

Enrico Soranzo ¹⁾

Universität für Bodenkultur Wien, Department für Landschaft, Wasser und Infrastruktur, Institut für Geotechnik, Wien, Österreich

Einleitung

Sieb- und Schlämmanalysen sind aufwendig. Alternative Ansätze haben Einschränkungen bei Genauigkeit, Kosten und Anwendbarkeit (Zuo et al. 2000). Convolutional Neural Networks (CNNs) zeigen versprechende Ergebnisse, werden meist für die Texturklassifikation (Buscombe 2020 and Lang et al. 2021) und nicht für die Vorhersage der Kornverteilung genutzt. Eine Studie (Soranzo et al. 2025) entwickelte ein Modell zur Kornverteilung-Vorhersage, das auf MobileNet (Howard et al. 2017) basiert und standardisierte Bodenbilder verwendet. Trotz guter Ergebnisse zeigte das Modell Schwächen bei neuen geografischen Daten. Diese wurden durch zusätzliche Trainingsdaten, Datenaugmentation und 5-fache Kreuzvalidierung verbessert.

Materialien und Methoden

Es wurden 56 Bodenproben aus der Nähe von Wien und Frankfurt berücksichtigt. Nahaufnahmen der Proben dienen als Eingabedaten. Die Bilder wurden mit Smartphone-Kameras (Motorola Edge, Samsung A52, iPhone 14) in einer dunklen Kammer aufgenommen (Abbildung 1). Die Kameras waren in einem festen Abstand von 210 mm zur Bodenoberfläche positioniert und die Proben wurden zuvor homogenisiert und getrocknet. Es wurden mehrere Bilder pro Probe aufgenommen, wobei die Bodenoberfläche zwischen den Aufnahmen verändert wurde.




Abbildung 1. Experimenteller Aufbau zur Aufnahme von Bodenbildern. Die Fotos werden durch eine 45×45 mm große Öffnung aufgenommen (Soranzo et al., 2025).

Die Pixeldichte wurde durch Kalibrierung mit einem Lineal auf 4,6 PPM standardisiert (Abbildung 2). Die Bilder wurden auf 400×400 Pixel zugeschnitten.




Abbildung 2. Beispiel für die Kalibrierung der Pixeldichte. Die Anzahl der Pixel für eine bestimmte Länge wird gemessen.

Die Kornverteilungen wurden mit der Weibull-Verteilung modelliert, wobei die Parameter $\ln(b)$ und c als Ausgabewerte dienten.

$$F(d \leq d_i) = 1 - \exp \left[- \left(\frac{d}{b} \right)^c \right] \quad (1)$$

Für die Analyse wurde das MobileNet CNN mit vortrainierten Schichten aus dem ImageNet-Datensatz (Deng et al., 2009) und zusätzlichen Regressionsschichten verwendet. 90% der Bilder wurden für das Training und 10% für Tests verwendet. Datenaugmentationstechniken wurden eingesetzt, um die Trainingsdaten zu erweitern (Abbildung 3).




Abbildung 3. Datenaugmentierungstechniken. Aus einem Originalbild wurden $2^{10} = 512$ Bilder erstellt.

Ergebnisse

Die Werte für den R^2 und den MAPE wurden für $\ln(b)$ und c berechnet, indem die Modellvorhersagen mit den Beobachtungen verglichen wurden. Die Vorhersagen des Modells stimmen gut mit den erwarteten Werten überein (Abbildung 4).




Abbildung 4. Modellvorhersage der Parameter $\ln(b)$ und c .

Eine Webanwendung wurde entwickelt, um das Modell bereitzustellen (Abbildung 5). Derzeit unterstützt sie die drei vorher genannten Smartphones und Auflösungen sowie das iPhone 16 mit einer Auflösung von 4284×5712 (noch nicht für das Modelltraining verwendet).

Diskussion und Fazit

Das Tool kann schnelle und effiziente Vorhersagen liefern. Das Modell ist online verfügbar, sodass Nutzer Kornverteilungen-Vorhersagen in Echtzeit erhalten können. Dies fördert eine kostengünstige Bodenanalyse unter Verwendung gängiger Geräte. Trotz der Einschränkung der Pixeldichte kann das Modell mit zwei Kurvenparametern, den gesamten Verlauf interpolieren, einschließlich Feinanteilen, sofern diese nicht zu hoch sind. Das Modell wurde an einer breiten Palette von Böden getestet. Zukünftige Forschungen sollten rein tonige Böden und mehr Proben aus unterschiedlichen Regionen einbeziehen.

