

## Hinweiskarten für Bodeneigenschaften

Landesweit modellierte Karten für Bodeneigenschaften für drei Tiefenstufen

**KOBO-Bericht Nr. 6**

Oktober 2023

## Impressum

**Autoren:** F. Stumpf, T. Behrens, K. Schmidt, A. Keller

**Erscheinungsjahr:** 2023

**Herausgeber:** Kompetenzzentrum Boden (KOBO), [ccsols.ch](http://ccsols.ch).

Das KOBO arbeitet im Auftrag der drei Bundesämter BAFU (Bundesamt für Umwelt), BLW (Bundesamt für Landwirtschaft) und ARE (Bundesamt für Raumentwicklung) und ist an der Hochschule für Agrar-, Forst- und Lebensmittelwissenschaften (HAFL) der Berner Fachhochschule (BFH) in Zollikofen angesiedelt.

**Empfohlene Zitierweise:** F. Stumpf, Behrens T., K. Schmidt und A. Keller (2023). Hinweiskarten für Bodeneigenschaften - Landesweit modellierte Karten für Bodeneigenschaften für drei Tiefenstufen. KOBO-Bericht Nr. 6, BFH-HAFL, CH-3052 Zollikofen-Bern, verfügbar unter [www.ccsols.ch](http://www.ccsols.ch)

**Copyright:** Gemäss untenstehendem Creative Commons-Lizenzsymbol ist die nicht-kommerzielle Vervielfältigung erwünscht, jedoch mit Quellenangabe und einem Belegexemplar an den Herausgeber. Die Weitergabe erfolgt nur unter gleichen Lizenzbedingungen.



# Inhaltsverzeichnis

1	Hintergrund	4
2	Methode Kartenerstellung	5
	2.1 Konzept	5
	2.2 NABODAT – Datensatz für Bodeneigenschaften	5
	2.3 Ableitung flächendeckender Umweltvariablen	14
	2.4 Räumliche Modellierung der Bodeneigenschaften	21
3	Hinweiskarten Bodeneigenschaften	23
4	Einordnung der Ergebnisse	35
5	Bereitstellung der Rasterkarten	37
6	Literatur	38

# 1 Hintergrund

Für eine nachhaltige Nutzung und den Schutz der Böden sind fundierte Bodeninformationen von zentraler Bedeutung. Flächenhafte Bodeninformationen sind beispielsweise sowohl für die Bestimmung und Beurteilung der Multifunktionalität der Böden als auch für die vielfältigen Bedürfnisse verschiedener Nutzergruppen unabdingbar (z.B. Wald- und Landwirtschaft, Klima, Gewässerschutz, Biodiversität, Raumplanung u.a.). Verschiedene Studien haben die Vielfalt der Bedürfnisse und Interessen von potenziellen Nutzern, Bodenfachstellen sowie Vertreterinnen und Vertretern dieser Nutzergruppen erfasst (Lüscher 2004, Knecht et al. 2017, Keller et al. 2018). Bodeninformationen sind gegenwärtig in der Schweiz nur in wenigen Kantonen flächendeckend vorhanden. Bisher wurde nur rund 13% der landwirtschaftlichen Nutzfläche der Schweiz kartiert (Rehbein et al. 2019).

In Bezug zu grossräumigen oder landesweiten Fragestellungen standen für die Praxis, den Vollzug und die Forschung bisher keine Karten für Bodeneigenschaften zur Verfügung. Angesichts dieser gravierenden Datenlücke behelfen sich viele Forschungsprojekte in der Vergangenheit mit Ableitungen und Schätzungen auf Basis der Bodeneignungskarte (BEK) der Schweiz im Massstab 1:200'000 aus dem Jahre 1980 (BEK 200, Vökt und Pazeller 2002). Die BEK200 wurde in den 1970er-Jahren erarbeitet, der bodenkundliche Inhalt wurde aufgrund von Luftbildanalysen, geologischer und geotechnischer Karten sowie aus relativ wenigen Bodenprofilen und Bohrungen aus Reliefeinheiten und geologischen Gegebenheiten interpretiert. Die BEK200 Kartierungseinheiten enthalten Informationen zu sechs Bodenkennwerten in groben Klassen, aber keine Angaben zu wichtigen Bodeneigenschaften wie pH, Humus- oder Tongehalt. Durchschnittlich deckt ein Polygon der BEK200 mehrere Quadratkilometer ab. Für viele Fragestellungen auf nationaler Ebene ist diese räumliche Auflösung unbefriedigend.

Vor diesem Hintergrund und aufgrund der hohen Nachfrage seitens Forschung, Vollzug und Praxis hat das Kompetenzzentrum Boden (KOBO) auf Basis der verfügbaren Bodendaten aus dem Bodeninformationssystem NABODAT landesweit Hinweiskarten für Bodeneigenschaften modelliert. Im Fokus stehen die Bodeneigenschaften Ton-, Schluff-, Sand- und Kohlenstoffgehalt, sowie der pH-Wert und die potenzielle Kationenaustauschkapazität für drei Tiefenstufen und für alle Landnutzungen (Ackerland, Grasland und Wald).

Die vorliegende Dokumentation beschreibt die Aufbereitung und die statistische Analyse der verfügbaren Bodeninformationen aus NABODAT, die Ableitung der flächendeckenden Umweltvariablen (Kovariablen) für die räumliche Modellierung, und stellt die finalen Produkte und Validierungsergebnisse der digitalen Bodenkartierung von Bodeneigenschaften vor. Zudem wird die Bereitstellung der Kartenprodukte beschrieben.

## 2 Methode Kartenerstellung

### 2.1 Konzept

Die räumliche Modellierung der Bodeneigenschaften erfolgt anhand mathematisch-statistischer Verfahren, die räumliche Beziehungen zwischen den am Punkt gemessenen Bodeneigenschaften und Kovariablen quantitativ abbilden. Konzeptionell orientiert sich eine digitale Bodenkartierung an dem Zustands-Faktoren-Modell (Dokuchaev 1883; Jenny 1941; McBratney et al. 2003), wobei die vorhergesagte Bodeneigenschaft  $S$  eine Funktion aus den Faktoren Boden ( $s$ ), Klima ( $c$ ), Vegetation/Landnutzung ( $o$ ), Relief ( $r$ ), Ausgangsmaterial ( $p$ ), Zeit ( $a$ ) und Raum ( $n$ ) ist:

$$S = f(s, c, o, r, p, a, n)$$

Auf Basis dieser Modelle und der flächendeckend verfügbaren Kovariablen werden im Nachgang räumliche Prognosen und Prognoseunsicherheiten für die jeweilige Bodeneigenschaft abgeleitet. In der Literatur finden sich zahlreiche Fallstudien und Varianten der digitalen Kartierung von Bodeneigenschaften (z.B. Behrens et al. 2018, Poggio and Gimona, 2017; Žižala et al., 2022).

### 2.2 NABODAT – Datensatz für Bodeneigenschaften

Mit dem Bodeninformationssystem NABODAT (Nationale Bodendatenbank: [www.nabodat.ch](http://www.nabodat.ch)) wurden in den letzten Jahren die vorhandenen kantonalen Bodendaten in ein einheitliches Datenmodell überführt, und Bodendaten harmonisiert, die vor allem in Bodenkartierungen in den Kantonen über vier Jahrzehnte hinweg erhoben wurden (Rehbein et al. 2019). Die Servicestelle NABODAT migriert laufend weitere Datenätze aus früheren Kartierprojekten, kantonalen Beobachtungsnetzen (KABO) oder anderen Erhebungen in das nationale Bodeninformationssystem und stellt periodisch den aktuellen Punktdatensatz für die Öffentlichkeit zur Verfügung, der von den Kantonen frei gegeben wird. Die Version 6 des Punktdatensatzes enthält Bodendaten von rund 33 000 Standorten ([www.nabodat.ch](http://www.nabodat.ch)). Für die digitale Bodenkartierung wurden die im Labor gemessenen Bodeneigenschaften des Nationalen Bodendatensatzes in der Version V6 verwendet (NABODAT 2023). Die im Feld geschätzten Humus-, Ton- und Schluffgehalte wurden zur Kartenerstellung nicht verwendet, da die Korrelation zwischen den gemessenen Bodeneigenschaften und den Feldschätzungen über alle Projekt-Datensätze hinweg unbefriedigend war. Eine Besonderheit im NABODAT Datensatz stellt die landesweite Rasterbeprobung von Böden (4 x 6 km) im Rahmen des Biodiversitätsmonitorings der Schweiz (BDM) dar. Zwischen 2011 und 2015 wurden in diesem Messnetz einmalig für den Oberboden (0 – 20 cm) Bodenproben erhoben und laboranalytisch bestimmt (BDM 2023).

Trotz der grossen Anstrengungen der NABODAT-Servicestelle für die Harmonisierung und Zusammenführung der Bodendaten in ein einheitliches Datenmodell weist der Datensatz in

verschiedener Hinsicht Unterschiede in der Datenqualität auf. Insbesondere betrifft dies die räumlich-zeitliche Verteilung, die Probenahme im Feld und der genaue Tiefenbezug, die Georeferenzierung sowie die verschiedenen laboranalytischen Bestimmungsmethoden.

Für die räumliche Modellierung der Bodeneigenschaften wurde zunächst in mehreren Arbeitsschritten der Datensatz weitergehend harmonisiert und wo möglich bereinigt. Beispielsweise wurden Kennzeichnungen und Einheiten der jeweiligen Bodeneigenschaften vereinheitlicht. Erhebungen vor dem Jahr 1985 wurden ausgeschlossen, da für diese Erhebungen wichtige Metainformationen oftmals nicht verfügbar sind, oder die Georeferenzierung der Standorte als zu ungenau eingeschätzt wurde. Profildaten mit überlappenden Horizontgrenzen, Duplikate, Wiederholungsmessungen am gleichen Standort (Monitoring) und unplausible Werte wurden identifiziert und gemittelt bzw. entfernt. Messwerte für Standorte, die zum Zeitpunkt der Probenahme versiegelt waren, deuten auf eine unpräzise Georeferenzierung hin und wurden ebenfalls ausgeschlossen.

Laboranalytisch wurde die Bodentextur (Ton, Schluff, Sand) mittels der Sedimentationsmethode bestimmt (Gee et al., 1986). Bodenkohlenstoffgehalte (SOC), die gemäss Schweizer Referenzmethode nach FAL durch Nassoxidation bestimmt wurden, wurden auf das Wertenniveau der aktuellen Referenzmethode (Trockenveraschung; CN-Analyzer) umgerechnet (Gubler et al. 2018). Bodenhumusgehalte wurden in SOC anhand der Formel  $SOC [\%] = \frac{Humus [\%]}{1.725}$  konvertiert (Pribyl 2010). Böden mit erhöhtem SOC von grösser als 10 % wurden von der Analyse ausgeschlossen, da für diesen Wertebereich die Beprobungsdichte überproportional gering und die Messunsicherheit hoch ist. Boden pH-Werte (pH) wurde potentiometrisch in einer  $CaCl_2$ -Lösung bestimmt. Für die laboranalytische Bestimmung der potenziellen Kationenaustauschkapazität ( $CEC_{pot}$ ) wurden zunächst die austauschbaren Kationen von Ca, Mg, K, Na und H in einer  $BaCl_2$ - bzw.  $HCl+H_2SO_4$ -Lösung extrahiert. Anschliessend wurden Elementkonzentrationen mittels der Atomabsorptionsspektroskopie (AAS) bzw. eines Flammenphotometers bestimmt und aufsummiert (Agroscope, 2023).

Um die Tiefeninformationen der jeweiligen Bodeneigenschaft im Datensatz zu harmonisieren, wurde ein kontinuierlicher Tiefengradient mittels einer Spline-Interpolation abgeleitet und anschließend der Mittelwert für drei Tiefenstufen (0 – 30 cm; 30 – 60 cm; 60 – 120 cm) berechnet (Bishop et al. 1999).

Die harmonisierten Datensätze für die Bodeneigenschaften (Ton, Schluff, Sand, SOC, pH,  $CEC_{pot}$ ) wurden mit Bezug zu Landnutzung und Tiefenstufe ausgewertet. Dabei wurde die räumliche Verteilung bzw. die Beprobungsdichte nach Landnutzung, die Häufigkeitsverteilung nach Erhebungsjahr und die Häufigkeitsverteilung der Analysedaten untersucht (Tabelle 1; Abbildung 1 bis Abbildung 6). Die Auswertungen zeigen deutlich, dass die räumliche Dichte der Beprobungsstandorte über die Schweiz, Landnutzungen und Tiefenstufen hinweg sehr unterschiedlich ist.

