

HENRY

Hydraulic Engineering Repository

Ein Service der Bundesanstalt für Wasserbau

Conference Paper, Published Version

Irniger, Andrea; Rozniak, Angieszka; Lang, Nico; Wegner, Jan Dirk; Schindler, Konrad; Hunziker, oni

GRAINet: Automatische Kornverteilungsanalysen aus Drohnen-Bildern mit CNNs

VAW Mitteilungen

Zur Verfügung gestellt in Kooperation mit/Provided in Cooperation with:

ETH Zürich, Versuchsanstalt für Wasserbau, Hydrologie und Glaziologie (VAW)

Verfügbar unter/Available at: <https://hdl.handle.net/20.500.11970/108429>

Vorgeschlagene Zitierweise/Suggested citation:

Irniger, Andrea; Rozniak, Angieszka; Lang, Nico; Wegner, Jan Dirk; Schindler, Konrad; Hunziker, oni (2021): GRAINet: Automatische Kornverteilungsanalysen aus Drohnen-Bildern mit CNNs. In: Boes, Robert (Hg.): Wasserbau-Symposium 2021. Wasserbau in Zeiten von Energiewende, Gewässerschutz und Klimawandel. Band 2. VAW Mitteilungen 263. Zürich: ETH Zürich, Versuchsanstalt für Wasserbau, Hydrologie und Glaziologie. S. 399-407.

Standardnutzungsbedingungen/Terms of Use:

Die Dokumente in HENRY stehen unter der Creative Commons Lizenz CC BY 4.0, sofern keine abweichenden Nutzungsbedingungen getroffen wurden. Damit ist sowohl die kommerzielle Nutzung als auch das Teilen, die Weiterbearbeitung und Speicherung erlaubt. Das Verwenden und das Bearbeiten stehen unter der Bedingung der Namensnennung. Im Einzelfall kann eine restriktivere Lizenz gelten; dann gelten abweichend von den obigen Nutzungsbedingungen die in der dort genannten Lizenz gewährten Nutzungsrechte.

Documents in HENRY are made available under the Creative Commons License CC BY 4.0, if no other license is applicable. Under CC BY 4.0 commercial use and sharing, remixing, transforming, and building upon the material of the work is permitted. In some cases a different, more restrictive license may apply; if applicable the terms of the restrictive license will be binding.

Verwertungsrechte: CC BY 4.0



***GRAINet*: Automatische Kornverteilungsanalysen aus Drohnen-Bildern mit CNNs**

GRAINet: Automatic grain size distribution analysis from UAV images with CNNs

**Andrea Irniger, Angieszka Rozniak, Nico Lang, Jan Dirk Wegner,
Konrad Schindler, Roni Hunziker**

Kurzfassung

In diesem Beitrag wird eine neue Methodik *GRAINet* (Lang *et al.*, 2021) vorgestellt, die eine automatische Bestimmung der Kornverteilungskurven auf Kiesbänken mit Drohnenbildern erlaubt. Der Ansatz basiert auf einem *convolutional neural network* (CNN). Für das Training standen 1'491 Kornverteilungskurven von sechs Schweizer Flüssen zur Verfügung. *GRAINet* ermöglicht i) die Bestimmung einer aussagekräftigen, über eine Kiesbank gemittelten Kornverteilungskurve und ii) die grossflächige und hochauflösende Kartierung der mittleren Korn Durchmesser dm . Die resultierenden Karten weisen einen mittleren Fehler (ME) <0.1 cm und einen mittleren absoluten Fehler (MAE) von 1.1 cm auf. Bei einer Mittelung des dm über die gesamte Kiesbank reduziert sich der MAE auf 0.3 cm. Somit bietet *GRAINet* ein grosses Potenzial für das Monitoring und die Defizitanalyse bei der Sanierung Geschiebehaushalt sowie für die Kalibrierung numerischer Geschiebetransportmodelle.

