

Das Potenzial von Citizen Science für die Kartierung von Landschaftsveränderungen in arktischen Permafrostregionen

The Potential of Citizen Science for Mapping Landscape Change in Arctic Permafrost Regions

Oliver Fritz¹, Sabrina Marx¹, Benjamin Herfort¹, Soraya Kaiser^{3,4}, Moritz Langer^{3,4}, Josefine Lenz³, Christian Thiel⁵, Alexander Zipf^{1,2}

¹Heidelberg Institute for Geoinformation Technology (HeiGIT), Heidelberg · oliver.fritz@heigit.org

²Abteilung Geoinformatik, Universität Heidelberg

³Sektion Permafrostforschung, Alfred-Wegener-Institut Helmholtz-Zentrum für Polar- und Meeresforschung, Potsdam

⁴Geographisches Institut, Humboldt-Universität zu Berlin

⁵Institut für Datenwissenschaften, Deutsches Zentrum für Luft und Raumfahrt, Jena

Zusammenfassung: Das Monitoring des tauenden Permafrosts in der Arktis ist ein wesentlicher Schlüssel, um die globalen Klimafolgen abzuschätzen. Bürgerwissenschaftliche Ansätze können dabei einen entscheidenden Beitrag leisten. In einer Fallstudie kartieren Besuchende einer Ausstellung arktische Frostmusterböden in Satellitenbildern basierend auf dem sogenannten Micro-Mapping-Ansatz. Die Auswertung der erfassten Daten ergibt, dass die Kartierung von Frostmusterböden eine größere Herausforderung darstellt als bereits etablierte Aufgabenstellungen, wie die Gebäude-Erkennung. Eine Vereinfachung der Aufgabe (binäre Klassifizierung) erhöht die Übereinstimmung in der Permafrost-Kartierung. Die bürgerwissenschaftliche Datenauswertung zeigt großes Potenzial für die Permafrostforschung, muss jedoch weiter erprobt werden.

Schlüsselwörter: Bürgerwissenschaften, Permafrost, Crowdsourcing, Intrinsische Qualitätsanalyse, Kartierung

Abstract: *Monitoring permafrost thaw in the Arctic is essential for assessing global climate change impact. Citizen science approaches can make a crucial contribution to this. In a case study using a micro-mapping methodology, visitors of an exhibition mapped polygonal soil patterns in satellite images of the Arctic. The evaluation of the collected data reveals that mapping such patterns poses a bigger challenge than more established tasks, such as building detection. A simplification of the task using a binary detection approach increases the agreement in permafrost mapping. Citizen science shows great potential for permafrost research, although methods must be further tested.*

Keywords: *Citizen science, permafrost, crowdsourcing, intrinsic quality assessment, mapping*

1 Motivation und Stand der Forschung

Die Lufttemperaturen der Arktis erwärmen sich derzeit zwei- bis dreimal stärker als die globale Durchschnittstemperatur (Meredith et al., 2018). Durch das Auftauen der arktischen Permafrostböden können zusätzliche Treibhausgase in die Atmosphäre gelangen und die globale Erwärmung verstärken. Zudem kommt es zu Veränderungen von Ökosystemen und der Destabilisierung von Infrastruktur mit direkten Auswirkungen für die in der Arktis lebenden Menschen (Hjort et al., 2018; Gädeke et al., 2021; Ramage et al., 2021). Das Auftauen des

Permafrosts (Dauerfrostboden) kann kaum direkt beobachtet werden, sondern findet in den Tiefen des Bodens statt. Dies erschwert die wissenschaftliche Beurteilung der Klimafolgen und führt dazu, dass die Folgen der Klimaerwärmung auf die Ökosysteme der Arktis nicht unmittelbar erlebbar und daher schwerer vermittelbar sind.

Ein an der Oberfläche sichtbarer Indikator für Permafrost und dessen Degradation sind Frostmusterböden, die in Form von polygonalen Eiskeil-Strukturen auftreten (French, 2018). Diese entstehen durch thermische Kontraktion sowie Frosthebungsprozesse und ermöglichen Rückschlüsse über den Eisgehalt im Untergrund (Kanevskiy et al., 2013). Der zeitliche Rahmen und die Intensität der erfolgten Degradation kann im Zusammenspiel mit regionalen Klimadaten ermittelt werden. Die Beobachtung dieser Frostmusterböden ist daher ein wesentlicher Schlüssel, um die globalen Klimafolgen durch das Tauen des Permafrosts abzuschätzen (Liljedahl et al., 2016). Es werden zunehmend Methoden entwickelt, um diese Landschaftsstrukturen in Permafrostregionen anhand hochauflösender Fernerkundungsdaten zu erkennen. Die Methoden reichen dabei von klassischen Spektralklassifikationen (Rettelbach et al., 2021, Kaiser et al., 2021) bis hin zu KI-basierter Objekterkennung (Abolt et al., 2021, Zhang et al., 2020). Für den pan-arktischen Einsatz der Detektionsverfahren sind Anpassungen anhand hinreichend großer und bereits klassifizierter Datensätze erforderlich. Bislang stehen diese nur für regionale Anwendungen zur Verfügung.