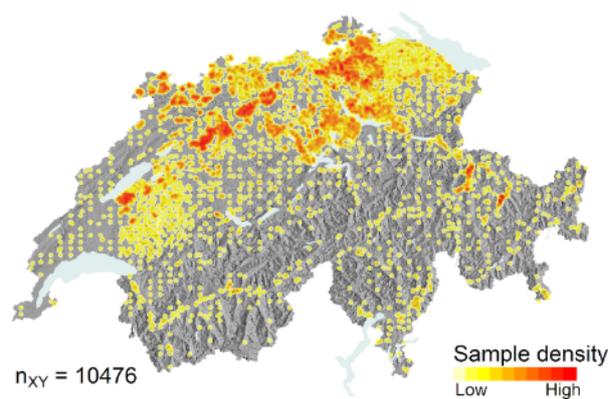
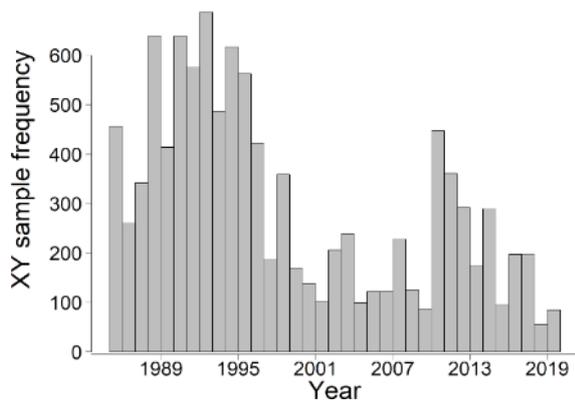
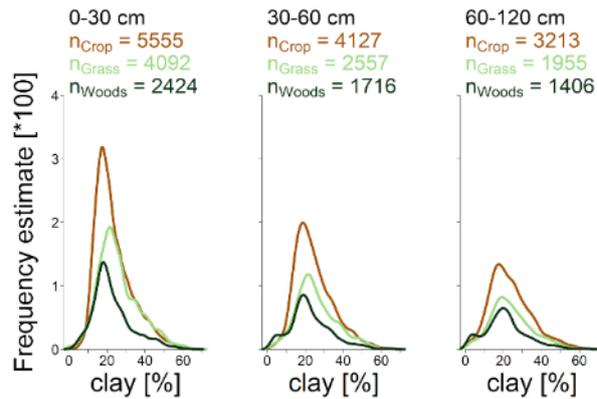
Insbesondere Grasland- und Waldflächen sind im Vergleich zu Ackerlandflächen deutlich unterrepräsentiert. Ebenso sinkt die Beprobungsdichte mit zunehmender Beprobungstiefe. Im mittleren und nördlichen Mittelland wurden in der Vergangenheit Kartierungen bzw. Bodenuntersuchungen durchgeführt, während vor allem in weiten Teilen des Jura, Wallis, Tessin, Graubünden und den Voralpen kaum Analysendaten für Bodeneigenschaften vorliegen bzw. vorhandene Datensätze noch nicht nach NABODAT migriert werden konnten (vergleiche mit den Karten zum Stand der Bodenkartierung in Rehbein et al. 2019). Ungefähr 70% der Bodendaten wurden im Zeitraum zwischen 1990 und 2000 erhoben. Darüber hinaus sind die Häufigkeitsverteilungen der Analysedaten, geschichtet nach Landnutzung und Beprobungstiefe, sehr ähnlich.

**Tabelle 1:** Anzahl der Beprobungsstandorte pro km<sup>2</sup> für jede Bodeneigenschaft (Ton, Schluff, Sand, SOC, pH, CEC<sub>pot</sub>) bezogen auf die Fläche aller Landnutzungen (Ackerland, Grasland, Wald; Total: Summe aller Flächen).

Bodeneigenschaft	Total [km <sup>-2</sup> ]	Ackerland [km <sup>-2</sup> ]	Grasland [km <sup>-2</sup> ]	Wald [km <sup>-2</sup> ]
Ton	0.35	1.25	0.22	0.20
Schluff	0.34	1.24	0.22	0.20
Sand	0.25	0.82	0.17	0.17
SOC	0.37	1.30	0.23	0.25
pH	0.55	1.86	0.36	0.37
CEC <sub>pot</sub>	0.06	0.21	0.04	0.04

## Clay [%]

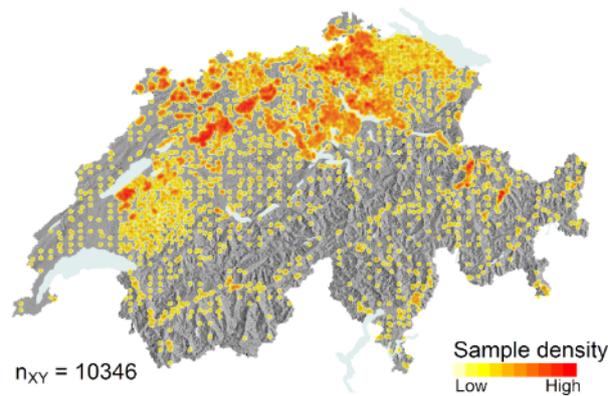
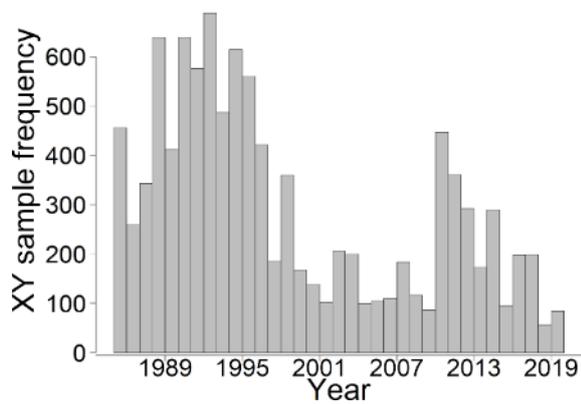
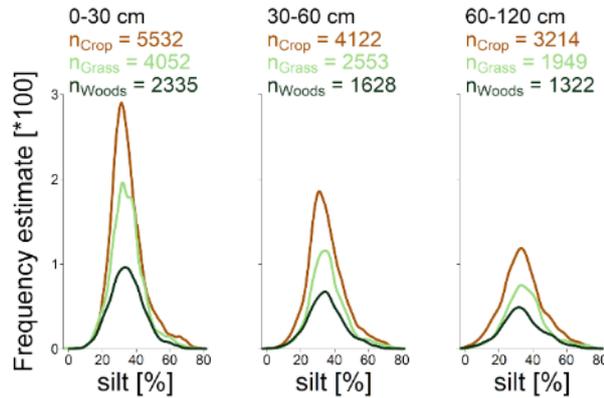
Min	0.02
Max	69.17
Q1	16.85
Median	22.04
Q2	29.94
Mean	24.16
Sd	10.78
n	27045



**Abbildung 1:** Statistische, zeitliche und räumliche Verteilung der im Labor gemessenen Tongehalte (Clay) des NABODAT-Datensatzes v6. Oben: statistische Kennwerte der Laboranalysen (Min: Minimum; Max: Maximum; Q1: 25%-Quantil; Q2: 75%-Quantil; Sd: Standardabweichung; n: Anzahl Erhebungen) und Häufigkeitsverteilungen nach Tiefenstufen und Landbedeckung (braun: Ackerland; hellgrün: Grasland; dunkelgrün: Wald); Unten links: Häufigkeitsverteilung über die Zeit; Unten rechts: räumliche Verteilung der Beprobungsstandorte  $n_{xy}$ .

## Silt [%]

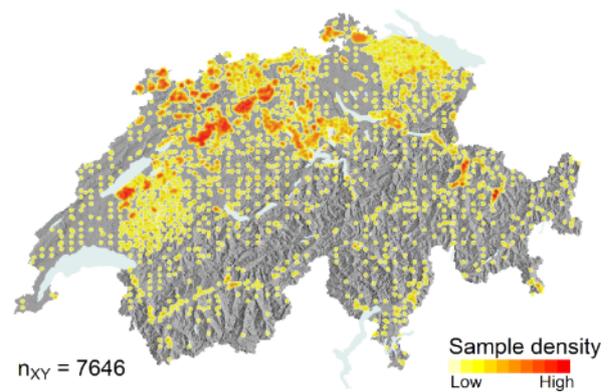
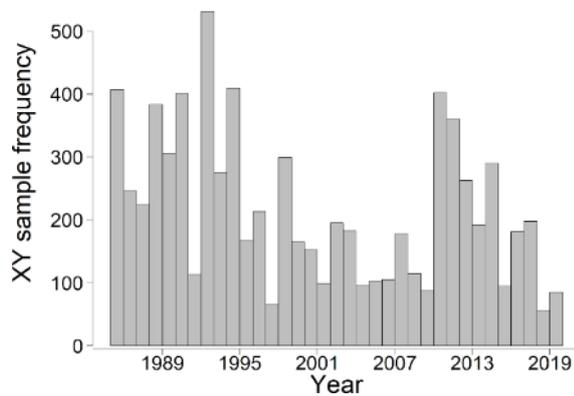
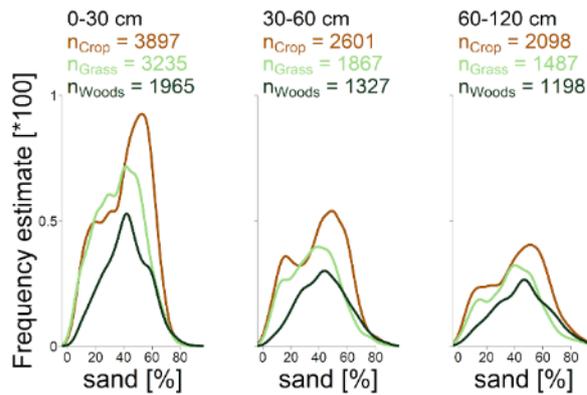
Min	0.02
Max	78.41
Q1	27.98
Median	33.85
Q2	40.69
Mean	34.9
Sd	10.87
n	26707



**Abbildung 2:** Statistische, zeitliche und räumliche Verteilung der im Labor gemessenen Schluffgehalte (Silt) des NABODAT-Datensatzes v6. Oben: statistische Kennwerte der Laboranalysen (Min: Minimum; Max: Maximum; Q1: 25%-Quantil; Q2: 75%-Quantil; Sd: Standardabweichung; n: Anzahl Erhebungen) und Häufigkeitsverteilungen nach Tiefenstufen und Landbedeckung (braun: Ackerland; hellgrün: Grasland; dunkelgrün: Wald); Unten links: Häufigkeitsverteilung über die Zeit; Unten rechts: räumliche Verteilung der Beprobungsstandorte  $n_{xy}$ .

## Sand [%]

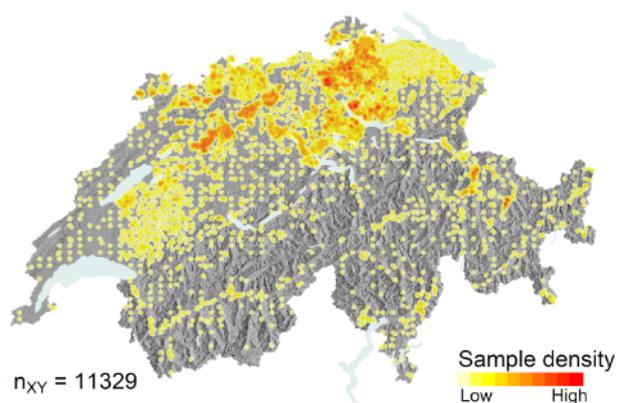
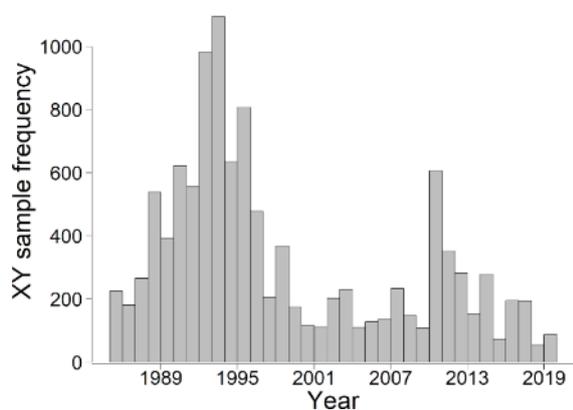
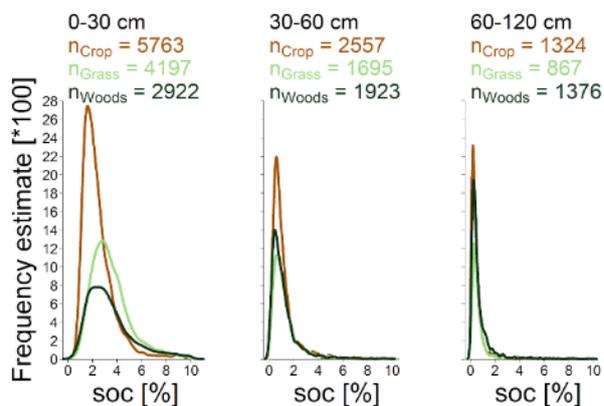
Min	0.1
Max	92.38
Q1	26.52
Median	41.2
Q2	52.81
Mean	39.97
Sd	17.67
n	19675



**Abbildung 3:** Statistische, zeitliche und räumliche Verteilung der im Labor gemessenen Sandgehalte (Sand) des NABODAT-Datensatzes v6. Oben: statistische Kennwerte der Laboranalysen (Min: Minimum; Max: Maximum; Q1: 25%-Quantil; Q2: 75%-Quantil; Sd: Standardabweichung; n: Anzahl Erhebungen) und Häufigkeitsverteilungen nach Tiefenstufen und Landbedeckung (braun: Ackerland; hellgrün: Grasland; dunkelgrün: Wald); Unten links: Häufigkeitsverteilung über die Zeit; Unten rechts: räumliche Verteilung der Beprobungsstandorte  $n_{xy}$ .