Abstract

In this paper a new methodology *GRAINet* (Lang *et al.*, 2021) is presented, which allows an automatic estimation of grain size distributions on gravel bars from UAV images. The approach is based on a convolutional neural network (CNN), where 1'491 grading curves of six Swiss rivers were available for training. *GRAINet* allows i) the determination of a robust grading curve averaged over a gravel bank and ii) the large-scale and high-resolution mapping of mean grain diameters dm . The resulting maps have a mean error (ME) <0.1 cm and a mean absolute error (MAE) of 1.1 cm. If the dm is averaged over the entire gravel bar, the MAE is reduced to 0.3 cm. Thus, *GRAINet* offers great potential for monitoring and deficit analysis in bedload management and for the calibration of numerical bedload transport models.

1 Einleitung

Die Kornverteilung auf Kiesbänken ist ein Schlüsselindikator zur Beurteilung der

Sedimentdynamik eines Flusses sowie für die Berechnung des Geschiebetransports. Heute stehen oft nur einzelne Proben zur Verfügung, weil einerseits die traditionellen Messungen im Feld (Linien- und Volumenproben) zeit- und kostenintensiv sind und andererseits bestehende, bildbasierte Methoden, z.B. BASEGRAIN (Detert & Weitbrecht, 2012) oder SediNet (Buscombe, 2019), nur punktuell anwendbar und aufgrund der händischen Parameterwahl oder der begrenzten Trainingsdatensätze limitiert sind. Im Rahmen dieses Fachbeitrags wird eine neue Methodik *GRAINet* (Lang *et al.*, 2021) vorgestellt, welche die direkte Regression der Kornverteilung und der mittleren Korndurchmesser (dm) aus Drohnenbildern mittels eines *convolutional neural network* (CNN) automatisch und grossflächig ermöglicht.

2 Methodik

2.1 Daten

Für das Training des CNNs wurden Linienproben nach Fehr (1987) aus den Orthofotos digitalisiert, welche hier als Referenzdaten¹ bezeichnet werden. Dazu wurden an sechs verschiedenen Flüssen mit total 25 Standorten mittels einer Drohne (DJI-Phantom 4 Pro) Orthofotos mit einer Auflösung von 0.25 cm/Pixel aufgenommen. Die Orthofotos wurden in Kacheln (1.25 m x 0.50 m) unterteilt, auf welchen am Computer *manuell* Polygone um 100-150 Steine entlang der Mittellinie gezeichnet wurden (1, Abb. 1). Anschliessend wurde in einem automatisierten GIS-Algorithmus die B-Achse gemessen (2, Abb. 1), woraus die relative Häufigkeitsverteilung der Kornklassen abgeleitet wurde (3, Abb. 1). Schliesslich wurde mit dem Verfahren nach Fehr (1987) die Kornverteilungskurve (*KVK*) berechnet (4, Abb. 1).

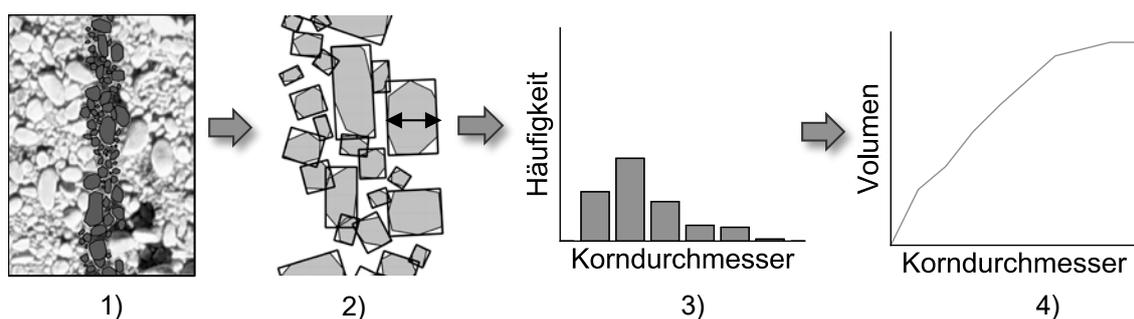


Abb. 1: Algorithmus zur Auswertung der digitalen Linienproben

Insgesamt wurden 1'491 Kacheln ausgewertet, was >180'000 Steinen entspricht. Die Anzahl ausgewerteter Kacheln pro Kiesbank variiert zwischen 4 (*Reuss km*

¹ Es wird somit davon ausgegangen, dass die Linienzahlanalyse nach Fehr (1987) für diese Fragestellung gültig ist und die digitalen Linienproben repräsentativ sind.

