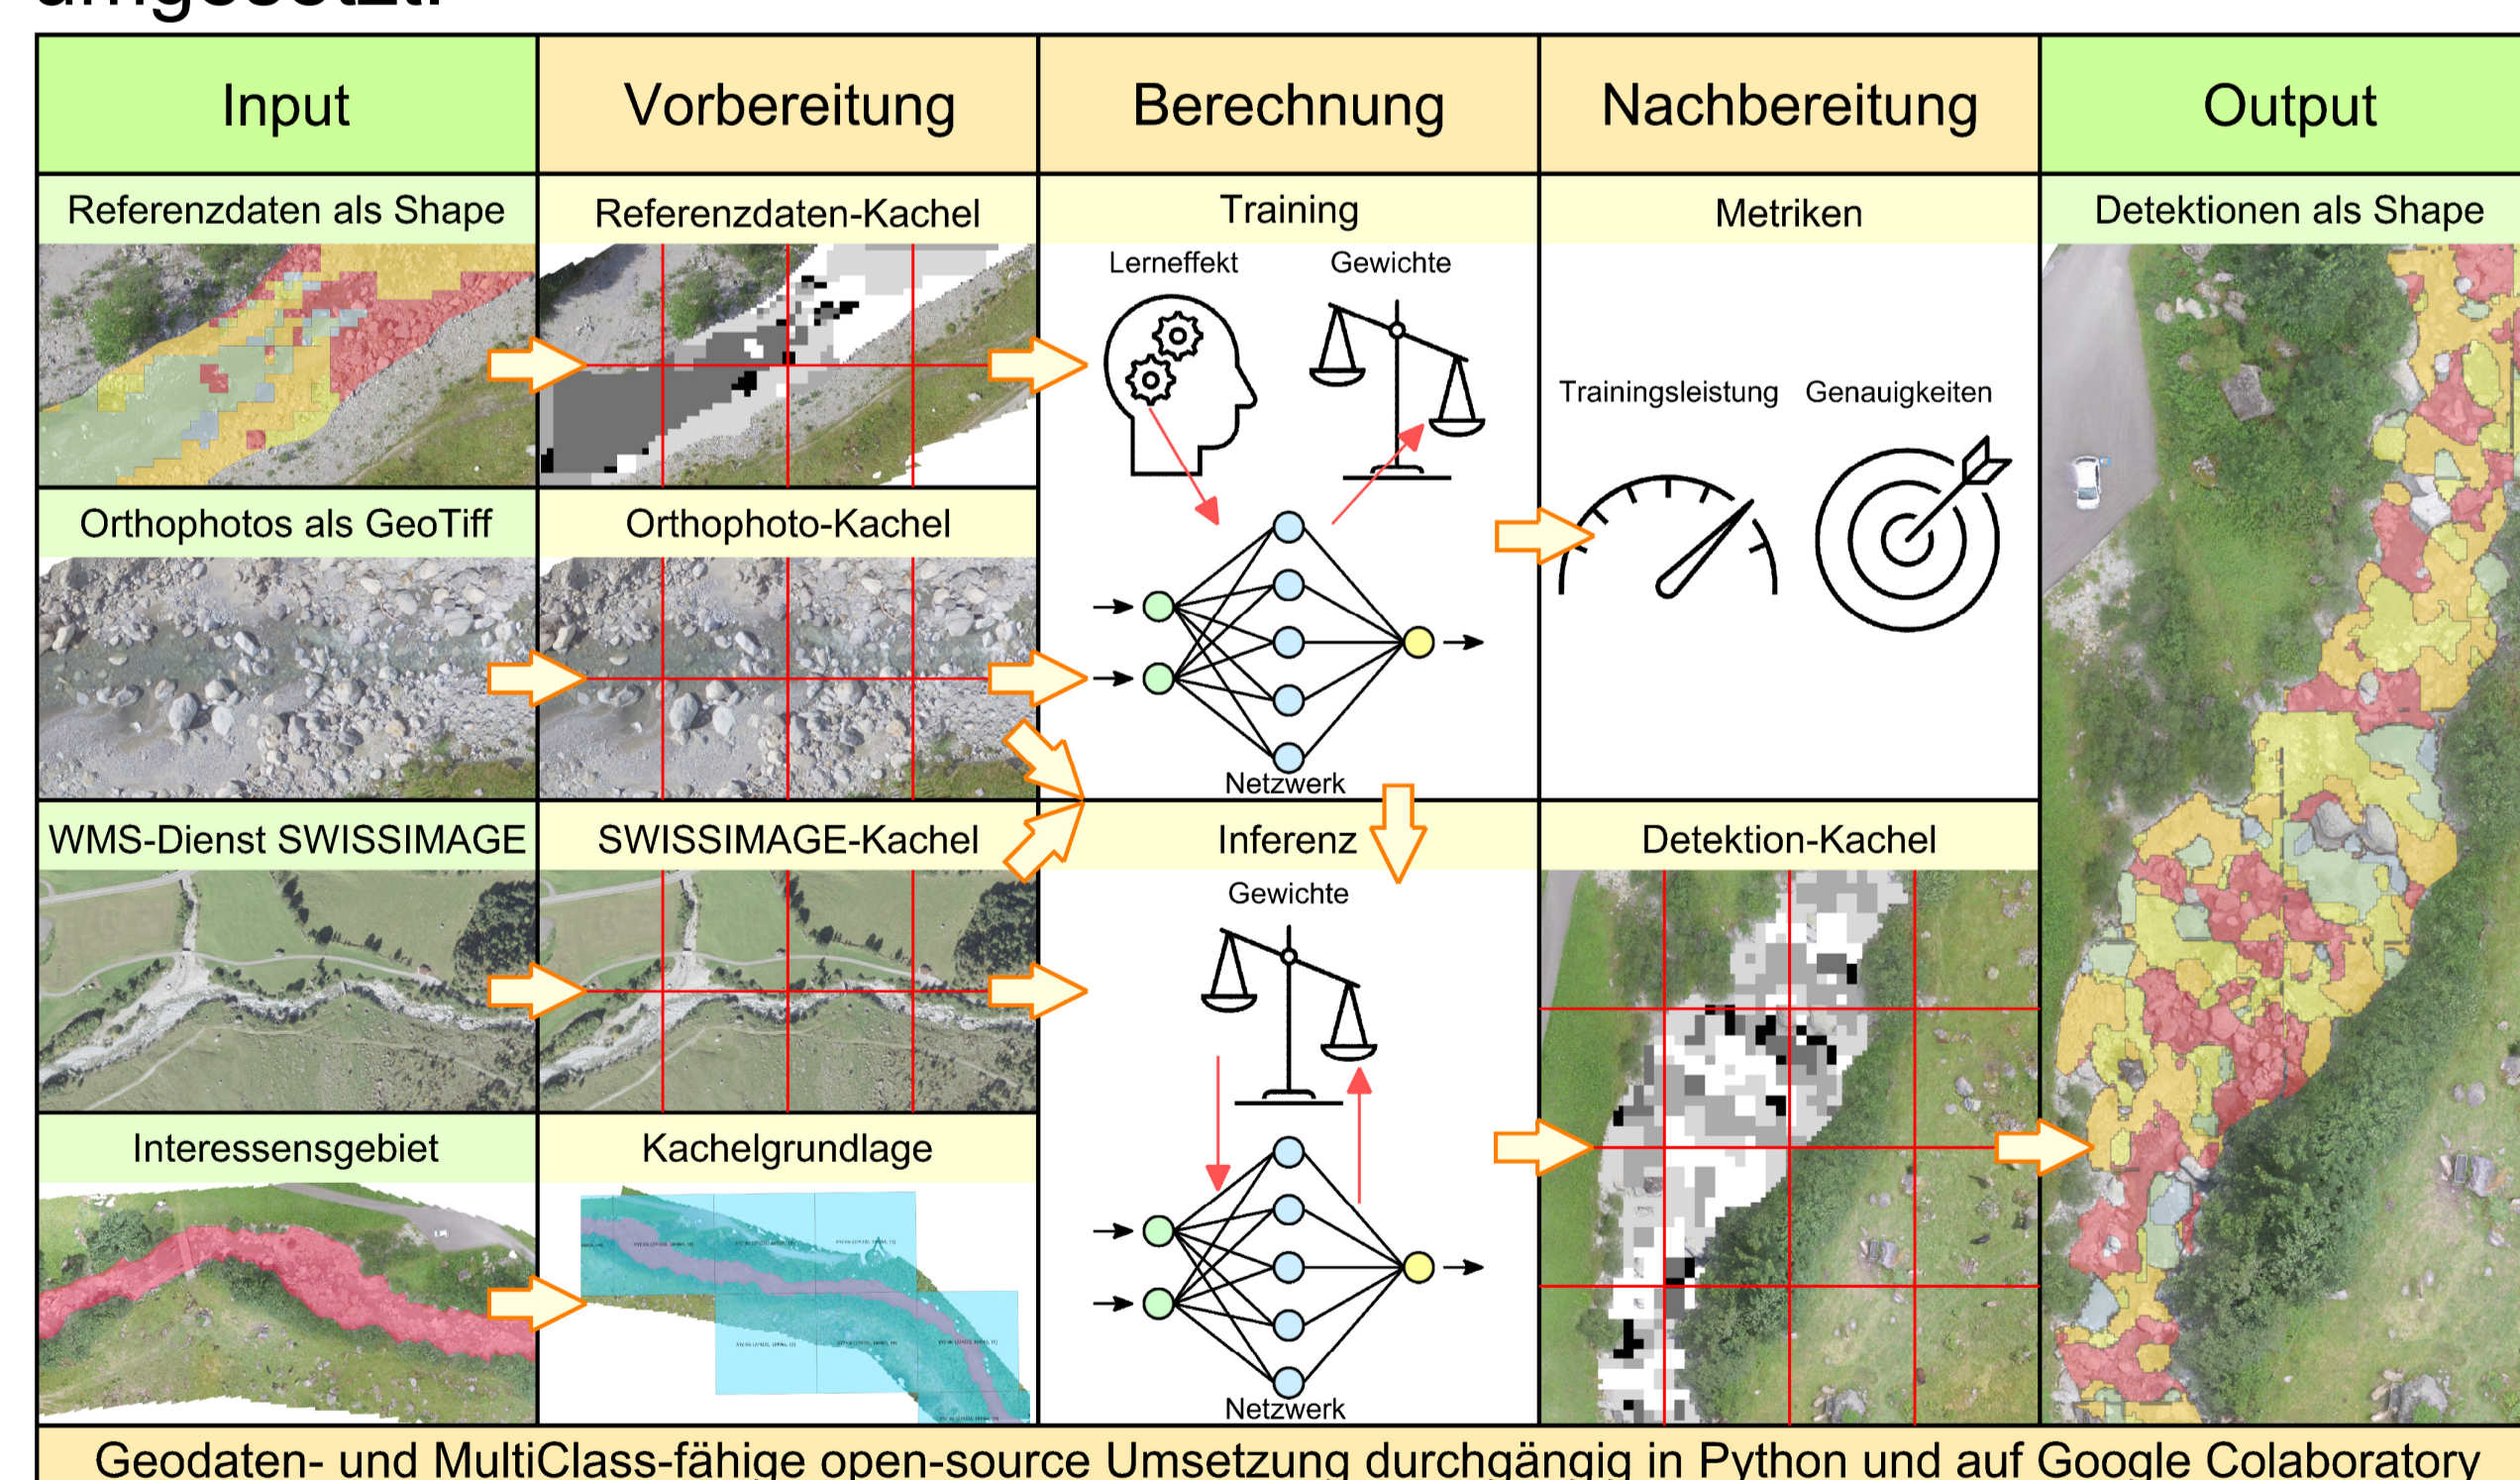


Abb. 1: Workflow B Semantische Segmentation

Versuchsaufbau und Modelltraining

Mit einem Versuchsaufbau konnten die Leistungsfähigkeit der Workflows und der verwendeten Detektionsansätze an unterschiedlichen Bodenauflösungen (3cm/5cm/10cm/25cm) und Bildquellen (lokale Orthophotos / SWISSIMAGE) überprüft werden. Für Workflow A Objektdetektion wurde Detectron2/ResNet50 und für Workflow B Semantische Segmentation U-Net/MobileNet_v2 und U-Net/ResNet50 verwendet.