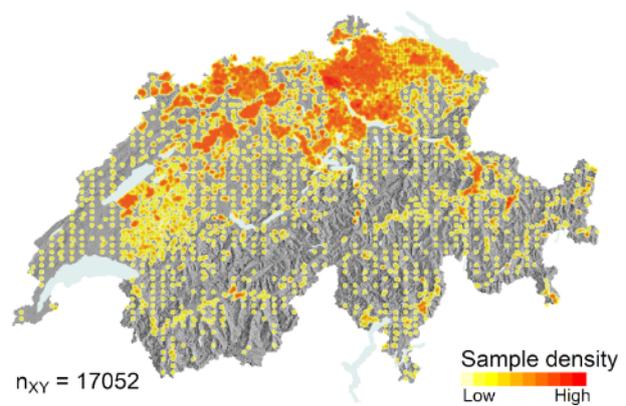
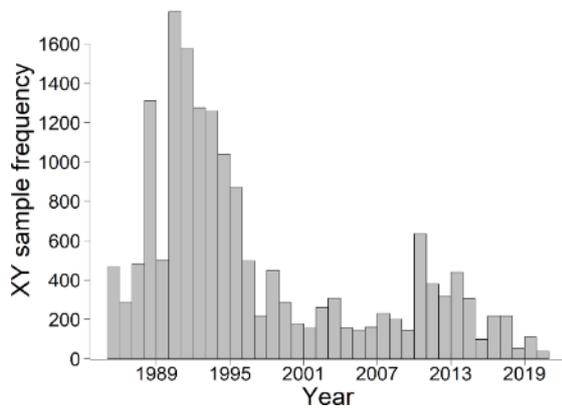
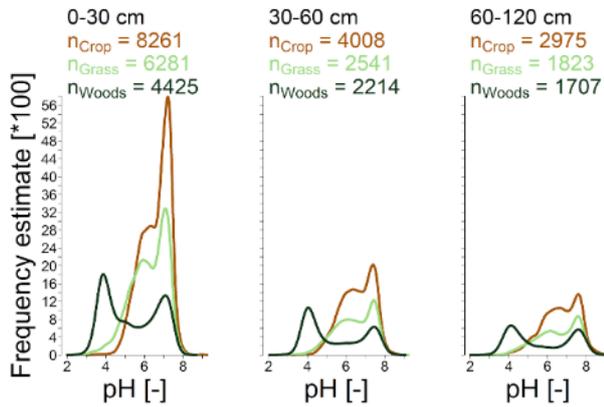
## SOC [%]

Min	0.01
Max	10.19
Q1	0.77
Median	1.75
Q2	3
Mean	2.14
Sd	1.76
n	22624



**Abbildung 4:** Statistische, zeitliche und räumliche Verteilung der im Labor gemessenen Kohlenstoffgehalte (SOC) des NABODAT-Datensatzes v6. Oben: statistische Kennwerte der Laboranalysen (Min: Minimum; Max: Maximum; Q1: 25%-Quantil; Q2: 75%-Quantil; Sd: Standardabweichung; n: Anzahl Erhebungen) und Häufigkeitsverteilungen nach Tiefenstufen und Landbedeckung (braun: Ackerland; hellgrün: Grasland; dunkelgrün: Wald); Unten links: Häufigkeitsverteilung über die Zeit; Unten rechts: räumliche Verteilung der Beprobungsstandorte  $n_{xy}$ .

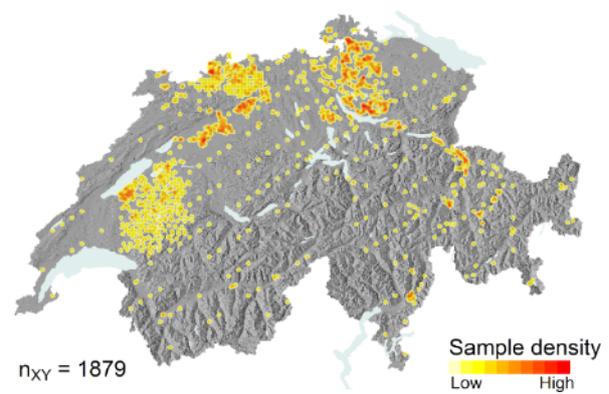
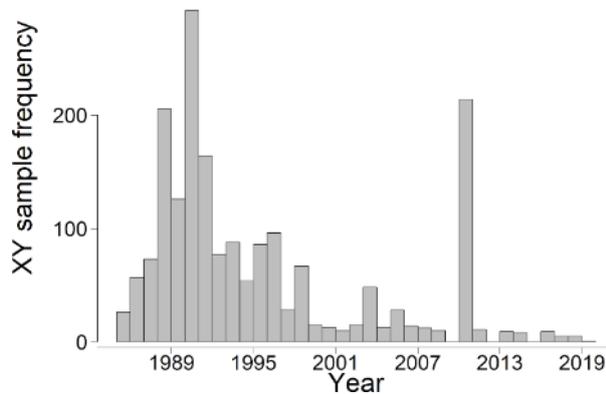
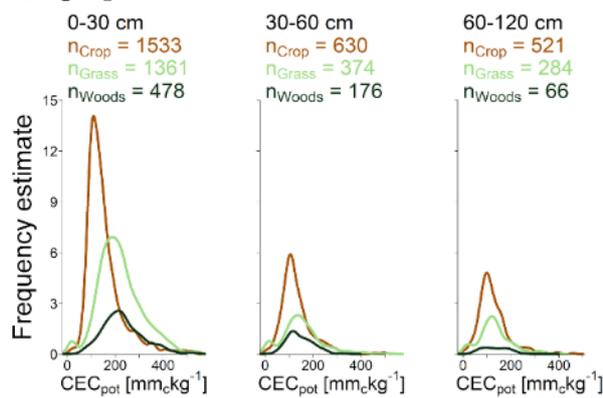
pH [-]	
Min	2.5
Max	9
Q1	5.5
Median	6.5
Q2	7.2
Mean	6.2
Sd	1.1
n	34235



**Abbildung 5:** Statistische, zeitliche und räumliche Verteilung der im Labor gemessenen pH-Werte (pH) des NABODAT-Datensatzes v6. Oben: statistische Kennwerte der Laboranalysen (Min: Minimum; Max: Maximum; Q1: 25%-Quantil; Q2: 75%-Quantil; Sd: Standardabweichung; n: Anzahl Erhebungen) und Häufigkeitsverteilungen nach Tiefenstufen und Landbedeckung (braun: Ackerland; hellgrün: Grasland; dunkelgrün: Wald); Unten links: Häufigkeitsverteilung über die Zeit; Unten rechts: räumliche Verteilung der Beprobungsstandorte  $n_{xy}$ .

## CEC<sub>pot</sub> [mm<sub>c</sub>kg<sup>-1</sup>]

Min 1  
 Max 554  
 Q1 109  
 Median 150  
 Q2 214  
 Mean 170  
 Sd 88  
 n 5423



**Abbildung 6:** Statistische, zeitliche und räumliche Verteilung der im Labor gemessenen potenziellen Kationenaustauschkapazität (CEC<sub>pot</sub>) des NABODAT-Datensatzes v6. Oben: statistische Kennwerte der Laboranalysen (Min: Minimum; Max: Maximum; Q1: 25%-Quantil; Q2: 75%-Quantil; Sd: Standardabweichung; n: Anzahl Erhebungen) und Häufigkeitsverteilungen nach Tiefenstufen und Landbedeckung (braun: Ackerland; hellgrün: Grasland; dunkelgrün: Wald); Unten links: Häufigkeitsverteilung über die Zeit; Unten rechts: räumliche Verteilung der Beprobungsstandorte  $n_{xy}$ .

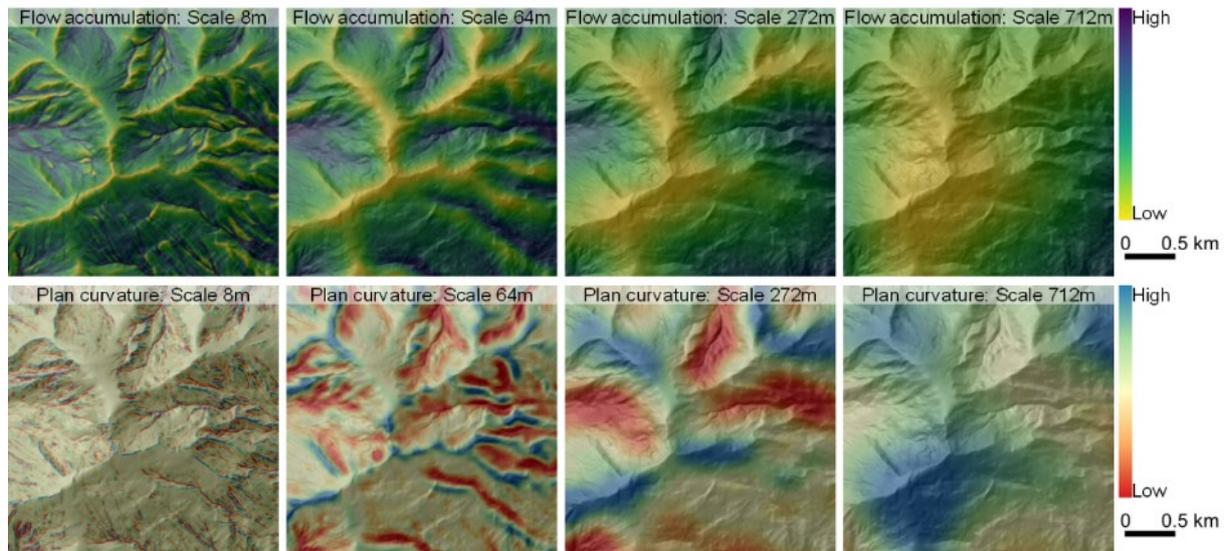
## 2.3 Ableitung flächendeckender Umweltvariablen

### *Terraindaten*

Terraineigenschaften sind wichtige bodenbildende Faktoren und können auf Basis digitaler Höhenmodelle abgeleitet werden. Des Weiteren sind sie wichtige Proxygrößen für geologische und klimatische Phänomene und Eigenschaften (Behrens et al. 2010). Mittels einer multiskaligen Terrainanalyse wurden Terraineigenschaften flächendeckend für die Schweiz in verschiedenen räumlichen Skalenbereichen beschrieben (Behrens et al. 2018; Behrens et al. 2019; Behrens and Viscarra Rossel 2020). Als Datengrundlage für die Terrainanalyse dient das digitale Höhenmodell swissALTI<sup>3D</sup> in einer räumlichen Auflösung von 2 x 2 m, welches auf Basis flugzeuggestützter Laserscan-Messungen berechnet wird (Swisstopo 2023). Dabei wurden 11 Terrainparameter in jeweils 14 verschiedenen räumlichen Auflösungen zwischen 8m und 4880m abgeleitet (Tabelle 2). Im Ergebnis resultierten aus der multiskaligen Terrainanalyse insgesamt 154 landesweite Rasterdatensätze.

*Tabelle 2: Parameter der multiskaligen Terrainanalyse.*

Beschreibung/Name	Referenz
Elevation (a.s.l.) [m]	Swisstopo, 2023
Slope Inclination [°]	Zevenbergen and Thorne, 1987
Terrain Ruggedness Index [-]	Riley et al., 1999
Terrain Roughness Index [-]	Wilson et al., 2007
Topographic Position Index [-]	Guisan et al., 1999
Profile Curvature [-]	Zevenbergen and Thorne, 1987
Planform Curvature [-]	Zevenbergen and Thorne, 1987
Flow Accumulation, log10 [-]	Quinn et al., 1991
Convergence Index [-]	Kiss, 2004
Eastness [-], sin(aspect in rad)	Wilson et al., 2007
Northness [-], cos(aspect in rad)	Wilson et al., 2007