021.4) und 212 (Kl. Emme km 030.3). Die *dm* der Referenzdaten umfassen eine Bandbreite von 1.3 cm bis 29.3 cm, wobei der Mittelwert 6.2 cm beträgt. Zur Überprüfung der Gültigkeit des GIS basierten Ansatzes standen an 22 Standorten im Feld aufgenommene Linienproben zur Verfügung und 17 Kacheln wurden von fünf Experten digitalisiert, damit die Qualität der Modelle der menschlichen Variabilität gegenübergestellt werden konnte.

2.2 Regression der KVK mit GRAINet

CNNs sind generische *Machine Learning* Modelle, welche charakteristische Muster in Textur und Spektrum erlernen können. Im Gegensatz zur klassischen Bildverarbeitung werden die Bildfilter (Netzwerkparameter) nicht manuell definiert, sondern mit einem Optimierungsverfahren direkt aus den Referenzdaten gelernt. *GRAINet* (Lang *et al.*, 2021) basiert auf dem *ResNet* Modell von He *et al.* (2016). Das CNN extrahiert Muster aus einer Kachel von 500x250 Pixel und schätzt eine Verteilung oder ein Skalar direkt mittels einer Regression. Einzelne Steine werden nicht explizit detektiert. Stattdessen werden globale Muster extrahiert, die mit der Zielgrösse korrelieren. *GRAINet* wurde mit drei Zielgrössen getestet:

1. Die relative Häufigkeitsverteilung (*GRAINet frequency*)
2. Die relative Volumenverteilung (*GRAINet volume*)
3. Der mittlere Korndurchmesser (*GRAINet dm*)

2.3 Evaluierung

Die drei Modelle wurden mit den folgenden zwei Strategien trainiert und getestet:

Kreuzvalidierung: Die Referenzdaten werden zufällig in zehn, disjunkte Teilmengen geteilt. Im Training stehen dann neun Teilmengen zur Verfügung (Kacheln von jeder Bank). Die Qualität wird auf der zehnten Teilmenge getestet.

Generalisierung: Um die Generalisierung für eine neue Kiesbank zu testen, stehen im Training alle Referenzdaten zur Verfügung, ausser diejenigen, die zur testenden Bank gehören.

2.4 Endprodukte

Die Resultate der Modelle *GRAINet frequency* und *volume* wurden anschliessend mit dem Ansatz nach Fehr (1987) kombiniert und damit die *KVK* sowie der *dm* abgeleitet. Die Methodik erlaubt dank der Vielzahl der georeferenzierten Resultate die Generierung zweier relevanten Produkte:

- I. Aussagekräftige, über die Bank gemittelte *KVK* und *dm*.
- II. Hochaufgelöste und grossflächige Karten der räumlichen Verteilung der *dm*.

3 Resultate und Diskussion

3.1 Gültigkeit der digitalisierten Referenzdaten

Bei 22 Standorten konnten die dm der Referenzdaten mit zwei bis drei im Feld aufgenommenen Linienproben auf Bankebene verglichen werden (Abb. 2). Der Mittelwert der im Feld aufgenommenen dm liegt bei allen Standorten innerhalb der minimalen und maximalen dm der Referenzdaten und stimmt gut mit dem Mittelwert der digitalen Referenzdaten überein. Somit sind die digitalisierten Referenzdaten repräsentativ und zeigen keine systematischen Unterschiede zu klassischen Linienproben auf.