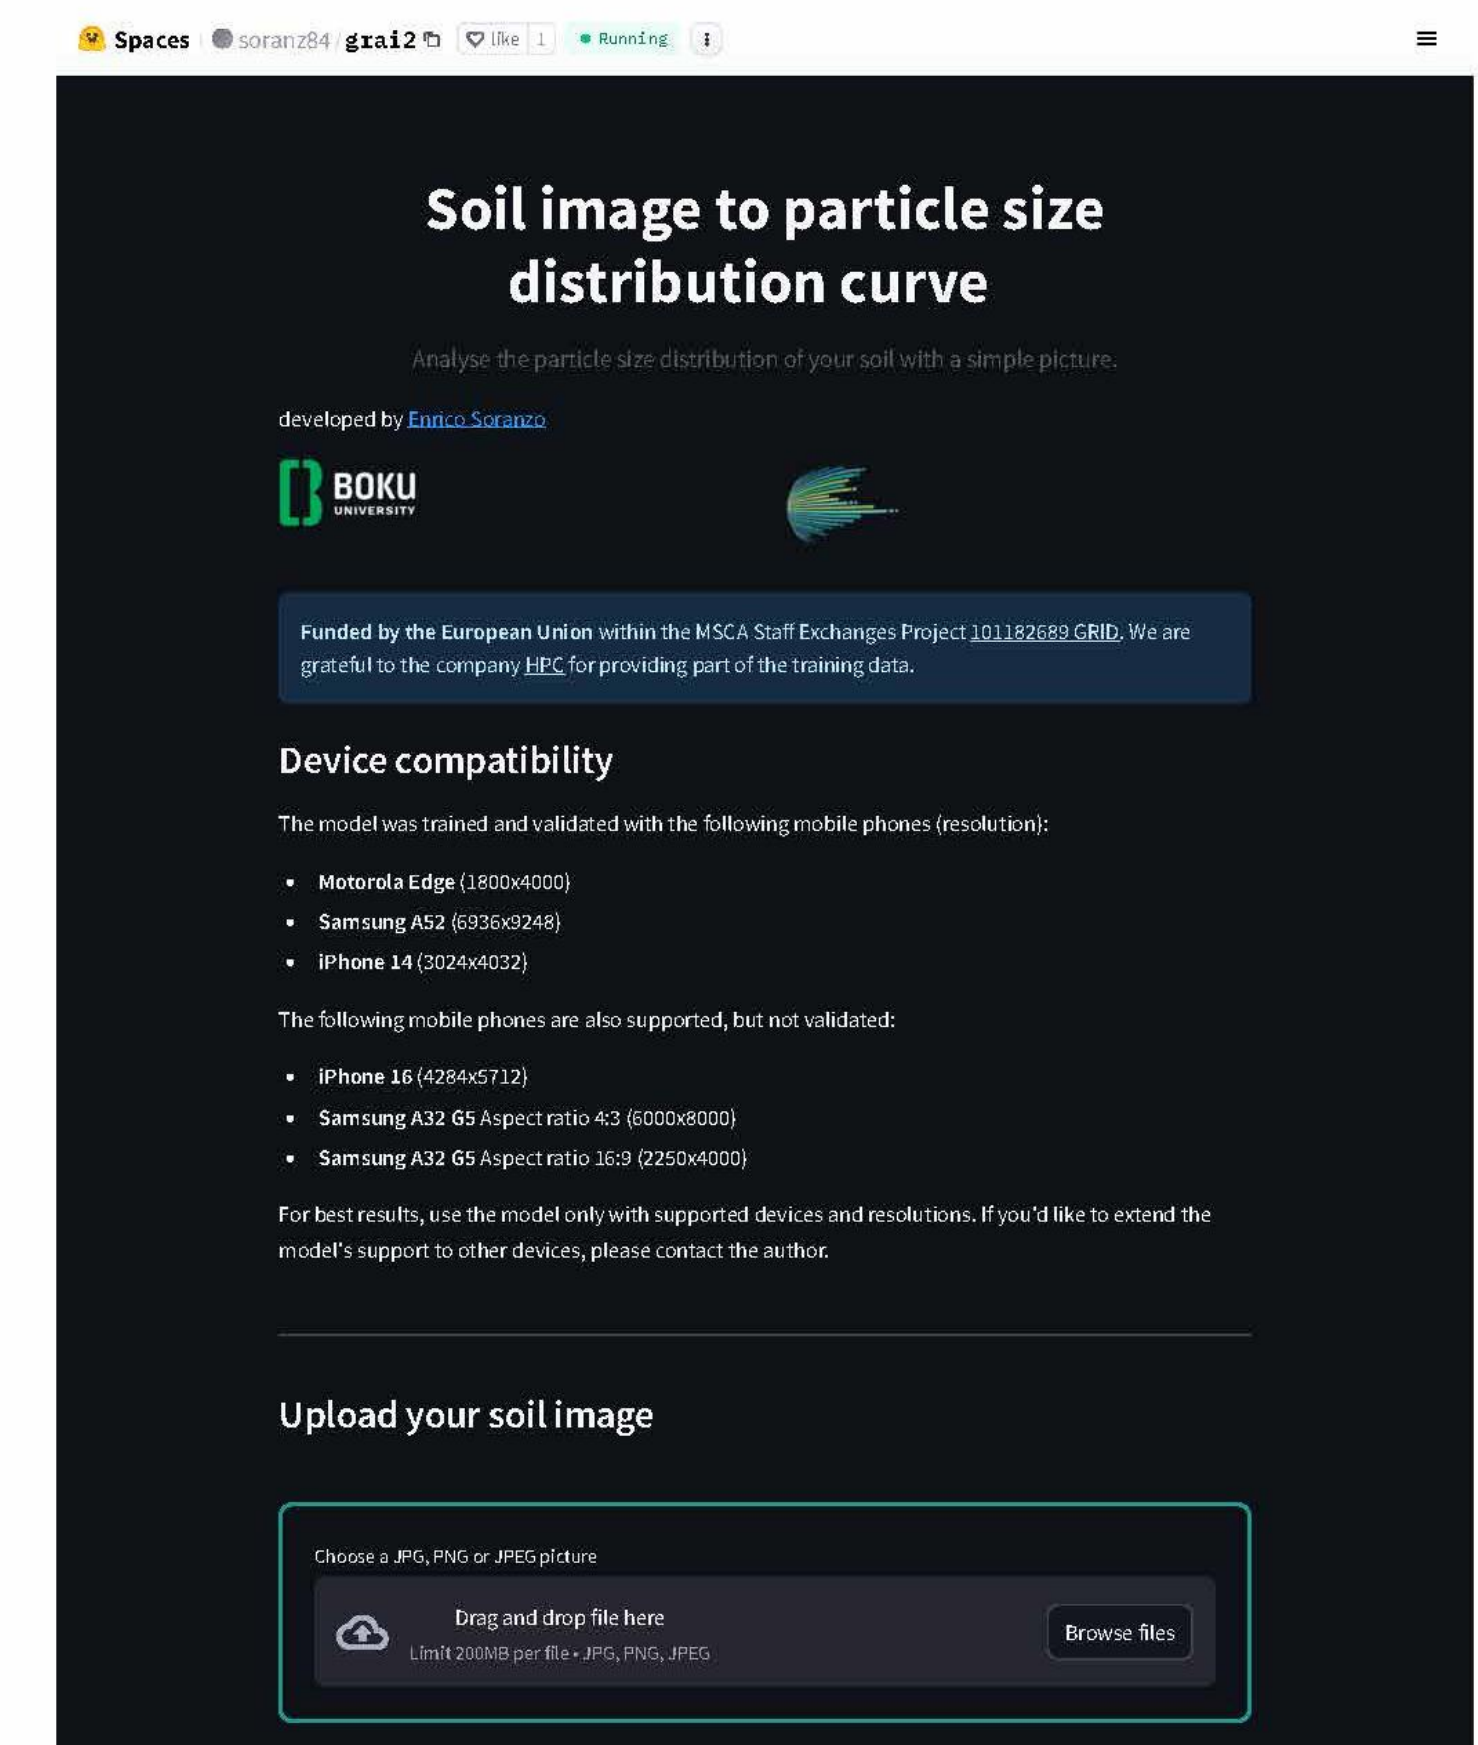


Abbildung 5. Screenshot der Web-App

Acknowledgments

Finanziert von der EU im Rahmen des MSCA Staff Exchanges Projekts 101182689 Geotechnical Resilience through Intelligent Design (GRID). Die hierin geäußerten Ansichten und Meinungen stammen jedoch ausschließlich von dem Autor und spiegeln nicht unbedingt die Ansichten der Europäischen Union oder der Europäischen Exekutivagentur für Forschung (REA) wider. Weder die Europäische Union noch die Bewilligungsbehörde können dafür verantwortlich gemacht werden.

Literaturverweise

- Buscombe D. 2020. SediNet: a configurable deep learning model for mixed qualitative and quantitative optical granulometry. *Earth Surface Processes and Landforms* 45(3), pp. 638–651. DOI: [10.1002/esp.4760](https://doi.org/10.1002/esp.4760)
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K. & Fei-Fei, L. 2009. ImageNet: A Large-Scale Hierarchical Image Database. *CVPR09*.

Howard, A.G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto & M., Adam, H. 2017. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. *CoRR*, abs/1704.04861. DOI: [10.48550/arXiv.1704.04861](https://arxiv.org/abs/1704.04861)

Lang, N., Irrniger, 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* 25(5), pp. 2567–2597. DOI: [10.5194/hess-25-2567-2021](https://doi.org/10.5194/hess-25-2567-2021)

Soranzo, E., Guardiani, C. & Wu, W. 2025. Convolutional neural network prediction of the particle size distribution of soil from close-range images. *Soils and Foundations* 65(1), 101575. DOI: [10.1016/j.sandf.2025.101575](https://doi.org/10.1016/j.sandf.2025.101575)

Zuo, Y., Erbach, D.C. & Marley, S.J. 2000. Soil structure evaluation by using a fiber-optic sensor. *Transactions of the American Society of Agricultural Engineers* 43(6), pp. 1317–1322.