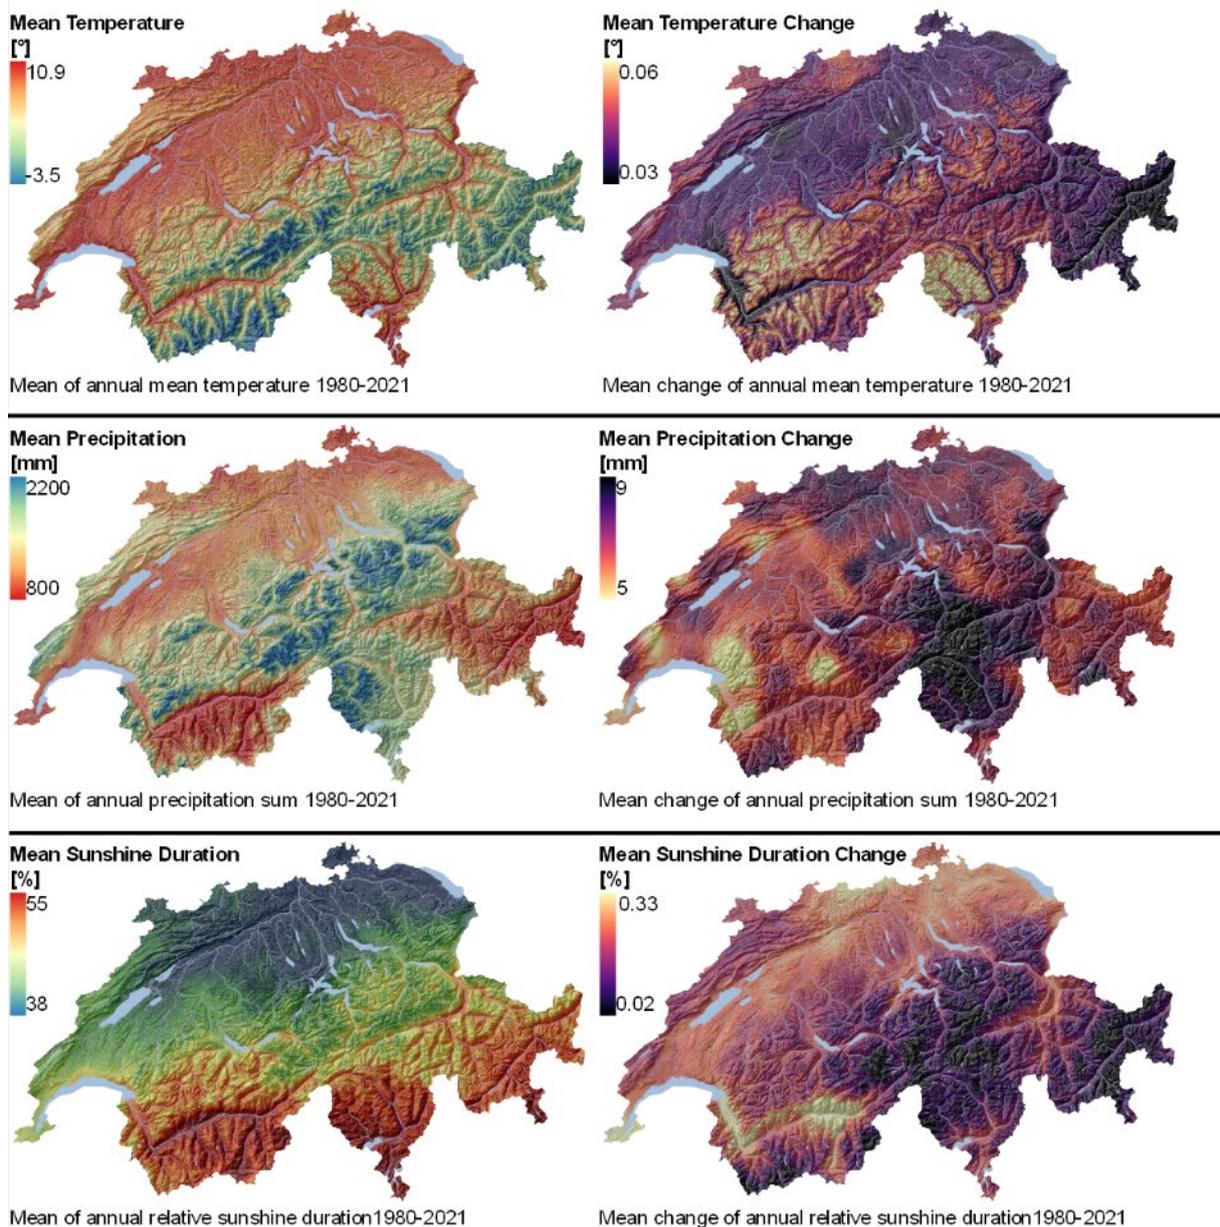


**Abbildung 7:** Multiskalige Reliefanalyse am Beispiel der Fließakkumulation (Flow Accumulation  $FLA_{0g}$ ) und der planaren Krümmung (Plan Curvature: CPL) in den Skalen 8 m, 64 m, 272 m und 712 m.

### **Klimadaten**

Das Klima beeinflusst die Bodengenese unter anderem aufgrund von Wechselbeziehungen mit hydrologischen Kreisläufen. Diese Wechselbeziehungen stehen wiederum in Zusammenhang mit Bodenerosion, sowie Veränderungen der organischen Substanz, Textur, Wasserspeicherkapazität und Kationenaustauschkapazität des Bodens (Brevik 2013).

Als Datengrundlage zur Ableitung von räumlich-zeitlichen Klimaeigenschaften für die Schweiz dienen landesweite Rasterdaten zu jährlichen Niederschlagssummen, mittlerer Temperatur und mittlerer relativer Sonnenscheindauer in einer räumlichen Auflösung von 1000 x 1000 m (Meteoswiss 2021). Die Rasterdaten zu Niederschlag und Temperatur basieren auf den Arbeiten von Frei et al. (2006; 2014). Die Datengrundlage dieser Arbeiten ist ein Messnetz aus 430 Niederschlags- und 125 Temperaturmessstationen in der Schweiz. Die relative Sonnenscheindauer entspricht dem Verhältnis aus effektiver Sonnenscheindauer und maximal möglicher Sonnenscheindauer bei wolkenloser Atmosphäre (Frei et al. 2015). Im Ergebnis stehen für den Zeitraum zwischen 1980 und 2021 landesweite Rasterdaten die mittlere Temperatur, die mittlere Niederschlagssumme und die mittlere relative Sonnenscheindauer zur Verfügung. Zudem wurde für jeden Klimaparameter und für den gleichen Zeitraum die mittlere jährliche Veränderung abgeleitet (Abbildung 8).



**Abbildung 8:** Landesweite Klimaparameter für den Zeitraum 1980 bis 2021: Mittlere Temperatur (Temperature mean; oben links) und mittlere jährliche Temperaturveränderung (Mean temperature change; oben rechts); mittlerer Niederschlag (Precipitation mean; zentral links) und mittlerer jährliche Niederschlagsveränderung (Mean precipitation change; zentral rechts); mittlere relative Sonnenscheindauer (Mean sunshine duration; unten links) und deren jährliche Veränderung (Mean sunshine duration; unten rechts).

### ***Vegetations- und Landnutzungsdaten***

Vegetation und Landnutzung sind ein wichtiger Einflussfaktor für Bodenprozesse und -eigenschaften und sind folglich bedeutende Komponenten für die Beschreibung bodenbildender Prozesse. Sie beeinflussen unter anderem die Kohlenstoff- und Nährstoffkreisläufe und verändern dabei die Bodenbiologie und die Bodenphysik (De Vries et al. 2013). Zudem beeinflusst

Landnutzungswandel Bodeneigenschaften wie z.B. organische Substanz, Raumgewicht und Wasserspeicherkapazität (Haghighi et al. 2010).

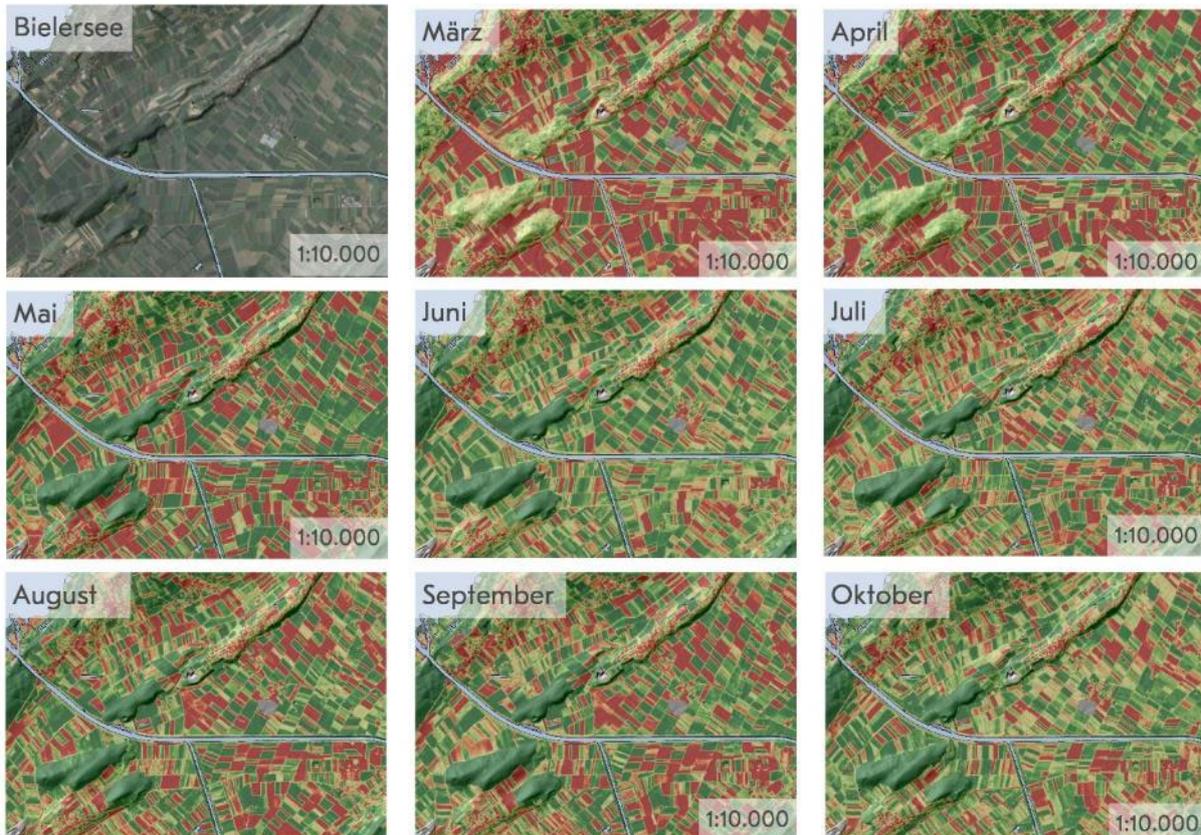
Mittels einer multi-temporalen Vegetations- und Landnutzungsanalyse wurden Vegetationseigenschaften und Landnutzung flächendeckend für die Schweiz in verschiedenen zeitlichen Skalenbereichen und ausgehend von jedem Jahr zwischen 1985 und 2021 als Referenzjahr abgeleitet. Als Datengrundlage dienen satellitenbasierte Zeitreihen von dem Spektralindex «Normalized Difference Vegetation Index» (NDVI, Rouse et al. 1974) der Landsat-Missionen seit 1985 und der Sentinel-Missionen seit 2018 (ESA 2023; USGS 2023). Die räumliche Auflösung der Landsatdaten beträgt 30 x 30 m, die der Sentineldaten 10 x 10 m. Der NDVI ist ein Indikator für die Vegetationsdichte und –produktivität, der Index skaliert zwischen -1 und 1. Generell lassen negative NDVI-Werte auf Wasserflächen, niedrige positive NDVI-Werte auf annähernd vegetationsfreie Flächen und weiter ansteigende Werte auf zunehmend mehr Biomasse schliessen.

Alle verfügbaren Landsat- und Sentinel-Daten wurden zu mehreren jährlichen Rasterzeitreihen aggregiert (Tabelle 3). Für diese Zeitreihen wurden für jedes Jahr rückwirkend im Intervall von fünf Jahren für Landsat-Daten und drei Jahren für Sentinel-Daten Trendfunktionen (Median, Standardabweichung, Theil-Sen-Trendschätzer) berechnet (Sen 1968; Wu et al 2014).

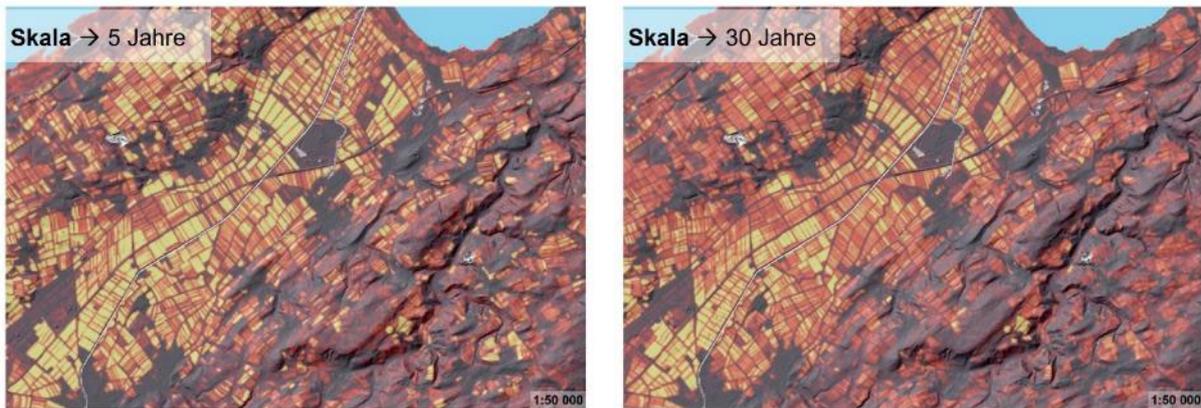
**Tabelle 3:** Sentinel- und Landsat-Zeitserien anhand ihrer Aggregation, des zeitlichen Bezugs und der räumlichen Auflösung.

Datenquelle	Aggregation	Zeitlicher Bezug	Räumliche Auflösung
Sentinel 2 – NDVI	Mittelwert	Monatlich 2018 – 2021	10 m
Sentinel 2 – NDVI	Median	Jährlich 2017 – 2021	10 m
Landsat – NDVI		Jährlich 1985 – 2021	30 m
Sentinel 2 – NDVI	Maximum	Jährlich 2017 – 2021	10 m
Landsat – NDVI		Jährlich 1985 – 2021	30 m
Sentinel 2 – NDVI	Minimum	Jährlich 2017 – 2021	10 m
Landsat – NDVI		Jährlich 1985 – 2021	30 m
Sentinel – NDVI	Standardabweichung	Jährlich 2017 – 2021	10 m
Landsat – NDVI		Jährlich 1985 – 2021	30 m

Weiterhin wurden die Sentinel-Daten zu monatlichen Rasterzeitreihen von März bis Oktober für die Jahre 2018 bis 2021 auf Basis des Mittelwerts aggregiert (Abbildung 9). Die Kombination der erzeugten Rasterdaten beschreibt den Zustand und die Veränderung der Vegetation und Landnutzung für jedes Jahr seit 1985 in mehreren Zeitperioden (Abbildung 10). Im Gesamten resultieren aus der multi-temporalen Analyse der Fernerkundungsdaten rund 500 landesweite Rasterdatensätze zur Vegetation- und Landnutzung.



**Abbildung 9:** Vegetations- und Landnutzungsanalyse am Beispiel des monatlichen Vegetationszustandes südlich des Bielersees im Jahr 2021. Die abgebildete Zeitreihe basiert auf dem Spektralindex NDVI der Sentinel-2-Satelliten (NDVI: Normalized Difference Vegetation Index; Rot-Gelb-Grün-Farbskala entspricht niedrig zu hohem NDVI).



**Abbildung 10:** Vegetations- und Landnutzungsanalyse am Beispiel der Landnutzungsintensität in zwei Zeitskalen südöstlich des Neuenburgersees. Die Landnutzungsintensität basiert auf der jährlichen NDVI-Standardabweichung gemittelt über 5 Jahre (links) und 30 Jahre (rechts), ausgehend vom Referenzjahr 2021 (NDVI: Normalized Difference Vegetation Index; Violett-Rot-Gelb-Farbskala entspricht niedriger zu hoher Landnutzungsintensität).