Autor: Patrick Keusch

Examinatoren: Prof. Dr. Denis Jordan, Adrian Meyer

Experten: Jan Baumgartner, Benjamin Berger

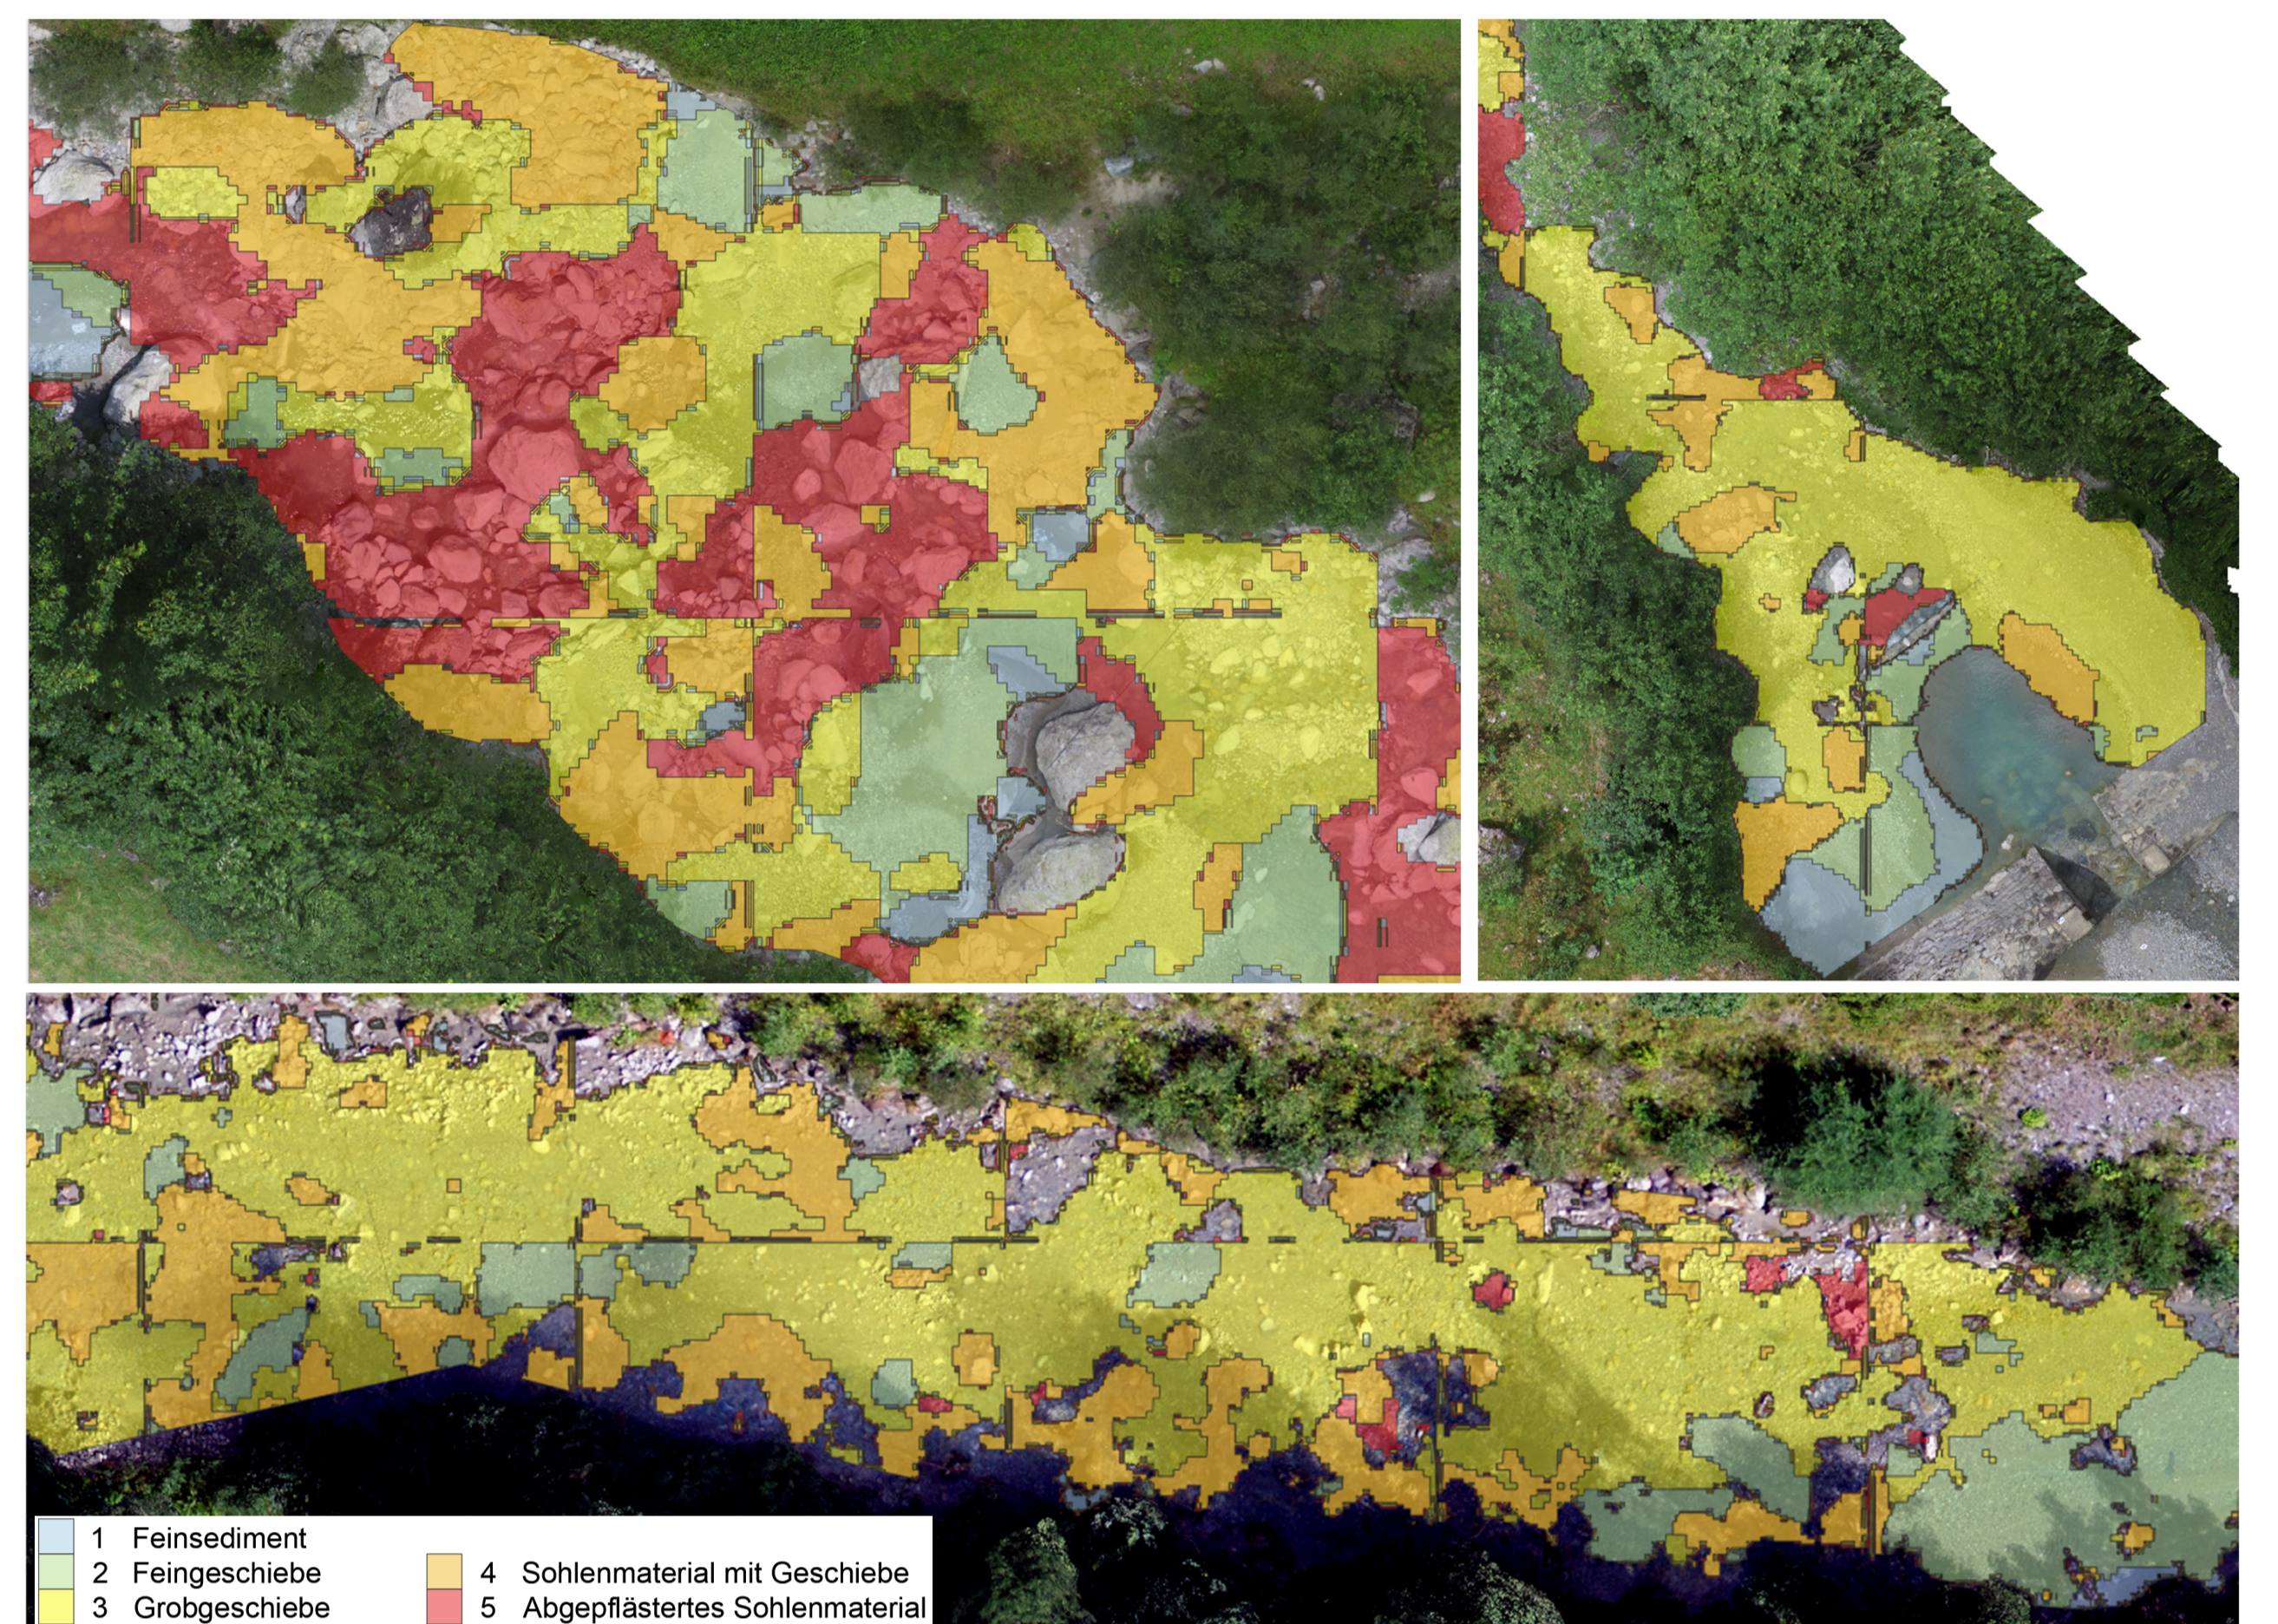


Abb. 2: Detektionsresultate Semantische Segmentation mit ResNet50

Resultate

Ein Trainingseffekt mit vergleichbaren Genauigkeitswerten konnte bei beiden Workflows besonders bei hohen Auflösungen beobachtet werden. Die visuelle Betrachtung der Detektion (Abb. 2) zeigt für hohe Auflösungen plausible Resultate. Bereiche mit niedrigen Wasserständen werden erkannt und Vegetation oder tiefe Bereiche konsequent ausgeschieden. Vereinzelt