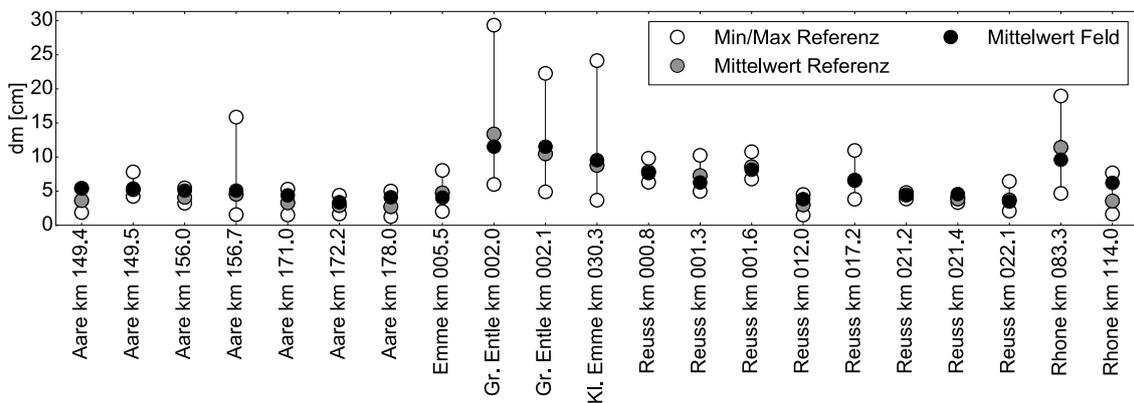


Abb. 2 Vergleich der digitalisierten Referenzdaten und der im Feld aufgenommenen Linienproben

3.2 Kornverteilungskurven

Die Qualität der mit *GRAINet frequency* und *volume* prädizierten, über die jeweilige Kiesbank gemittelten *KVK* wird an drei Standorten qualitativ vorgestellt (Abb. 3). Die Beispiele zeigen, dass mit beiden Modellen die Form der *KVK* bestimmt werden kann, wobei aber bei feineren Kiesbänken die größeren Kornklassen mit *frequency* tendenziell überschätzt werden (*Aare km 171.0 km*, Abb. 3).

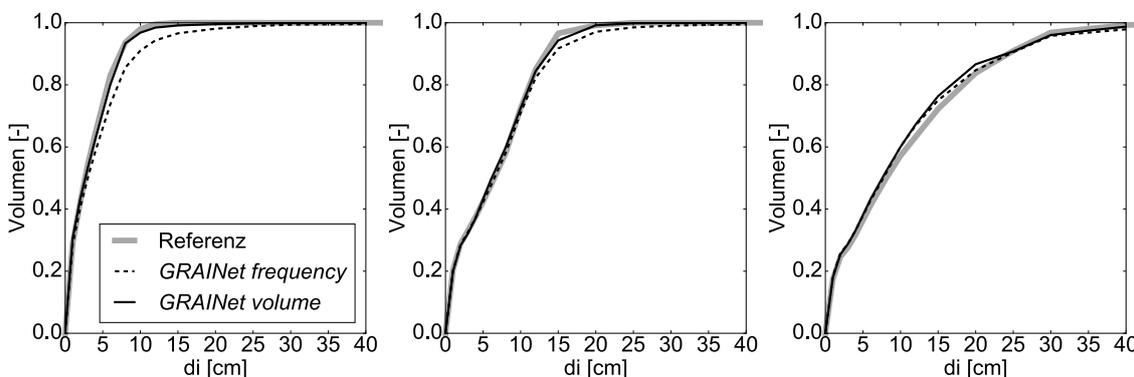


Abb. 3 Über die gesamte Bank gemittelte Kornverteilungskurve mit *GRAINet frequency* und *volume* (Kreuzvalidierung) im Vergleich zu den Referenzdaten . Von links nach rechts: *Aare km 171.0 km*, *Reuss km 017.0* und *Grosse Entle km 002.1*