### **Spektrale Bodendaten – «Bare Soil»**

Physische und chemische Eigenschaften des geologischen Ausgangsmaterials sind ein bedeutender Faktor der Bodengenese (Loiseau et al., 2020). Mineralogie, Granulometrie und Farbe stehen in engem Zusammenhang mit der spektralen Signatur des unbedeckten Bodens (Gray et al., 2016). Die Erstellung von flächendeckenden Karten, welche die spektrale Signatur des unbedeckten Bodens («bare soil») anzeigen, kann die räumliche Vorhersage von Bodeneigenschaften verbessern, vor allem für Oberböden.

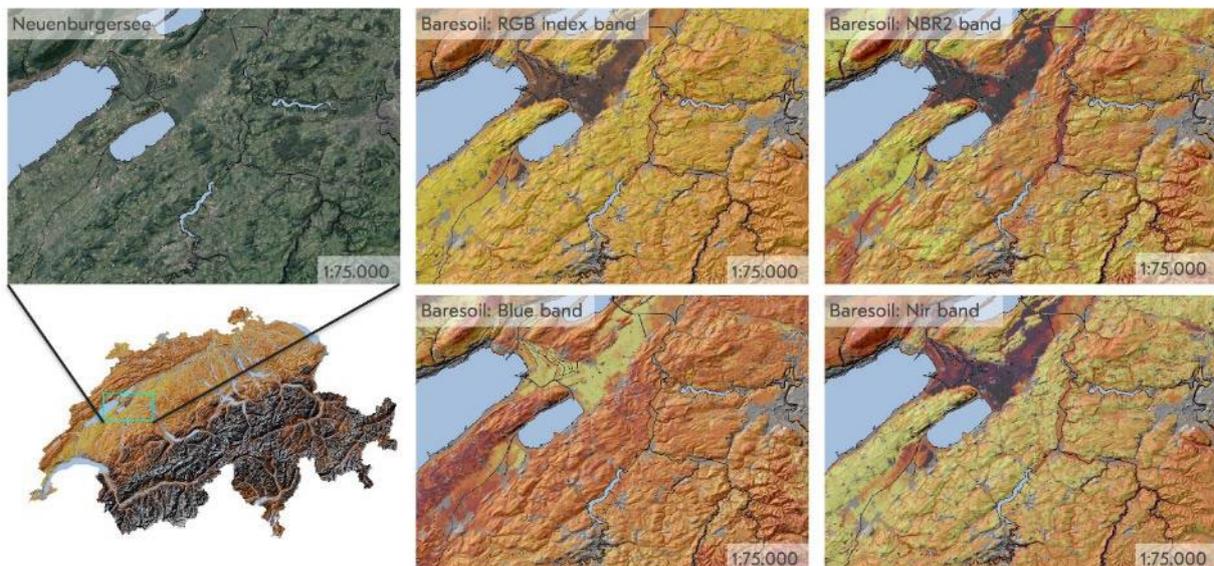
Anhand von Satellitendaten wurde die spektrale Signatur des Bodens für die landwirtschaftliche Fläche der Schweiz abgeleitet. Als Datengrundlage dienen Zeitreihen der Landsat-Missionen seit 1985 in einer räumlichen Auflösung von 30 x 30 m (USGS 2023). Für diese wurden die Spektralindizes NDVI (Rouse et al. 1974) und NBR2 (Normalized Burn Ratio 2; Garcia and Caselles 1991) als zusätzliche Informationen abgeleitet. Der NBR2 findet u.a. Verwendung in Fragestellungen zu Streuauflage, Bodenfeuchte und Bodentextur (Dematté et al., 2018). Der Index ist zwischen -1 und 1 skaliert, und wird auf Basis der Spektralbänder des kurzwelligen Infrarotbereichs berechnet.

Die Kombination aus den Spektralindizes NDVI und NBR2 ermöglicht es Flächen von unbedecktem Boden zu identifizieren und die Rasterzeitreihen entsprechend zu filtern. Da die landwirtschaftlichen Flächen nicht zur gleichen Zeit ohne Bodenbedeckung sind, wurden die Rasterzeitreihen zeitlich aggregiert (Abbildung 11). Dabei werden alle Flächen, die temporär während der gesamten Zeitspanne von 1985 bis 2021 frei von Vegetation waren, berücksichtigt. Für Flächen, die kontinuierlich seit 1985 mit Vegetation bedeckt waren (z.B. Wald), wurde die spektrale

Signatur mittels maschinellen Lernens auf Basis aller Rasterzellen mit verfügbaren NVDI und NBR2 modelliert. Als Ergebnis stehen 8 schweizweite Rasterdatensätze zur Verfügung (Tabelle 4).

**Tabelle 4:** Spektraldatensätze für den unbedeckten Boden («bare soil»).

Spektralkanal	Wellenlänge [nm]	Indexberechnung
BLUE	482 – 485	-
GREEN	560 – 569	-
RED	655 – 662	-
NIR	835 – 865	-
SWIR1	1609 – 1676	-
SWIR2	2206 – 2223	-
RGBindex		$RED * 65636 + GREEN * 256 + BLUE$
NDVI		$(NIR - RED) / (NIR + RED)$
NBR2		$(SWIR1 - SWIR2) / (SWIR1 + SWIR2)$



**Abbildung 11:** Spektrale Bodenindizes für den unbedeckten Boden («bare soil»). Abgebildet ist der Spektralkanal «RGB index» für die Fläche der Schweiz (unten links), sowie für die Region südöstlich des Neuenburgersees die Spektralkanäle «RGB index» (zentral oben), «BLUE» (zentral unten), «NBR2» (rechts oben) und «NIR» (rechts unten). Erklärung der Abkürzungen siehe Text und Tabelle 4.

## 2.4 Räumliche Modellierung der Bodeneigenschaften

Zielvariablen der digitalen Bodenkartierung sind die im Labor gemessenen Bodeneigenschaften des Nationalen Bodendatensatzes in der Version V6 (Ton, Schluff, Sand und Kohlenstoffgehalt, sowie pH-Wert und Kationenaustauschkapazität). Die Kovariablen für die räumliche Modellierung stellen die rasterbasierten und flächendeckend verfügbaren Umweltvariablen zu Relief, Klima, Vegetation und Landnutzungen, sowie die spektralen Bodeninformationen dar (Kapitel 2; total  $n = 668$  Kovariablen).

Das Modelldesign basiert auf dem nicht-parametrischen Ensemblemodell «Quantile Regression Forest» (QRF, Breiman, 2001; Meinshausen, 2006). Grundsätzlich generiert der Algorithmus eine Vielzahl randomisierter Entscheidungsbäume. Dabei wird die komplette statistische Verteilung der Zielvariablen in den Endknoten der Entscheidungsbäume erhalten. Auf Basis dieser Verteilungen im Ensemble werden Quantile als finale Prognose sowie als Prognoseintervalle abgeleitet. Die Randomisierung beruht auf jeweils zufällig gezogenen Teilmengen der Kalibrierungsdaten sowie auf einer zufälligen Auswahl einer Teilmenge der Kovariablen, die für jede Gabelung (Knoten) eines Entscheidungsbaumes getestet wird. Diejenige Teilmenge der Kalibrierungsdaten, die nicht für die Modellkalibrierung genutzt wird (out-of-bag, OOB-Daten), ermöglicht eine modellinterne Evaluierung. Diese erfolgt anhand der Berechnung der mittleren quadratischen Abweichung als Mittelwert über alle Entscheidungsbäume (OOB-Error). Für die finale Prognose wurde der Median aus der statistischen Verteilung in den Endknoten der Entscheidungsbäume verwendet. Die Prognoseunsicherheit basiert auf dem 90%-Prognoseintervall, definiert durch das 5%- und 95%-Perzentil der Verteilung in den Endknoten. Die Unsicherheit wird relativ zur Prognose angegeben (RPI: «Relative Prediction Interval»).

Für jede Bodeneigenschaft wurde ein separates Modell, welches die Tiefenstufe als weitere Kovariable berücksichtigt, erstellt. Dies ermöglicht räumliche Prognosen und Prognoseunsicherheiten für jede Tiefenstufe basierend auf einem einzigen Modell zu erstellen.

Die Validierung wurde über einen fünffachen «Split-Data-Ansatz» durchgeführt. Dabei wurde für jede Bodeneigenschaft der Datensatz zunächst nach Tiefenstufe (0 – 30 cm; 30 – 60 cm; 60 – 120 cm) und Landbedeckung («Ackerland», Grasland», «Wald») stratifiziert. Anschliessend wurde in jedem Stratum eine zufällige Teilmenge an Validierungsdaten im Verhältnis 20% (Validierung) zu 80% (Training) selektiert. Anhand der Trainingsdaten wurde das Modell kalibriert, wobei die Modellparameter mittels des OOB-Errors und eines «Grid-Tuning»-Ansatzes optimiert wurden. Die unabhängigen Validierungsdaten wurden herangezogen, um die Prognosegüte und die Prognoseunsicherheit zu bestimmen. Als Masszahl für die Prognosegüte wurden der „Root Mean Square Error“ (RMSE) und das Bestimmtheitsmass ( $R^2$ ) verwendet. Die Maßzahl für die relative Prognoseunsicherheit ist der RPI. Dieses Vorgehen wurde fünffach wiederholt, um die Variabilität

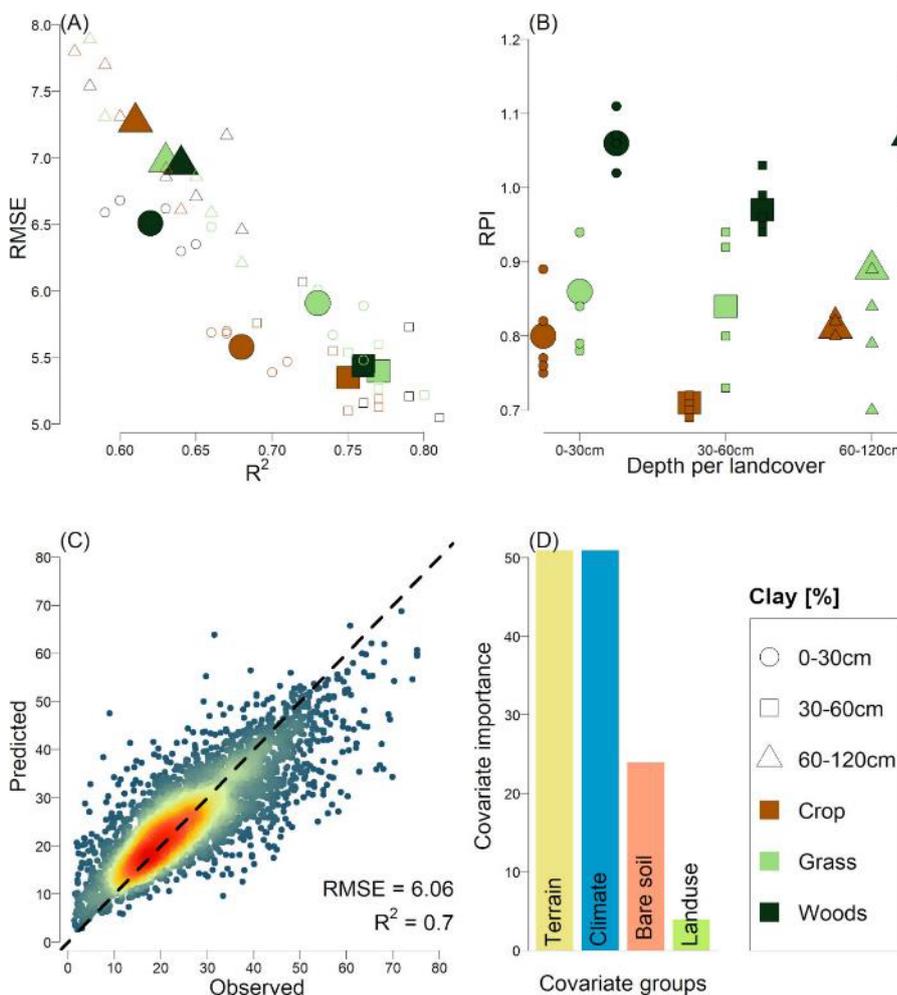
der Masszahlen zu analysieren, und um ein finales Modell zu berechnen. Die räumliche Auflösung der finalen Prognosen beträgt 90 x 90 m.

Das Modelldesign erlaubt es, den Einfluss der oben genannten Kovariablen auf die Prognose der jeweiligen Bodeneigenschaft zu analysieren (Feature Importance). Eine Feature-Importance Analyse erlaubt wichtige Rückschlüsse welche Kovariable am meisten zur räumlichen Variation einer Bodeneigenschaft beiträgt. Aufgrund der hohen Anzahl an Kovariablen wurden diese gemäss den oben aufgeführten Themen (Kapitel 2.3) gruppiert. Der Einfluss der jeweiligen Gruppe an Kovariablen auf die Prognose einer Bodeneigenschaft ergibt sich aus dem Vergleich zwischen dem OOB-Error des initialen Modells und dem OOB-Error von Modellen, in denen die Kovariablen zufällig permutiert wurden (Gregorutti et al. 2015).