Das Potenzial von bürgerwissenschaftlichen Ansätzen für die Datenerfassung in der Polarforschung wurde bereits in verschiedenen Projekten aufgezeigt, z. B. die bürgerwissenschaftlichen Meereis-Beobachtungen über das „ASSIST Data Network“ (The Polar Citizen Science Collective). Anders et al. (2020) haben einen Crowd-basierten Ansatz gewählt, um die per Laserscanning erfasste Absenkung von Permafrostböden zu validieren. In anderen Anwendungsbereichen haben sich längst „Volunteered Geographic Information“ (VGI) etabliert, wobei enorme Datenmengen über große Räume und Zeitspannen hinweg erzeugt werden konnten (Goodchild, 2007). Ein Beispiel ist die Kartierung von Gebäuden durch Freiwillige basierend auf Satellitenbildern mit der mobilen Anwendung „MapSwipe“ (MapSwipe). Der in MapSwipe verwendete Micro-Mapping-Ansatz bedeutet eine Unterteilung des Kartierungsprozesses in kleine und einfach zu lösende Aufgaben (Albuquerque et al., 2016). Für das Kartieren von besiedelten Gebieten reichen bereits drei bis fünf Antworten, um eine hohe Qualität zu erzielen (Herfort et al., 2017). Besonderes Potenzial für die Bürgerforschung birgt die Nutzung menschlicher kognitiver Fähigkeiten in Kombination mit Methoden des maschinellen Lernens (Franzen et al., 2021; Herfort et al., 2019; Huck et al., 2021).

Die Beurteilung von Frostmusterböden ist hingegen eine komplexe Aufgabe und erfolgte bisher durch Expert*innen. Bei komplexeren Aufgabenstellungen erreicht Crowdsourcing nicht immer Ergebnisse, die denen einer Expert*innen-Begutachtung gleichen (See et al., 2013). Ziel der hier vorgestellten Studie ist es, den Micro-Mapping-Ansatz erstmalig für die Kartierung von Frostmusterböden anzuwenden und zu evaluieren. Es ist fraglich, ob die erhobenen Daten im Vergleich zu etablierten Ansätzen wie MapSwipe ähnlich aussagekräftig sind. Eine Voraussetzung für verlässliche Ergebnisse im Crowdsourcing ist ein hohes Maß an Übereinstimmung in den Urteilen der Bearbeitenden. Daher gilt zu beantworten, 1.) wie die Übereinstimmung bei der Detektion von Frostmusterböden durch Bürgerforschende im Vergleich zur Gebäude-Kartierung zu bewerten ist, und 2.) welche Übereinstimmung für die Kartierung von verschiedenen Degradationszuständen erzielt wird.

2 Methoden

2.1 Datenerfassung

Im Rahmen einer Ausstellung zum Thema „Künstliche Intelligenz“ (KI) auf dem Binnenschiff MS Wissenschaft im Wissenschaftsjahr 2019 (Mai bis Oktober) konnten die Besuchenden verschiedene Micro-Mapping-Aufgaben bearbeiten. Die Aufgabenstellung 1 umfasste die Kartierung von Frostmusterböden unter Berücksichtigung des Degradationsgrades (vier Klassen: starke, mittlere, leichte und keine Degradation). Aus den Ergebnissen wurden nachträglich Ergebnisse für eine weniger komplexe Aufgabenstellung 2 abgeleitet: Die Detektion von Frostmusterböden (zwei Klassen: Frostmusterböden sichtbar/nicht-sichtbar). Für den Vergleich mit einem etablierten Micro-Mapping-Ansatz wurde Aufgabenstellung 3, die Kartierung von Gebäuden (Klassen: Gebäude sichtbar, nicht-sichtbar, unsicher), implementiert. Die Bearbeitung der Kartierungs-Aufgaben erfolgte in einer Webanwendung, die auf einer Touchscreen-Säule präsentiert wurde (Abb. 1). Nach einer Video-Einführung wurden die Bearbeitenden durch aufgabenspezifische Tutorials geführt. Anschließend startete die Kartierung. Angelehnt an das MapSwipe-Projekt wurden den Besuchenden sechs Teilaufgaben je sechs zusammenhängender Satellitenbild-Kacheln (Bing-Map-Tiles, ca. 125×125 m) gezeigt. Durch Klicken auf die Bildausschnitte konnte jede Kachel einer Klasse zugeordnet werden, die durch Symbole am Kachelrand repräsentiert wurden.