3.3 Qualität des dm

3.3.1 Vergleich der drei Modelle zur Schätzung des dm

Werden die prädizierten dm den Referenzdaten gegenübergestellt (Abb. 4), so ist der mittlere Fehler (ME) bei allen Modellen innerhalb ± 1.0 cm, bzw. der mittlere absolute Fehler (MAE) < 1.5 cm, wobei die Streuung der Modelle bei grösseren dm zunimmt. So beträgt beispielsweise der MAE ($GRAINet\ dm$) für Kacheln mit $dm < 3.0$ cm 0.7 cm und ist deutlich kleiner als derjenige für Kacheln mit $dm > 10.0$ cm (MAE : 2.2 cm). Dies ist auf die kleinere Anzahl Referenzdaten (nur 14% > 10 cm) sowie die grössere Variabilität von gröberen KVK zurückzuführen. Die Qualität der prädizierten dm ist mit $GRAINet\ dm$ am besten (ME : +0.02 cm, MAE : 1.05 cm), da nur dieser Ansatz mit prädizierten dm von 1.3 cm bis 24.4 cm die Bandbreite der Referenzdaten umfänglich reproduziert. Bei $GRAINet\ frequency$ und $volume$ werden die kleinen dm tendenziell über- und die grösseren dagegen unterschätzt.

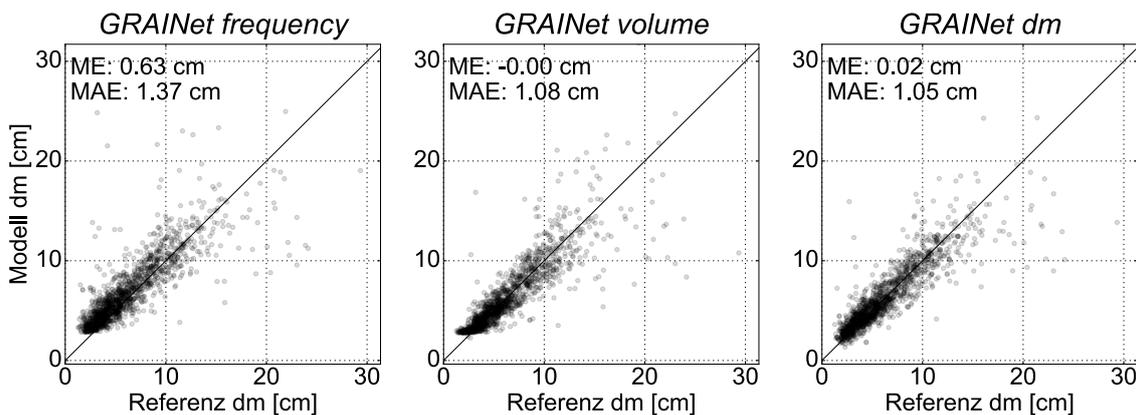


Abb. 4 Gegenüberstellung der Referenz dm und der prädizierten dm (Kreuzvalidierung)

3.3.2 Qualität des Modells im Vergleich zur menschlichen Variabilität

Da das $GRAINet\ dm$ die besten Ergebnisse bezüglich des dm aufweist, wird die Qualität dieses Modells mit der Variabilität von fünf Experten verglichen (Abb. 5). Bei 17, zufällig ausgewählten Kacheln variiert die Standardabweichung σ zwischen 0.1 cm (*Aare km 172.2*) und 2.0 cm (*Rhone km 083.3*). Die mittlere σ beträgt 0.5 cm. Der prädizierte dm liegt bei 9 Kacheln innerhalb von 1σ und bei 12 innerhalb von 2σ . Obwohl CNNs beim Training robust gegen dieses Rauschen sind, kann bei der Schätzung einer einzelnen Linienprobe der erwartete $MAE < 0.5$ cm werden, da die Referenzwerte des Testdatensatzes ebenfalls mit diesem Rauschen behaftet sind.