### 3 Hinweiskarten Bodeneigenschaften

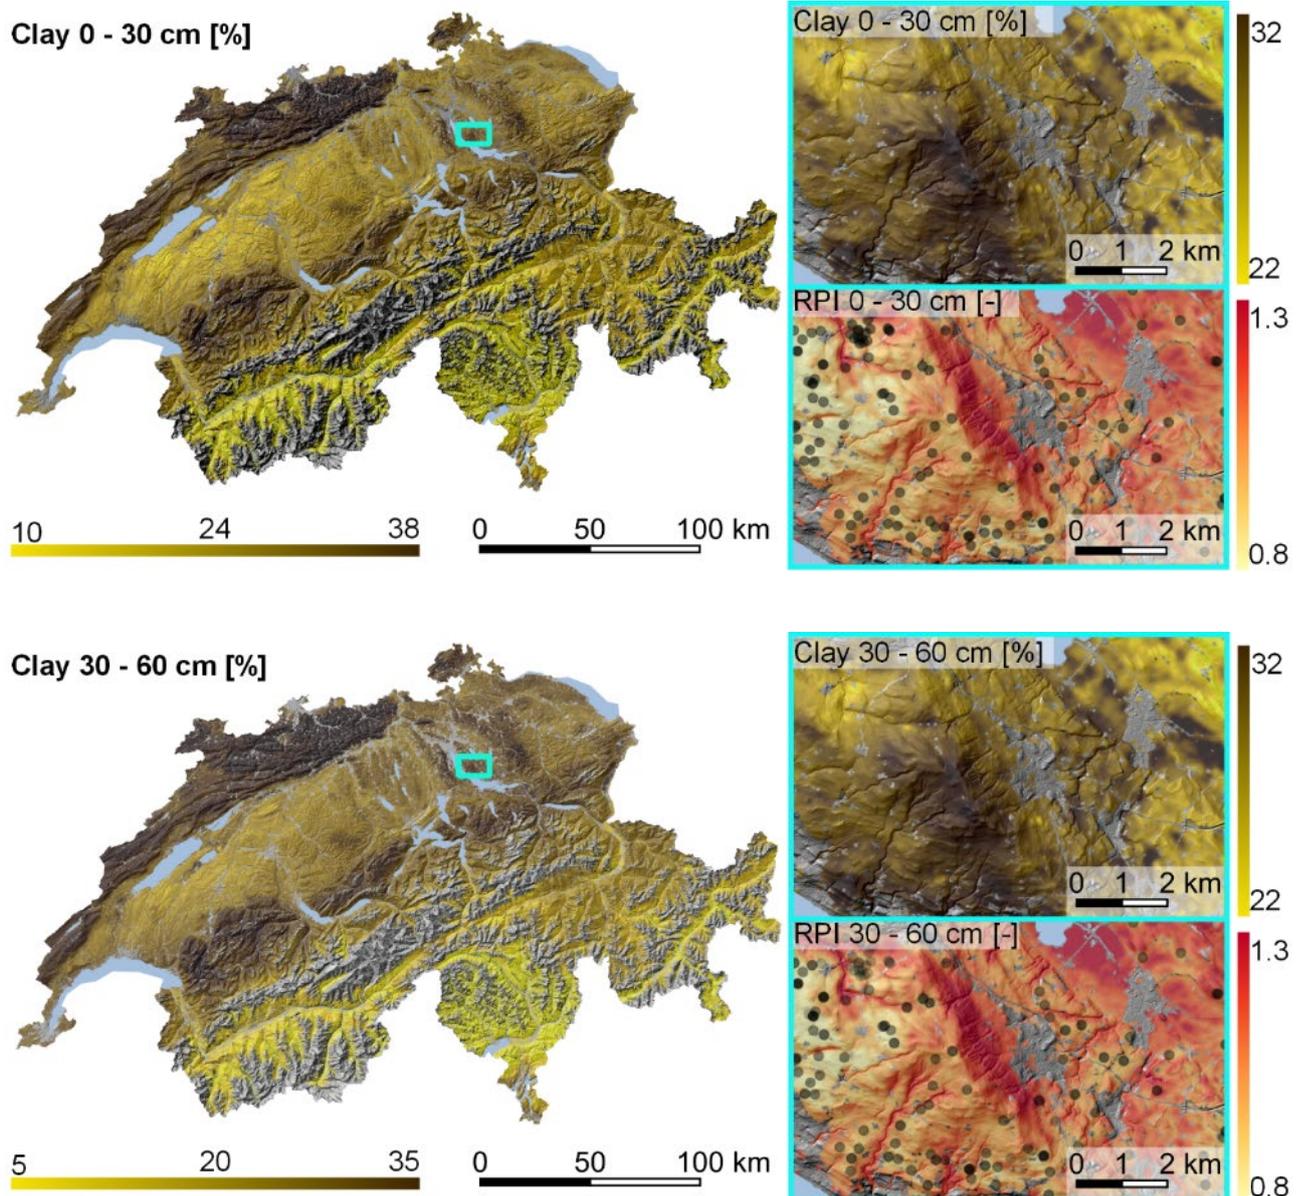
#### Tongehalt (Clay)

Die Prognosegüte bzw. -unsicherheit der digitalen Kartierung von Tongehalten über alle Tiefenstufen und Landbedeckungen hinweg zeigt einen  $R^2$  von 0.7, einen RMSE von 6.06 und ein RPI von 0.89. Bezogen auf die Tiefenstufen erreichte das Modell die höchste Prognosegüte und niedrigste Prognoseunsicherheit für die Tiefenstufe 30-60 cm, gefolgt von den Tiefenstufen 0-30 cm und 60-120 cm. Bezogen auf die Landbedeckungen sind die besten Ergebnisse für Ackerland, gefolgt von Grasland und Wald angezeigt. Der Einfluss der Kovariablen zu Terrain und Klima auf die Prognosegüte übertrifft den Einfluss der Kovariablen zu «bare soil» und Landnutzung (Abbildung 12a).



**Abbildung 12a:** Modellvalidierung für Tongehalte (Clay). (A) und (B): Prognosegüte (RMSE;  $R^2$ ) und -unsicherheit (RPI) für separate Tiefenstufen und Landbedeckungen (kleine Symbole markieren Einzelmodellergebnisse, grosse Symbole deren Mittelwert). (C): Heatmap der Prognosen (Predicted) vs. Validierungsdaten (Observed) über alle Tiefenstufen und Landbedeckungen. (D): Einfluss gruppiertter Kovariablen auf die Prognose.

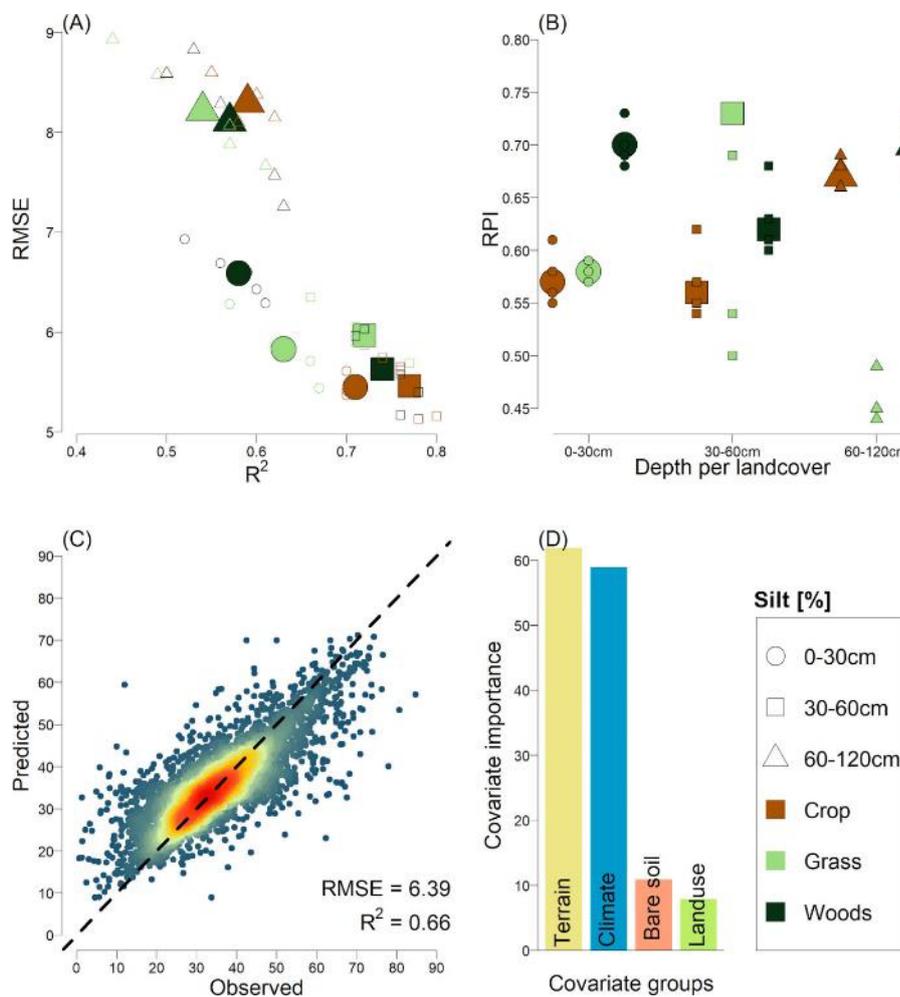
Die räumliche Verteilung der modellierten Tongehalte im Oberboden zeigt grundsätzlich ein konträres Muster zwischen den Regionen Jura, Mittelland, Alpennordflanke, östliche und westliche Zentralalpen und Alpensüdflanke. Dabei sind höhere Tongehalte (grösser 25%) vorwiegend im Jura und im Bereich des alpinen Grünlandes der Alpennordflanke vorzufinden. Die geringsten Tongehalte (kleiner 20%) befinden sich in den westlichen Zentralalpen und im Bereich Alpensüdflanke. Das Mittelland ist geprägt von Tongehalten zwischen 20% und 30% (Abbildung 12b).



**Abbildung 12b:** Landesweite Hinweiskarte des Tongehalts (Clay) für zwei Tiefenstufen, sowie beispielhaft für einen Ausschnitt aus dem Zürcher Oberland (Prognose und Prognoseunsicherheit RPI).

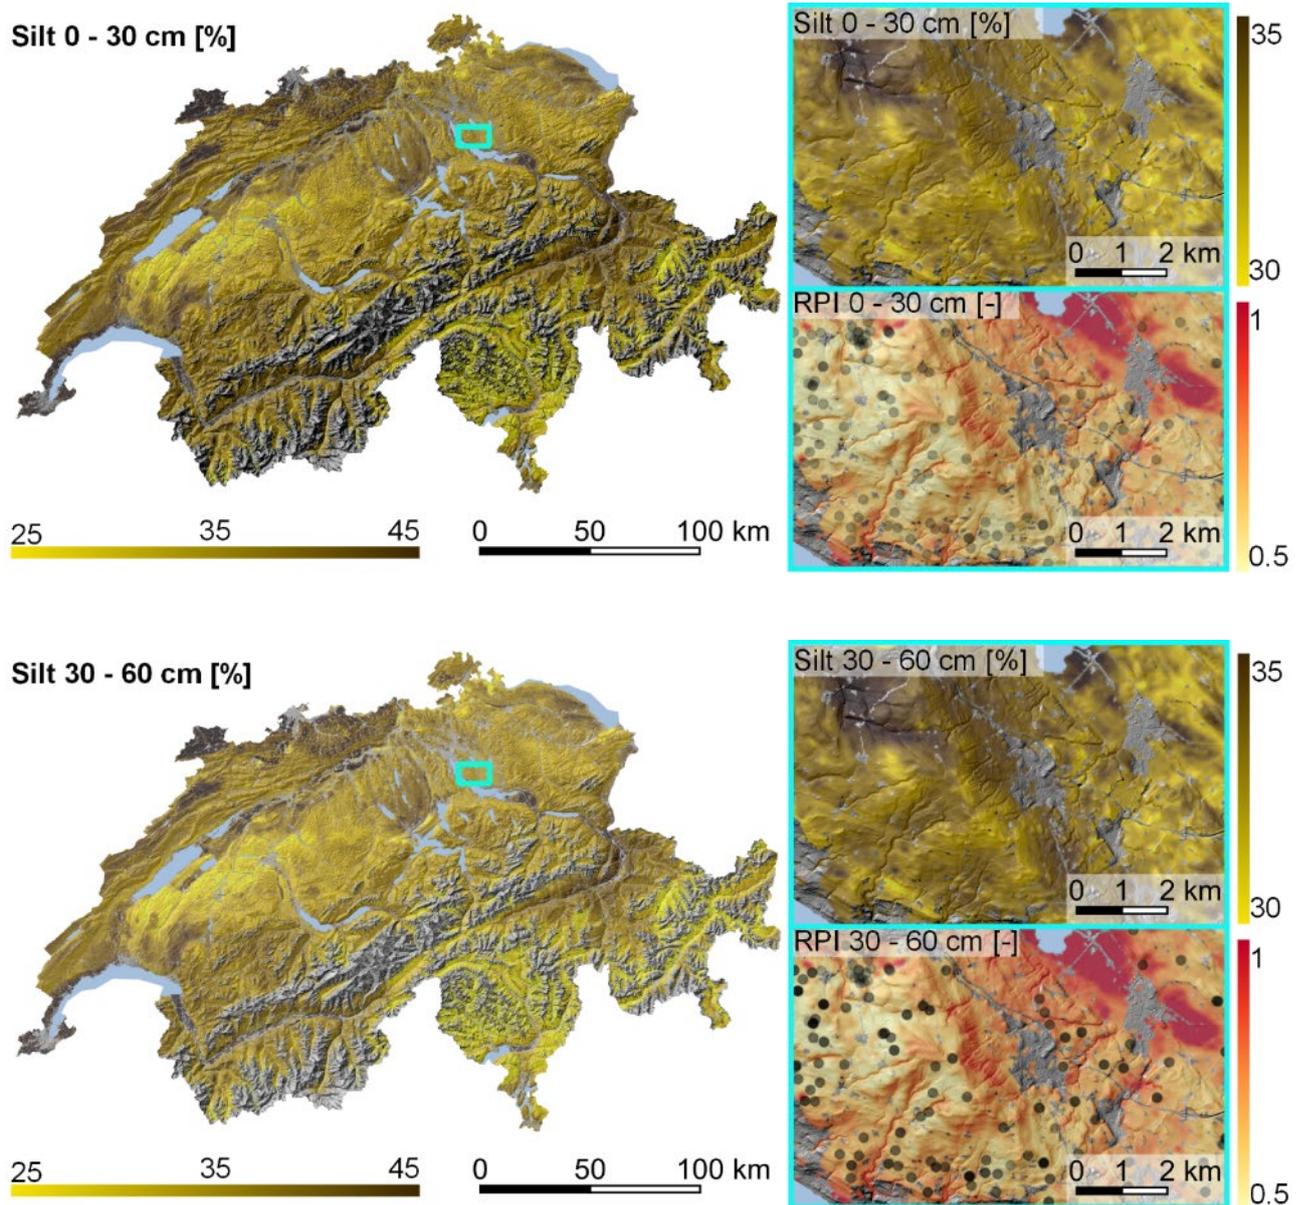
## Schluffgehalt (Silt)