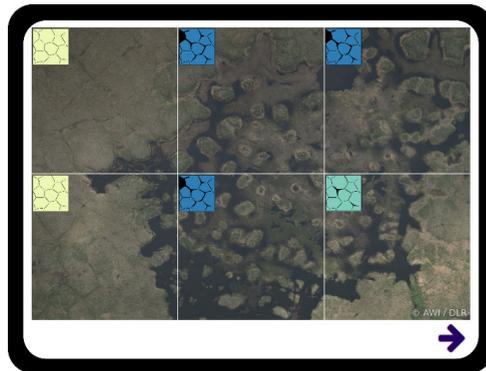


Abb. 1: Touchscreen-Säule als Exponat auf der MS Wissenschaft (links); Beispielhafte Darstellung der Webanwendung: Erfassung von Degradationszuständen; Bildquelle: MACS RGB-Bilder der Per-ma-X-Kampagne West-Alaska 2021 (rechts)

Alle Aufgaben wurden mehreren Bearbeitenden vorgelegt. Dies ermöglicht eine umfassende Analyse bezüglich des Mapping-Verhaltens und der Übereinstimmung der Antworten. Die Kartierung der Frostmusterböden wurde für sechs Regionen (fünf in Alaska, eines in Sibirien) mit einer Gesamtfläche von ca. 226 km^2 vorgenommen. Es wurden Regionen aus sich nach Temperatur und Niederschlag unterscheidenden arktischen Klimazonen ausgewählt, um möglichst vielfältige polygonale Landschaften in die Kartierungs-Fallstudie einzubeziehen. Die Kartierung der Gebäude erfolgte für drei Regionen in Guatemala, Laos und Malawi (Gesamtfläche ca. 62 km^2), welche bereits von Herfort et al. (2019) für die Analyse von MapSwipe-Projekten genutzt wurden. Diese Auswahl ermöglicht den Vergleich der in unterschiedlichen

Kontexten erreichbaren Ergebnisse bei gleicher Aufgabenstellung und gleicher Bilddaten-grundlage.

2.2 Datenverarbeitung

Nach Abschluss der Ausstellung lagen für die Klassifizierung von Frostmusterböden je Auf-gabe bis zu zehn Antwort-Datensätze vor. Diese wurden für die weitere Auswertung vorbe-reitet, indem 1.) unbearbeitet gebliebene Aufgabenteile entfernt wurden, 2.) die in verschie-denen Bearbeitungsdurchläufen entstandenen Antworten je Bildkachel zu einem Gesamter-gbnis aggregiert wurden und 3.) aus den Klassifizierungsergebnissen nachträglich binäre Ergebnisse (Frostmusterböden sichtbar/nicht sichtbar) abgeleitet wurden. Wenn in der Bear-beitung einer Teilaufgabe und aller darauffolgender Teilaufgaben keine aktive Klassifizie-rung vorgenommen wurde, wurden die Antworten dieser Teilaufgaben entfernt. Auch bei Bearbeitung nachfolgender Teilaufgaben wurde zudem die erste Teilaufgabe nicht berück-sichtigt, wenn darin maximal eine einzige Klassifizierung vorgenommen wurde. Um das Ge-samtergebnis je Bildkachel aus den Einzelantworten zu aggregieren, wurde im Falle multi-modalen Antwortverteilungen auf den Medianwert der ordinalen Klassifizierung zurückge-griffen, ansonsten der Modalwert verwendet. Aus den mehrklassigen Klassifizierungsergeb-nissen der Kartierung von Frostmusterböden wurden nachträglich binäre Ergebnisse abgelei-tet, um die Vergleichbarkeit mit den Ergebnissen der Gebäude-Detektion zu verbessern: Die drei Klassen (leicht, mittel und stark), die den Grad der Degradation bei erkennbaren Frost-musterböden angeben, wurden zu einer einzigen Klasse (Frostmusterböden sichtbar) zusam-mengefasst.

2.3 Übereinstimmungsanalyse

Die Übereinstimmungsanalyse dient der Klärung der Frage, ob die Varianz in den Einschät-zungen verschiedener Urteilender den Unterschieden in den beurteilten Objekten zuzuschrei-ben ist (Tinsley & Weis, 2000) – in diesem Fall also den sichtbaren Mustern in den Bilddaten. Ein hohes Maß an Übereinstimmung besteht, wenn unterschiedliche Bearbeitende bei glei-cher Datengrundlage zu den gleichen Schlüssen kommen. Dies ist zwar kein Garant für die Richtigkeit der Ergebnisse, aber eine Voraussetzung für zuverlässige und aussagekräftige Information (Wirtz & Kutschmann, 2007). In welchem Maße die Übereinstimmung als Indi-kator für die Qualität (insbesondere: die sachliche Genauigkeit) der Ergebnisse dienen kann, wäre Gegenstand einer weiteren Untersuchung durch Vergleich mit Ergebnissen, die auf an-derer Grundlage erzielt wurden (Mocnik et al., 2018). Die vorgenommene Übereinstim-mungsanalyse orientiert sich zwecks Vergleichbarkeit an den in Herfort et al. (2017) be-schriebenen Methoden. Die Übereinstimmung je Bildkachel wurde gemäß Fleiss (1971) be-stimmt (1), wobei n der Anzahl der Antworten je Bildkachel, k der Anzahl der Kategorien (hier: $k = 4$ bzw. $k = 2$ für die binäre Klassifizierung) und n_{ij} der Anzahl der Antworten-den, die die Kachel i der k -ten Kategorie zugewiesen haben, entspricht:

$$P_i = \frac{1}{n(n-1)} * \sum_{j=1}^k n_{ij}^2 - n_{ij} \quad (1)$$

Die durch Fleiss' *kappa* (Fleiss, 1971) ausgedrückte Urteilerübereinstimmung (auch: Inter-rater-Reliabilität) ist die normalisierte Übereinstimmung der Urteile mehrerer Bearbeitender, korrigiert für den bei Zufallsbeantwortung erwarteten Übereinstimmungswert. Sie berechnet

sich nach (2), wobei \bar{P} dem Durchschnitt der Übereinstimmung P_i je Aufgabe und \bar{P}_e der Summe der quadrierten Anteile der Zuweisung zu jeder Klasse entspricht:

$$\kappa = \frac{\bar{P} - \bar{P}_e}{1 - \bar{P}_e} \quad (2)$$

Wenn die Übereinstimmungswerte im Raum nicht zufällig verteilt sind, ist dies ein weiterer Hinweis darauf, dass die Übereinstimmung von systematischen Faktoren abhängt, z. B. den in den Bilddaten erkennbaren Mustern. Um auf räumliche Autokorrelation zu prüfen, wurde für den Übereinstimmungswert je Region Moran's I (Moran, 1950) bestimmt.

3 Ergebnisse

3.1 Übersicht

Für die insgesamt 19.044 Bildkacheln der 529 Aufgaben der Klassifizierung von Frostmusterböden konnten im Rahmen der Ausstellung auf der MS Wissenschaft 118.368 Antworten gesammelt werden. Die Aufgaben wurden den Beitragenden in Teilschritten je sechs Bildkacheln präsentiert. Da in der Verteilung der Antworten je Gesamtaufgabe von 36 Bildkacheln besonders häufig durch sechs teilbare Anzahlen von Kacheln mit detektierten Frostmusterböden vorkommen (Abb. 2), kann angenommen werden, dass manche Nutzende nur die ersten Teilaufgaben durchgeführt haben und sich dann zum Aufgabenende durchgeklickt haben. Die Begutachtung der Einzelergebnisse bestätigt diese Annahme und zeigt zudem auf, dass oft die erste Teilaufgabe übersprungen wurde.

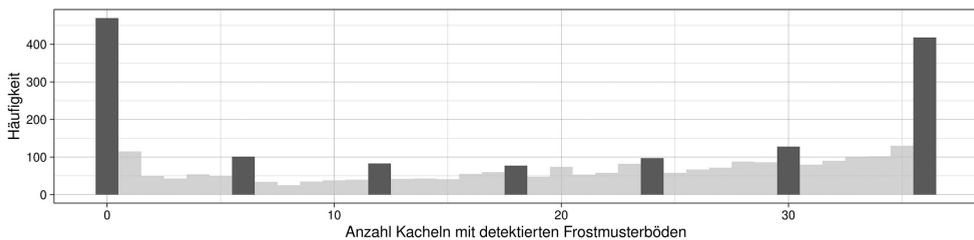


Abb. 2: Anzahl der Bildkacheln mit klassifizierten Frostmusterböden je Aufgabe (vor Datenbereinigung). Durch 6 teilbare Anzahlen sind hier hervorgehoben.

Nach der aus diesem Grund erfolgten Datenbereinigung (siehe 2.2) bleiben 81.306 Antworten (68,7 %) zu 14.826 Bildkacheln übrig (\bar{O} 5,48 Antworten je Kachel; s. Tab. 1). Die angenommene qualitätssichernde Wirkung des Crowdsourcings beruht darauf, dass durch mehrere Beobachtungen des gleichen Objekts individuelle Fehleinschätzungen an Gewicht verlieren (Goodchild & Li, 2012). Da die Ergebnisse in den Regionen 5 und 6 jeweils nur auf einer oder maximal zwei Beobachtungen beruhen, wurden diese Regionen aus der weiteren Analyse ausgeschlossen.

Tabelle 1: Übersicht: Ergebnisse der Kartierung

Testgebiet	Permafrost	Permafrost (bereinigt)	Gebäude
Anzahl Regionen	6	4	3
Gebiet (m ²)	225 516 633	181 881 148	67 251 651
# Aufgaben	529	415	86
# Bildkacheln	19 044	14 826	3 096
# Antworten	118 368	81 306	61 920
Ø Antworten je Kachel	6,22	5,48	20

Bei der Gebäudeerkennung konnten für sämtliche 3.096 Bildkacheln in den drei ausgewählten Regionen je 20 Antworten erzielt werden. Die Antworten der Klassifizierung von Frostmusterböden (Abb. 3) und der Gebäude-Detektion wurden zu Gesamtergebnissen je Bildkachel aggregiert.