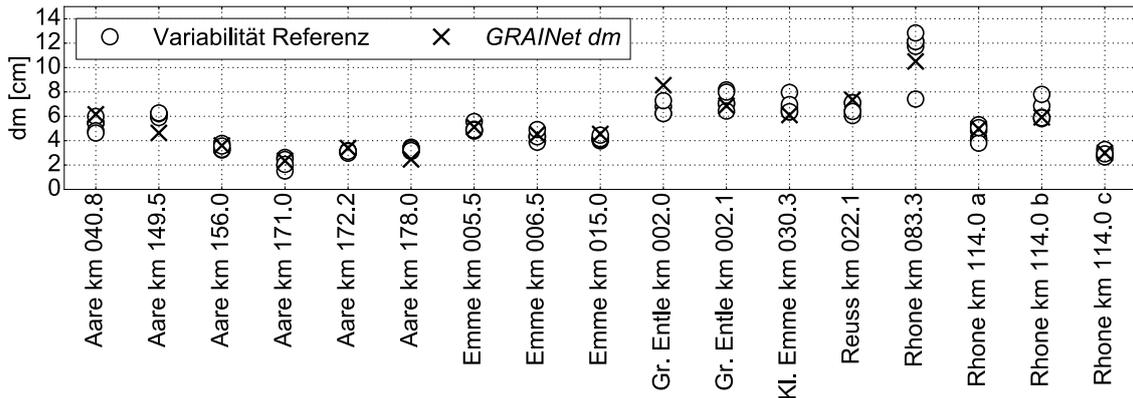


Abb. 5 Variabilität der mittleren Korndurchmesser pro Kachel, welche von jeweils fünf Experten digitalisiert wurden (Variabilität Referenz) im Vergleich zu den prädizierten *dm*

3.3.3 Analyse pro Kiesbank

Für den Aufbau und die Kalibrierung von Geschiebetransportmodellen ist eine repräsentative Beschreibung des über eine Kiesbank gemittelten *dm* relevant. Zur Beurteilung, ob *GRAINet dm* dafür verwendet werden kann, wurden die prädizierten *dm* einer Kiesbank gemittelt und demjenigen der Referenzdaten gegenübergestellt (Abb. 6).

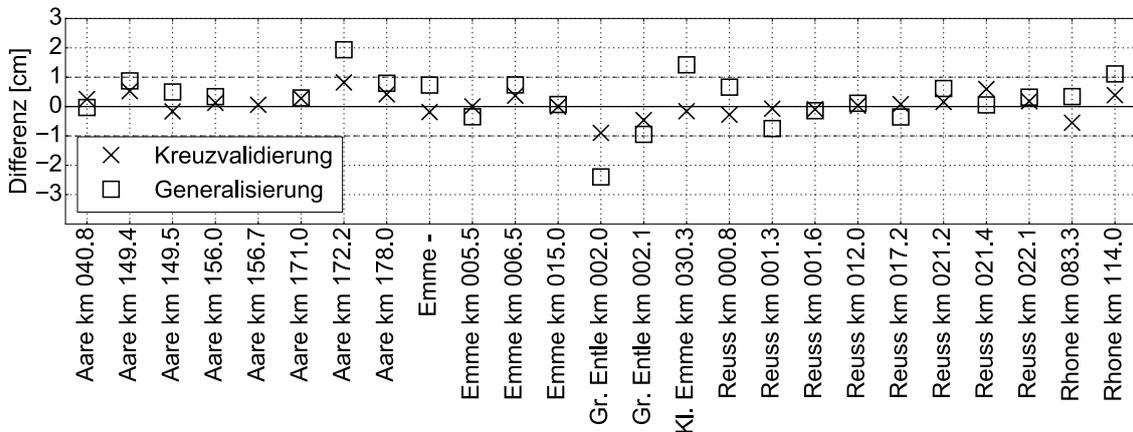


Abb. 6 Differenz zwischen des über eine Kiesbank gemittelten, mit *GRAINet dm* prädizierten *dm* und den Referenzdaten (ebenfalls über die Kiesbank gemittelt)

Kreuzvalidierung: Bei allen 25 Standorten liegt die Abweichung des über die Kiesbank gemittelten *dm* gegenüber demjenigen der Referenzdaten innerhalb von ± 1.0 cm; bei 13 Standorten (d. h. bei mehr als der Hälfte) sogar innerhalb von ± 0.2 cm. Werden die Differenzen aller Kiesbänke gemittelt, wird ein *MAE* von 0.3 cm erreicht, weshalb die Qualität als genügend beurteilt werden kann.