Die Prognosegüte und Prognoseunsicherheit der digitalen Kartierung von Schluffgehalten über alle Tiefenstufen und Landbedeckungen hinweg zeigt einen  $R^2$  von 0.66, einen RMSE von 6.39 und einen mittleren RPI von 0.65. Bezogen auf die Tiefenstufen erreichte das Modell die höchste Prognosegüte für 30-60 cm, gefolgt von den Tiefenstufen 0-30 cm und 60-120 cm. Die Unterschiede in Prognoseunsicherheit über alle Tiefenstufen hinweg sind marginal. Bezogen auf die Landbedeckung liefert das Modell die besten Ergebnisse für Ackerland, während die Prognosegüten für Grasland und Wald leicht abfallen und Prognoseunsicherheiten steigen. Der Einfluss der Kovariablen zu Terrain und Klima auf die Prognosegüte übersteigt den Einfluss der Kovariablen zu «bare soil» und Landnutzung (Abbildung 13a).



**Abbildung 13a:** Modellvalidierung für Schluffgehalte (Silt). (A) und (B): Prognosegüte (RMSE;  $R^2$ ) und -unsicherheit (RPI) für separate Tiefenstufen und Landbedeckungen (kleine Symbole markieren Einzelmodellergebnisse, grosse Symbole deren Mittelwert). (C): Heatmap der Prognosen (Predicted) vs. Validierungsdaten (Observed) über alle Tiefenstufen und Landbedeckungen. (D): Einfluss gruppierteter Kovariablen auf die Prognose.

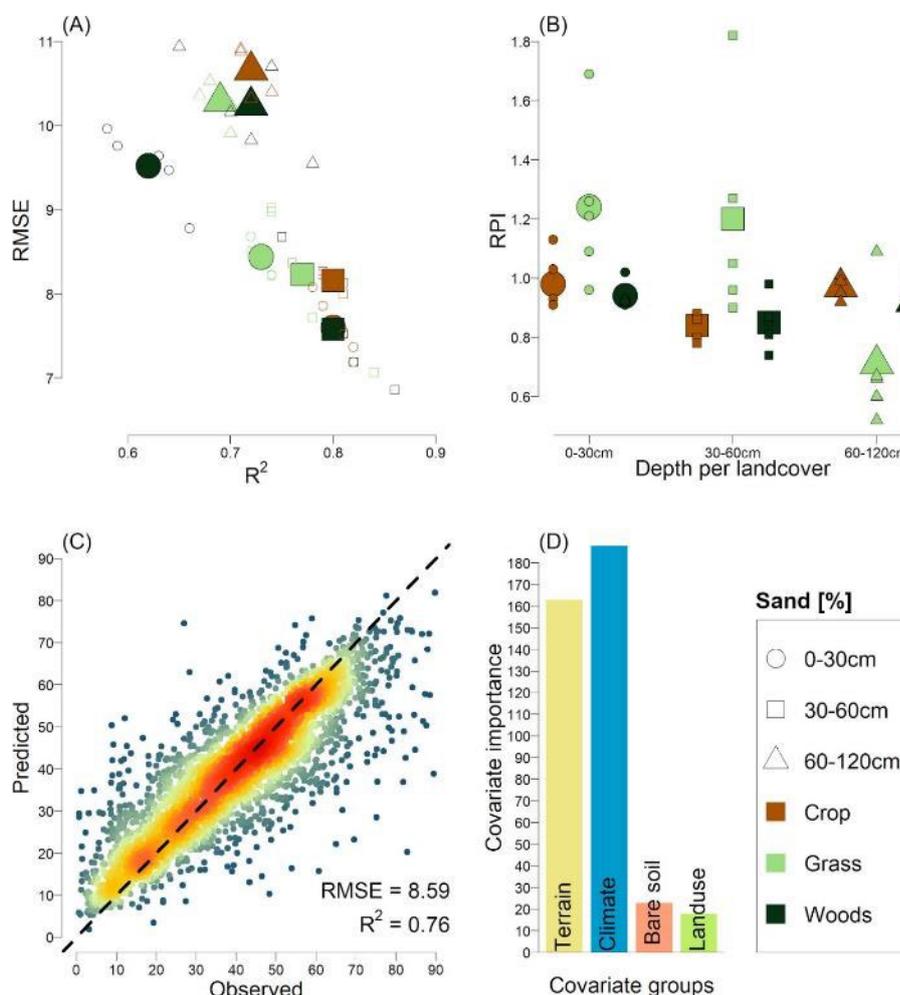
Die räumliche Verteilung der modellierten Schluffgehalte im Oberboden zeigt die geringsten Werte (kleiner 30%) im Bereich der Südalpenflanke, der östlichen Zentralalpen und in Teilen des westlichen Mittellands. Im Bereich der westlichen Zentralalpen, der Alpennordflanke, dem östlichen Mittelland und dem Jura sind die Schluffgehalte im Allgemeinen erhöht und betragen zwischen 30% und 40%. Lokal spezifisch, vor allem in Teilen des östlichen und nördlichen Jura, können die Schluffgehalte auf über 40% steigen (Abbildung 13b).



**Abbildung 13b:** Landesweite Hinweiskarte des Schluffgehalts (Silt) für zwei Tiefenstufen, sowie beispielhaft für einen Ausschnitt aus dem Zürcher Oberland (Prognose und Prognoseunsicherheit RPI).

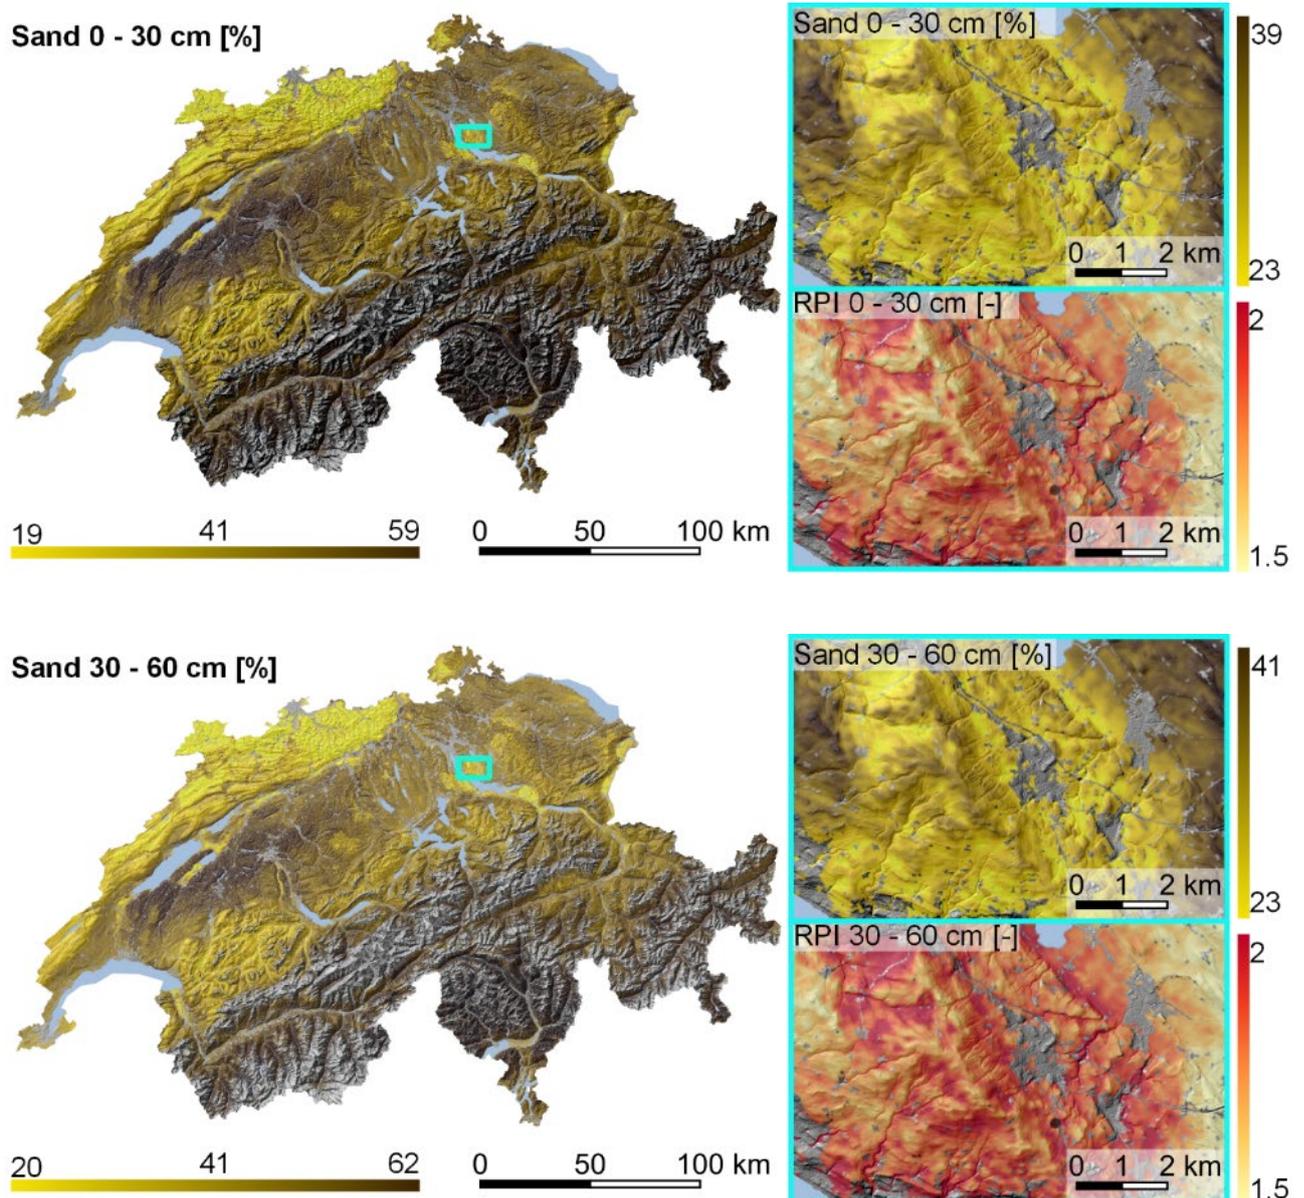
## Sandgehalt (Sand)

Die Prognosegüte und Prognoseunsicherheit der digitalen Kartierung von Sandgehalten über alle Tiefenstufen und Landbedeckungen hinweg zeigt einen  $R^2$  von 0.76, einen RMSE von 8.59 und ein mittleren RPI von 0.96. Bezogen auf die Tiefenstufen zeigt das Modell die höchste Prognosegüte für den Bereich 30-60 cm, gefolgt von den Tiefenstufen 0-30 cm und 60-120 cm. Dieser Trend ist bezüglich der Prognoseunsicherheit entgegengesetzt, wobei Unterschiede zwischen den Tiefenstufen marginal sind. Bezogen auf die Landbedeckung finden sich die höchsten Prognosegüten für das Ackerland, gefolgt von Grasland und Wald. Prognoseunsicherheiten sind für das Grasland am höchsten, während das Ackerland und Wald geringere Werte aufweisen. Der Einfluss von Terrain- und Klima-Kovariablen auf das Modell übersteigt den Einfluss der Kovariablen zu «bare soil» und Landnutzung (Abbildung 14a).



**Abbildung 14a:** Modellvalidierung für Sandgehalte (Sand). (A) und (B): Prognosegüte (RMSE;  $R^2$ ) und -unsicherheit (RPI) für separate Tiefenstufen und Landbedeckungen (kleine Symbole markieren Einzelmodellergebnisse, grosse Symbole deren Mittelwert). (C): Heatmap der Prognosen (Predicted) vs. Validierungsdaten (Observed) über alle Tiefenstufen und Landbedeckungen. (D): Einfluss gruppierter Kovariablen auf die Prognose.