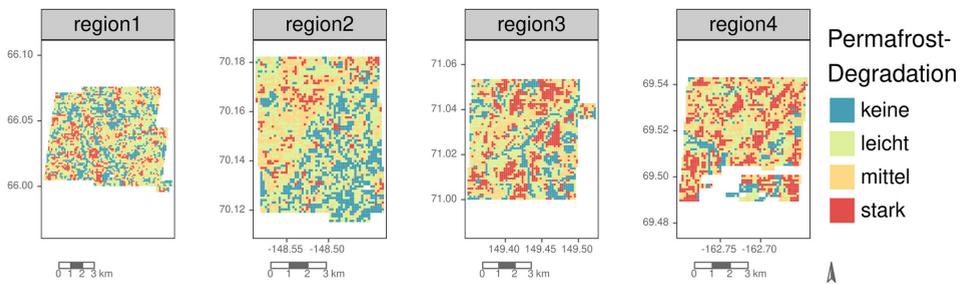


Abb. 3: Aggregierte Ergebnisse der Klassifizierung von Frostmusterböden auf Grundlage des bereinigten Antwortdatensatzes

3.2 Übereinstimmung

Für die vier untersuchten Regionen werden bei der Klassifizierung von Frostmusterböden mittlere Übereinstimmungswerte von ca. 0,4 erreicht. Die nachträgliche Umwandlung der Klassifizierung in eine binäre Detektion von Frostmusterböden führt zu einer deutlich höheren Übereinstimmung (Tab. 2).

Tabelle 2: Mittlere Übereinstimmung der Klassifizierung von Frostmusterböden je Region (vier Klassen/binär)

	Region 1	Region 2	Region 3	Region 4
Ø Übereinstimmung	0,384 / 0,716	0,396 / 0,695	0,378 / 0,758	0,365 / 0,787
Standardabweichung	0,225 / 0,250	0,224 / 0,243	0,215 / 0,240	0,209 / 0,240

Die mittlere Übereinstimmung der Klassifizierung steigt mit der Anzahl der Antworten je Bildkachel nur leicht (von 0,33 bei 2 Antworten auf 0,406 bei 8 Antworten) an. Die Anzahl der Antworten je Bildkachel hat dementsprechend wenig Einfluss auf die Übereinstimmung.

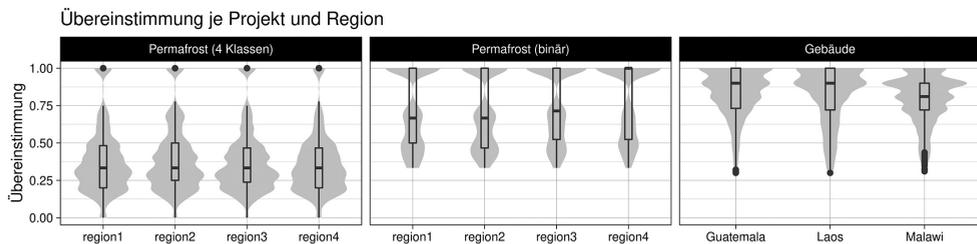


Abb. 4: Übereinstimmung der Kartierungsergebnisse je Projekt und Region

Es erscheint zunächst plausibel, die geringe Übereinstimmung zumindest in Teilen dem besonderen Bearbeitungskontext zuzuschreiben: Die Bearbeitung fand im Rahmen der Ausstellung möglicherweise hastiger und ungenauer statt, als dies bei selbst gewählten Umfeld und Zeitpunkt am eigenen Endgerät der Fall wäre. Um diese Annahme zu überprüfen, wurden die im gleichen Kontext (am Ausstellungstück) erzielten Ergebnisse der Gebäude-Detektion mit den Ergebnissen der Gebäude-Detektion mittels der MapSwipe-Anwendung verglichen. Die Gebäude-Detektion erreicht im Rahmen der Ausstellung ähnlich hohe Übereinstimmungswerte (Abb. 4), wie in den analysierten MapSwipe-Projekten (0,9 bzw. 0,868). Die geringe Übereinstimmung in den Permafrost-Aufgaben scheint somit nicht dem Kontext, sondern der höheren Schwierigkeit der Aufgabe geschuldet zu sein.

3.3 Urteilerübereinstimmung

Die Urteilerübereinstimmung (siehe 3.2) erreicht für die Klassifizierung von Frostmusterböden im Durchschnitt einen Wert von 0,1 (Abb. 5) und liegt damit geringfügig über dem bei Zufallsbeantwortung erwarteten Wert von 0. Für die binäre Nachklassifizierung erhöht sich der Wert auf 0,19. Die Ergebnisse der Gebäudeerkennung auf der MS Wissenschaft zeigen sich mit durchschnittlichen Kappa-Werten um 0,5 hingegen als ähnlich zuverlässig wie in der Analyse der MapSwipe-Projekte.