Generalisierung: Wenn während des Trainings die Referenzdaten der jeweiligen Kiesbank nicht gezeigt werden (Abb. 6), nimmt die Qualität der prädizierten *dm*

ab. Bei 20 Standorten liegt die Abweichung innerhalb ± 1.0 cm; bei 5 davon innerhalb von ± 0.2 cm. Ein grosser Unterschied ist bei der Bank *Aare km 156.7* zu beobachten, bei welcher die Abweichung von 0.06 cm auf 4.92 cm zunimmt. Dies ist dadurch zu erklären, dass dies die einzige Bank ist, bei welcher nasse Steine digitalisiert wurden. Dieses Beispiel verdeutlicht die Bedeutung einer möglichst grossen Variabilität der Referenzdaten, damit die Modelle auf nicht trainierten Kiesbänken angewendet werden können.

3.3.4 Erfassung der räumlichen Variabilität

Am Beispiel von drei ausgewählten Kiesbänken (Abb. 7) wird das Potenzial von *GRAINet dm* zur Kartierung der räumlichen Verteilung der *dm* vorgestellt. Bei allen Bänken kann das lückenhafte erkennbare Muster der *dm* der Referenzdaten durch die flächige Anwendung des Ansatzes verdichtet werden. Dabei werden sowohl die räumliche Variabilität innerhalb einer Bank sowie auch die Unterschiede in der Grössenordnung der *dm* zwischen den Bänken sichtbar.