sind fehlende Detektionen in dunklen/schattigen Bereichen erkennbar. Für die Beurteilung des Gewässerzustandes ist die Verteilung der Substratflächen und weniger die absolute Richtigkeit entscheidend. Eine Histogrammgegenüberstellung der detektierten Flächen und einer manuell digitalisierten Referenzverteilung sowie einer Verteilung anhand von geometrischen Rauigkeitsindikatoren zeigt, dass eine Semantische Segmentation mit ResNet50 die Referenzverteilung am treffendsten nachmodellieren kann. Eine Verschlechterung mit abnehmender Bodenauflösung ist auch hier feststellbar.




Abb. 3: Verteilung Detektionen Semantische Segmentation mit ResNet50 (grau) und Referenzverteilung (rot) zu manueller Digitalisierung (links) und Rauigkeitsansatz (rechts)

Fazit

Die entwickelten Workflows funktionieren und die offene Umsetzung ist zielführend. Die Semantische Segmentation mit ResNet50 bei 3cm Bodenauflösung zeigt die erfolgversprechendsten Resultate, während bereits ab 5cm eine starke Abnahme der Leistung auftritt. Die Validierung anhand der Referenzverteilungen zeigt, dass die Eignung von bildbasierten Deep-Learning-Ansätzen für die Substratkartierung gegeben ist.