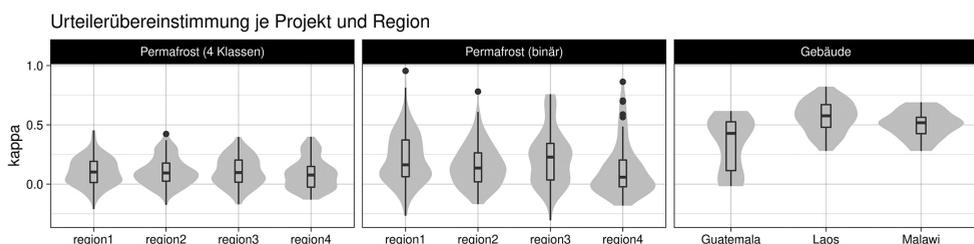


Abb. 5: Urteilerübereinstimmung je Projekt und Region

3.4 Räumliche Verteilung der Übereinstimmung

Bereits in der visuellen Erkundung (Abb. 6) der räumlichen Verteilung der Übereinstimmung in der Klassifizierung von Frostmusterböden sind Cluster von ähnlichen Werten erkennbar. Die nicht zufällige Verteilung im Raum ist ein Hinweis darauf, dass die Übereinstimmung von systematischen Faktoren abhängt, also von geographischen Phänomenen wie z. B. den in den Satellitenbildern sichtbaren Mustern.

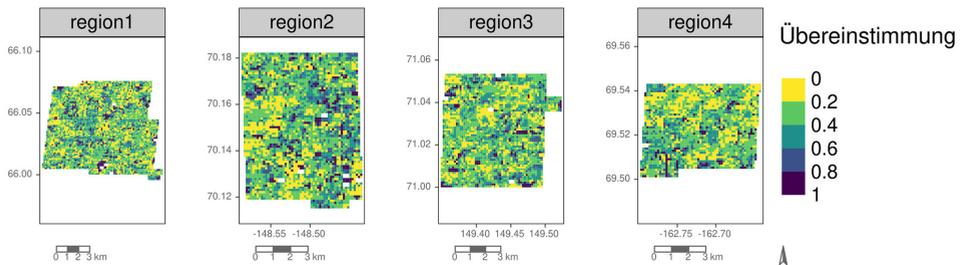


Abb. 6: Räumliche Verteilung der Übereinstimmung in der Klassifizierung von Frostmusterböden

Die Prüfung der räumlichen Autokorrelation ergibt für alle Regionen der Klassifizierung signifikant positive Werte für Moran's I (Tab. 3) und somit weitere Evidenz für ein Auftreten ähnlicher Übereinstimmungswerte in Clustern.

Tabelle 3: Moran's I der Übereinstimmungswerte in der Klassifizierung von Frostmusterböden

	Region 1	Region 2	Region 3	Region 4
Moran's I	0,237	0,260	0,306	0,245
p-Wert	0,001	0,001	0,001	0,001

4 Diskussion und Ausblick

Die Klassifizierung von Frostmusterböden in der Arktis auf Grundlage von Satellitenbildern stellt Bürgerwissenschaftler*innen vor größere Herausforderungen als die Erkennung von Gebäuden und Siedlungsflächen. Zwar deutet die nicht zufällige Verteilung der Übereinstimmungswerte im Raum darauf hin, dass die durch Crowdsourcing gewonnenen Daten tatsächlich in den Satellitenbilddaten sichtbare Phänomene widerspiegeln. Die niedrige durchschnittliche Übereinstimmung der Antworten je Bildkachel und die geringe Urteilerübereinstimmung je Aufgabe sprechen aber dafür, dass die Ergebnisse der Klassifizierung von Frostmusterböden unsicherer sind als etwa die Ergebnisse der Gebäude-Erkennung mit MapSwipe. Dass die unterschiedliche Qualität der Ergebnisse nicht allein durch die Umstände der Datenerfassung erklärt werden kann, zeigt der Vergleich mit der ebenfalls im Rahmen der Ausstellung auf

der MS Wissenschaft durchgeführten Gebäude-Erkennung. In welchem Maße sich die Qualität der durch Bürgerwissenschaftler*innen erzielten Ergebnisse von der durch Expert*innen-Begutachtung erreichten Qualität unterscheidet, ist in weiteren Studien zu untersuchen.