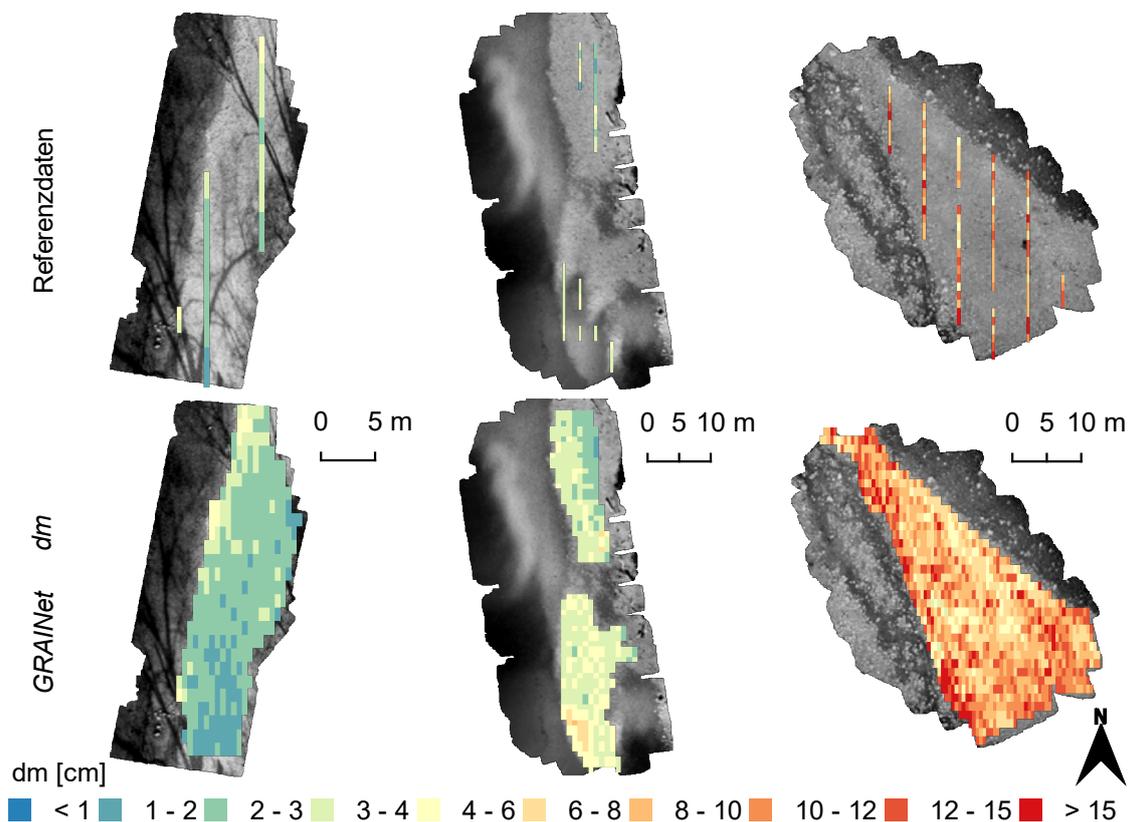


Abb. 7 Räumliche Verteilung der *dm* der Referenzdaten (oben) im Vergleich zu den prädizierten *dm* (*GRAINet dm*, Kreuzvalidierung; unten) am Beispiel der Kiesbänke *Reuss km 012.0*, *Aare km 171.0 km* und *Grosse Entle km 002.1* (v.l.n.r., Grafik digital in Farbe)

4 Zusammenfassung

Dieser Fachbeitrag stellt eine Methodik (*GRAINet*) vor, welche die automatische Bestimmung der Kornverteilung einer Kiesbank sowie die Kartierung der räumlichen Verteilung der mittleren Korndurchmesser dm über die Kiesbank mit Drohnenbildern erlaubt. Dafür wurden drei verschiedene CNN-Modelle (*GRAINet frequency*, *volume* und *dm*) mit 1'491 digitalisierten Linienproben von 25 Standorten trainiert und getestet. Während sich alle drei Modelle für die Beurteilung der über die Kiesbänke gemittelten Werte eignen, wird die Variabilität der dm über die Kiesbank mit *GRAINet dm* am besten prädiziert. Es ist vorgesehen, die Aussagequalität der Modelle durch eine Vergrößerung der Referenzdaten (insbesondere unterschiedliche Lichtverhältnisse) zu verbessern. Doch bereits heute bietet diese Methodik neue Möglichkeiten in Bezug auf die Analysen der Sedimentdynamik (z.B. bei Erfolgskontrollen) sowie bei der Kalibrierung von Abfluss- und Geschiebetransportmodellen.

Referenzen

- Lang, N., Irniger, A., Rozniak, A., Hunziker, R., Wegner, J. D., & Schindler, K. (2021). GRAINet: Mapping grain size distributions in river beds from UAV images with convolutional neural networks. *Hydrology and Earth System Sciences Discussions*, 25, 2567-2597.
- Buscombe, D. (2019). SediNet: A configurable deep learning model for mixed qualitative and quantitative optical granulometry, *Earth Surface Processes and Landforms*.
- He, K., Zhang, X., Ren, S., und J. Sun (2016). Deep residual learning for image recognition', in *IEEE Conference on Computer Vision and Pattern Recognition*.
- Detert, M., Weitbrecht, V. (2012). Automatic object detection to analyze the geometry of gravel grains - a free stand-alone tool. *River Flow 2012 - Proceedings of the International Conference on Fluvial Hydraulics*, 1:595–600.
- Fehr, R. (1987). Einfache Bestimmung der Korngrößenverteilung von Geschiebematerial mit Hilfe der Linienzahlanalyse. *Schweizer Ingenieur und Architekt*, 105(38):1104–1109.

Adressen der AutorInnen

Andrea Irniger (korrespondierende Autorin)

Roni Hunziker

Hunziker, Zarn & Partner

CH-5000 Aarau, Schachenallee 29

andrea.irniger@hzp.ch

Nico Lang, Angieszka Rozniak, Jan Dirk Wegner, Konrad Schindler

EcoVision Lab, Photogrammetry and Remote Sensing, ETH Zürich

CH-8093 Zürich, Stefano-Franscini-Platz 5

nico.lang@geod.baug.ethz.ch