Bei Minimierung der genannten Unsicherheiten hat die Erschließung von Beiträgen freiwilliger Bürgerwissenschaftler*innen für die Permafrostforschung, in der es derzeit an umfassenden Datensätzen (z. B. als Trainingsdatensätze für maschinelles Lernen) mangelt, ein großes Potenzial. Es ist daher wichtig, weiter nach den geeigneten Methoden, Ausgangsdaten und Aufgabengestaltungen zu suchen, die solche Beiträge in hoher Qualität und Verlässlichkeit ermöglichen. Dass die Art der Aufgabengestaltung einen Einfluss auf die Ergebnisqualität hat, zeigt bereits die Auswertung der einfacheren binären Aufgabe. Die Erprobung weiterer Aufgabenstellungen, wie z. B. der Erfassung von Geometrien der Frostmuster oder der Vergleich von Frostmusterböden über die Zeit, erscheint daher als vielversprechend. Auch die Verwendung höher auflösender, dreidimensionaler, multispektraler oder mit Methoden des maschinellen Lernens vorprozessierter Bilddaten kann die Aufgabenbearbeitung möglicherweise erleichtern und zu höherer Qualität führen. Die Kartierung sollte zudem in ein Konzept zum Wissensaustausch mit den Bearbeitenden eingebettet werden. Dies erfolgte in der hier beschriebenen Fallstudie durch junge Wissenschaftler*innen und Studierende, die die Ausstellung begleitet haben. Nur so gelingt es, Interessierte in den wissenschaftlichen Prozess der Permafrostforschung einzubeziehen und einen aktiven Dialog zu Klimafolgen in der Arktis als globale Herausforderung zu initiieren.

Danksagung

Wir danken den Besucherinnen und Besuchern und dem gesamten Team der MS Wissenschaft, im Wissenschaftsjahr 2019 – Künstliche Intelligenz. Das zugrunde liegende Vorhaben wurde mit Mitteln des Bundesministeriums für Bildung und Forschung gefördert. Diese Arbeit wurde von der Klaus Tschira Stiftung (KTS) unterstützt.

Literatur

- Abolt, C. J., Young, M. H., Atchley, A. L., & Wilson, C. J. (2019). Brief communication: Rapid machine-learning-based extraction and measurement of ice wedge polygons in high-resolution digital elevation models. *The Cryosphere*, 13(1), 237–245. <https://doi.org/10.5194/tc-13-237-2019>.
- Albuquerque, J., Herfort, B., & Eckle, M. (2016). The Tasks of the Crowd: A Typology of Tasks in Geographic Information Crowdsourcing and a Case Study in Humanitarian Mapping. *Remote Sensing*, 8(10), 859. <https://doi.org/10.3390/rs8100859>.
- Anders, K., Marx, S., Boike, J., Herfort, B., Wilcox, E. J., Langer, M., Marsh, P., & Höfle, B. (2020). Multitemporal terrestrial laser scanning point clouds for thaw subsidence observation at Arctic permafrost monitoring sites. *Earth Surface Processes and Landforms*, 45(7), 1589–1600. <https://doi.org/10.1002/esp.4833>.
- Fleiss, J. L. (1971). Measuring nominal scale agreement among many raters. *Psychological Bulletin*, 76(5), 378–382. <https://doi.org/10.1037/h0031619>.

- Franzen, M., Kloetzer, L., Ponti, M., Trojan, J., & Vicens, J. (2021). Machine Learning in Citizen Science: Promises and Implications. In: K. Vohland, A. Land-Zandstra, L. Ceccaroni, R. Lemmens, J. Perelló, M. Ponti, ... & K. Wagenknecht (Eds.), *The Science of Citizen Science* (pp. 183–198). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-58278-4_10.
- French, H. M. (2018). *The periglacial environment* (4th Ed). J. Wiley.
- Gädeke, A., Langer, M., Boike, J., Burke, E. J., Chang, J., Head, M., Reyer, C. P. O., Schaphoff, S., Thiery, W., & Thonicke, K. (2021). Climate change reduces winter overland travel across the Pan-Arctic even under low-end global warming scenarios. *Environmental Research Letters*, *16*(2), 024049. <https://doi.org/10.1088/1748-9326/abdcf2>.
- Goodchild, M. F. (2007). Citizens as sensors: The world of volunteered geography. *GeoJournal*, *69*(4), 211–221. <https://doi.org/10.1007/s10708-007-9111-y>.
- Goodchild, M. F., & Li, L. (2012). Assuring the quality of volunteered geographic information. *Spatial Statistics*, *1*, 110–120. <https://doi.org/10.1016/j.spasta.2012.03.002>.
- Herfort, B., Reimuth, M., Porto de Albuquerque, J., & Zipf, A. (2017). Towards evaluating crowdsourced image classification on mobile devices to generate geographic information about human settlements. *Proceedings of the 20th AGILE* (pp. 1–7).
- Herfort, B., Li, H., Fendrich, S., Lautenbach, S., & Zipf, A. (2019). Mapping Human Settlements with Higher Accuracy and Less Volunteer Efforts by Combining Crowdsourcing and Deep Learning. *Remote Sensing*, *11*(15), 1799. <https://doi.org/10.3390/rs11151799>.
- Hjort, J., Karjalainen, O., Aalto, J., Westermann, S., Romanovsky, V. E., Nelson, F. E., Etzelmüller, B., & Luoto, M. (2018). Degrading permafrost puts Arctic infrastructure at risk by mid-century. *Nature Communications*, *9*(1), 5147. <https://doi.org/10.1038/s41467-018-07557-4>.
- Huck, J. J., Perkins, C., Haworth, B. T., Moro, E. B., & Nirmalan, M. (2021). Centaur VGI: A Hybrid Human–Machine Approach to Address Global Inequalities in Map Coverage. *Annals of the American Association of Geographers*, *111*(1), 231–251. <https://doi.org/10.1080/24694452.2020.1768822>.
- Kaiser, S., Grosse, G., Boike, J., & Langer, M. (2021). Monitoring the Transformation of Arctic Landscapes: Automated Shoreline Change Detection of Lakes Using Very High Resolution Imagery. *Remote Sensing*, *13*(14), 2802. <https://doi.org/10.3390/rs13142802>.
- Kanevskiy, M., Shur, Y., Jorgenson, M. T., Ping, C.-L., Michaelson, G. J., Fortier, D., Stephani, E., Dillon, M., & Tumskey, V. (2013). Ground ice in the upper permafrost of the Beaufort Sea coast of Alaska. *Cold Regions Science and Technology*, *85*, 56–70. <https://doi.org/10.1016/j.coldregions.2012.08.002>.
- Liljedahl, A. K., Boike, J., Daanen, R. P., Fedorov, A. N., Frost, G. V., Grosse, G., Hinzman, L. D., Iijma, Y., Jorgenson, J. C., Matveyeva, N., Necsoiu, M., Reynolds, M. K., Romanovsky, V. E., Schulla, J., Tape, K. D., Walker, D. A., Wilson, C. J., Yabuki, H., & Zona, D. (2016). Pan-Arctic ice-wedge degradation in warming permafrost and its influence on tundra hydrology. *Nature Geoscience*, *9*(4), 312–318. <https://doi.org/10.1038/ngeo2674>.
- MapSwipe. Retrieved January 24, 2022, from <https://mapswipe.org>.
- Meredith, M., Sommerkorn, M., Cassotta, S., Derksen, C., Ekaykin, A., Hollowed, A., Kofinas, G., Mackintosh, A., Melbourne-Thomas, J., Muelbert, M. M. C., Ottersen, G., Pritchard, H., & Schuur, E. A. G. (2019). Polar Regions. *IPCC Special Report on the Ocean and Cryosphere in a Changing Climate* [H.-O. Pörtner, D.C. Roberts, V. Masson-Delmotte, P. Zhai, M. Tignor, E. Poloczanska, K. Mintenbeck, A. Alegría, M. Nicolai, A. Okem, J. Petzold, B. Rama, N.M. Weyer (Eds.)]. In press.

- Mocnik, F.-B., Mobasheri, A., Griesbaum, L., Eckle, M., Jacobs, C., & Klöner, C. (2018). A grounding-based ontology of data quality measures. *Journal of Spatial Information Science*, 16, 1–25. <https://doi.org/10.5311/JOSIS.2018.16.360>.
- Moran, P. A. P. (1950). Notes on Continuous Stochastic Phenomena. *Biometrika*, 37(1/2), 17. <https://doi.org/10.2307/2332142>.
- Ramage, J., Jungsberg, L., Wang, S., Westermann, S., Lantuit, H., & Heleniak, T. (2021). Population living on permafrost in the Arctic. *Population and Environment*, 43(1), 22–38. <https://doi.org/10.1007/s11111-020-00370-6>.
- Rettelbach, T., Langer, M., Nitze, I., Jones, B., Helm, V., Freytag, J.-C., & Grosse, G. (2021). A Quantitative Graph-Based Approach to Monitoring Ice-Wedge Trough Dynamics in Polygonal Permafrost Landscapes. *Remote Sensing*, 13(16), 3098. <https://doi.org/10.3390/rs13163098>.
- See, L., Comber, A., Salk, C., Fritz, S., van der Velde, M., Perger, C., Schill, C., McCallum, I., Kraxner, F., & Obersteiner, M. (2013). Comparing the Quality of Crowdsourced Data Contributed by Expert and Non-Experts. *PLoS ONE*, 8(7), e69958. <https://doi.org/10.1371/journal.pone.0069958>.
- The Polar Citizen Science Collective. Retrieved January 24, 2022, from <https://polarcollective.org/projects>.
- Tinsley, H. E. A., & Weiss, D. J. (2000). Interrater Reliability and Agreement. In: *Handbook of Applied Multivariate Statistics and Mathematical Modeling* (pp. 95–124). Elsevier. <https://doi.org/10.1016/B978-012691360-6/50005-7>.
- Wirtz, M., & Kutschmann, M. (2007). Analyse der Beurteilerübereinstimmung für kategoriale Daten mittels Cohens Kappa und alternativer Maße. *Die Rehabilitation*, 46(6), 370–377. <https://doi.org/10.1055/s-2007-976535>.
- Zhang, W., Liljedahl, A. K., Kanevskiy, M., Epstein, H. E., Jones, B. M., Jorgenson, M. T., & Kent, K. (2020). Transferability of the Deep Learning Mask R-CNN Model for Automated Mapping of Ice-Wedge Polygons in High-Resolution Satellite and UAV Images. *Remote Sensing*, 12(7), 1085. <https://doi.org/10.3390/rs12071085>.