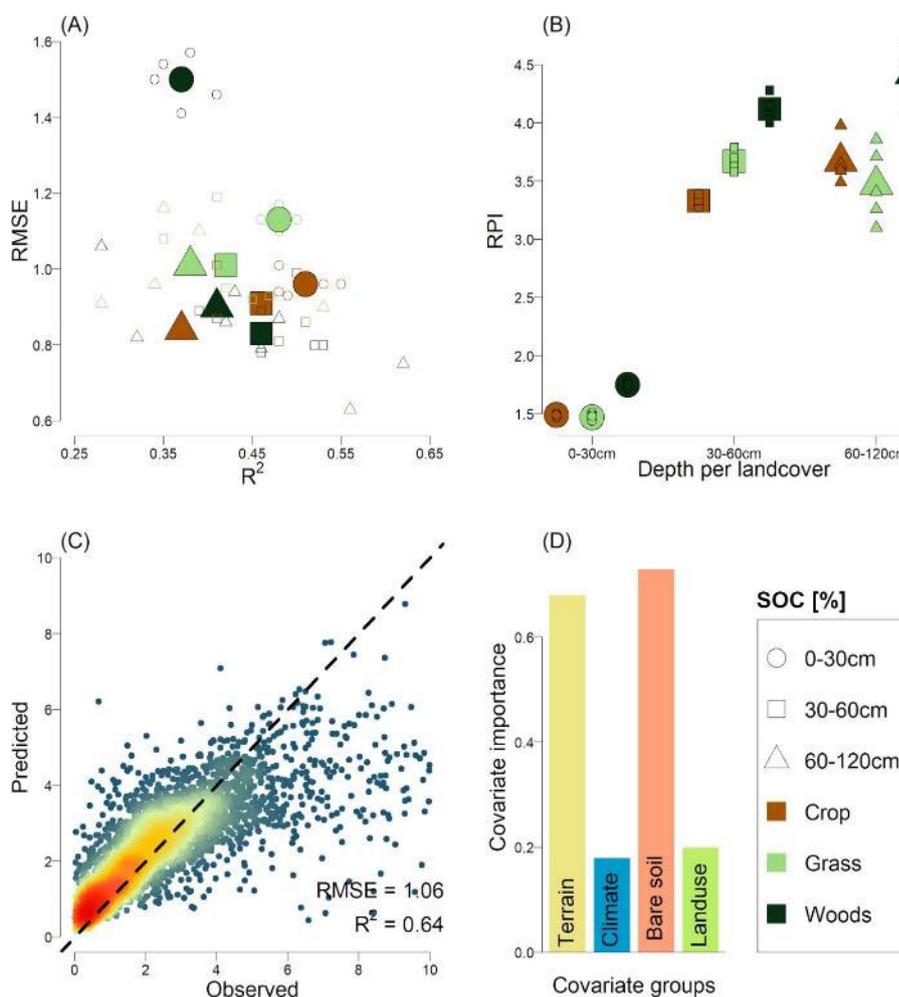
Die räumliche Verteilung der modellierten Sandgehalte im Oberboden zeigt die geringsten Werte (kleiner 25%) im Bereich des östlichen und nördlichen Jura. Im Mittelland, der Alpennordflanke und in Teilen der östlichen Zentralalpen steigen die Sandgehalte auf 25% bis 50%, wobei niedrigere Werte im Bereich alpinen Grünlandes vorwiegend sind. Im Bereich der westlichen Zentralalpen und der Alpensüdflanke sind die Sandgehalte am höchsten und übersteigen 50% (Abbildung 14b).



**Abbildung 14b:** Landesweite Hinweiskarte des Sandgehalts (Sand) für zwei Tiefenstufen, sowie beispielhaft für einen Ausschnitt aus dem Zürcher Oberland (Prognose und Prognoseunsicherheit RPI).

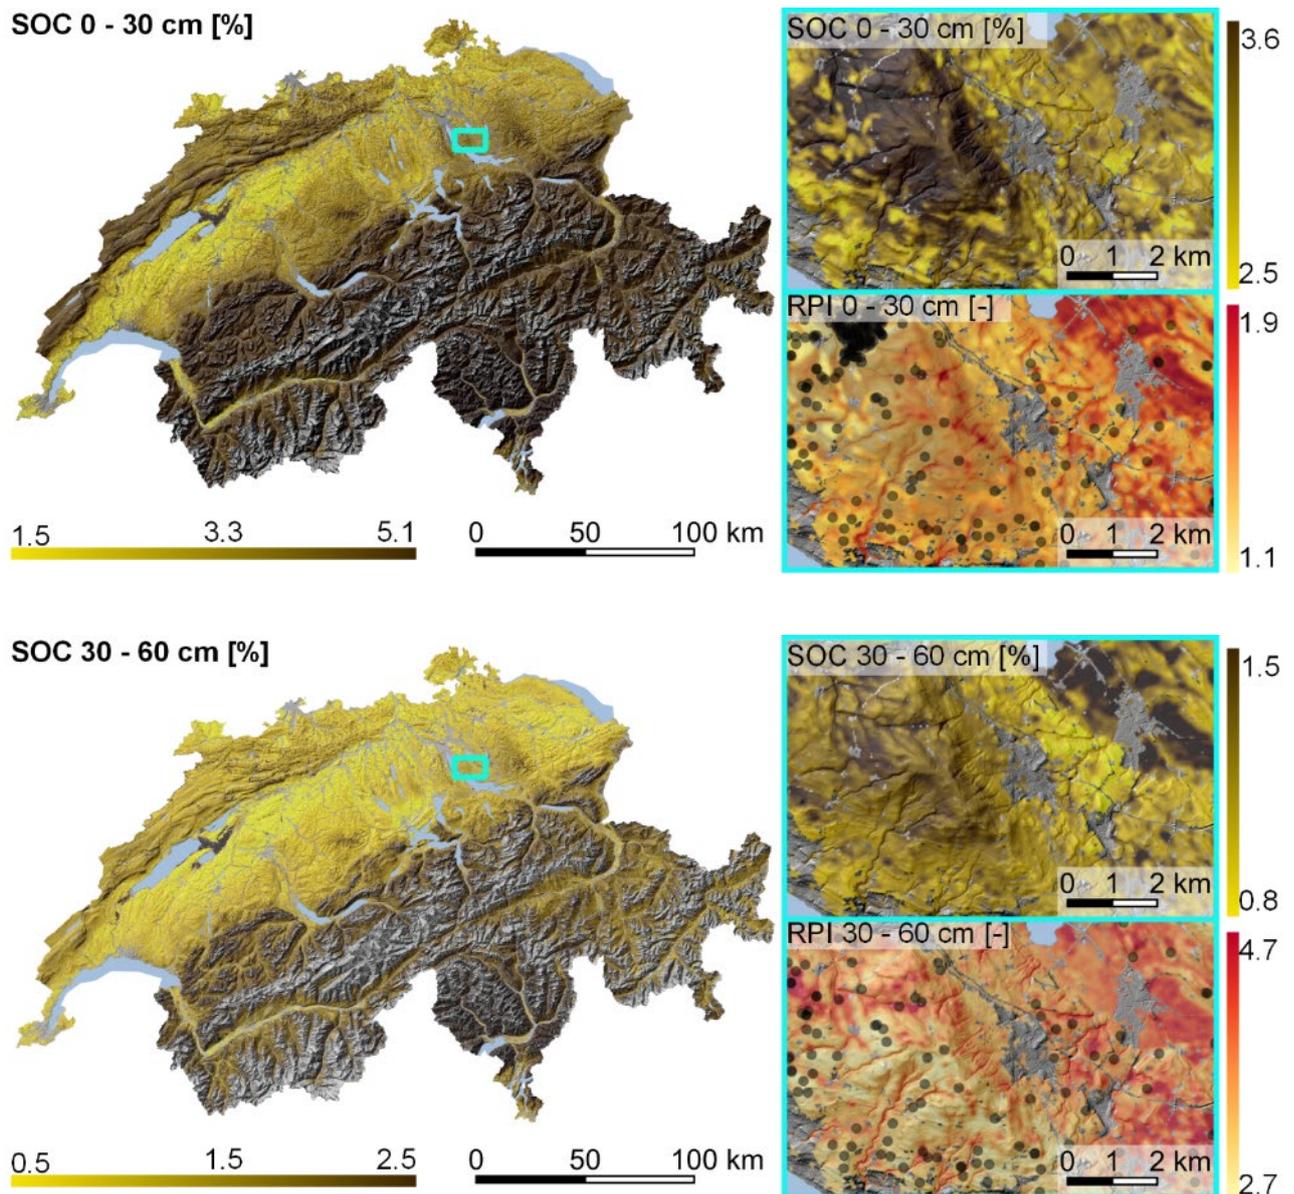
## Kohlenstoffgehalt (SOC)

Die Prognosegüte und -unsicherheit der digitalen Kartierung von Kohlenstoffgehalten über alle Tiefenstufen und Landbedeckungen hinweg zeigt ein  $R^2$  von 0.64, einen RMSE von 1.06 und ein RPI von 3.04. Bezogen auf die Tiefenstufen zeigt das Modell die höchste Prognosegüte ( $R^2$ -Werte) für 0-30 cm, gefolgt von 30-60 cm und 60-120 cm. Mittels RMSE zeigen sich die besten Ergebnisse für den Unterboden. Die Prognoseunsicherheiten folgen dem Trend der  $R^2$ -Werte. Bezogen auf Landbedeckungen und anhand der  $R^2$ -Werte liefert das Modell die beste Prognosegüte für Grasland, gefolgt von Ackerland und Wald. Mittels RMSE weist Ackerland eine höhere Güte im Vergleich zu Grasland auf, während die Prognoseunsicherheiten demselben Trend folgen. Der Einfluss von «bare soil»- und Terrain-Kovariablen auf die Prognosegüte übersteigt den Einfluss von Klima- und Landnutzungs-Kovariablen (Abbildung 15a).



**Abbildung 15a:** Modellvalidierung für Kohlenstoffgehalte (SOC). (A) und (B): Prognosegüte (RMSE;  $R^2$ ) und -unsicherheit (RPI) für separate Tiefenstufen und Landbedeckungen (kleine Symbole markieren Einzelmodellresultate, grosse Symbole deren Mittelwert). (C): Heatmap der Prognosen (Predicted) vs. Validierungsdaten (Observed) über alle Tiefenstufen und Landbedeckungen. (D): Einfluss gruppierter Kovariablen auf die Prognose.

Die räumliche Verteilung der modellierten Kohlenstoffgehalte im Oberboden zeigt grundsätzlich die niedrigsten Werte (kleiner 2%) im Mittelland. Dabei weisen Ackerlandflächen im Vergleich zu Graslandflächen grundsätzlich geringere Gehalte auf. Gegenüber dem Mittelland sind die Gehalte in den Oberböden im Jura leicht höher und liegen im Mittel zwischen 2% und 3%. Tendenziell weisen die Böden im Bereich der Alpennordflanke, der Zentralalpen und der Alpensüdflanke höhere Gehalte als im Mittelland auf (Abbildung 15b).

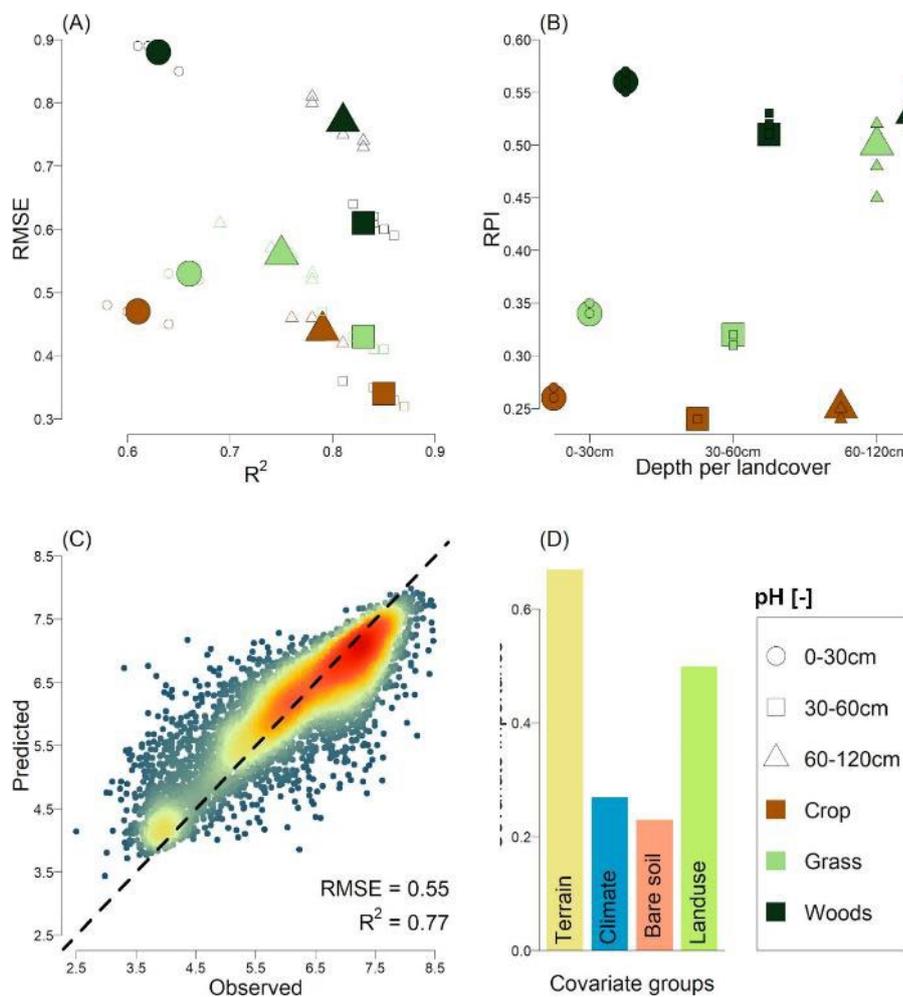


**Abbildung 15b:** Landesweite Hinweiskarte des Kohlenstoffgehalts (SOC) für zwei Tiefenstufen, sowie beispielhaft für einen Ausschnitt aus dem Zürcher Oberland (Prognose und Prognoseunsicherheit RPI).

## pH

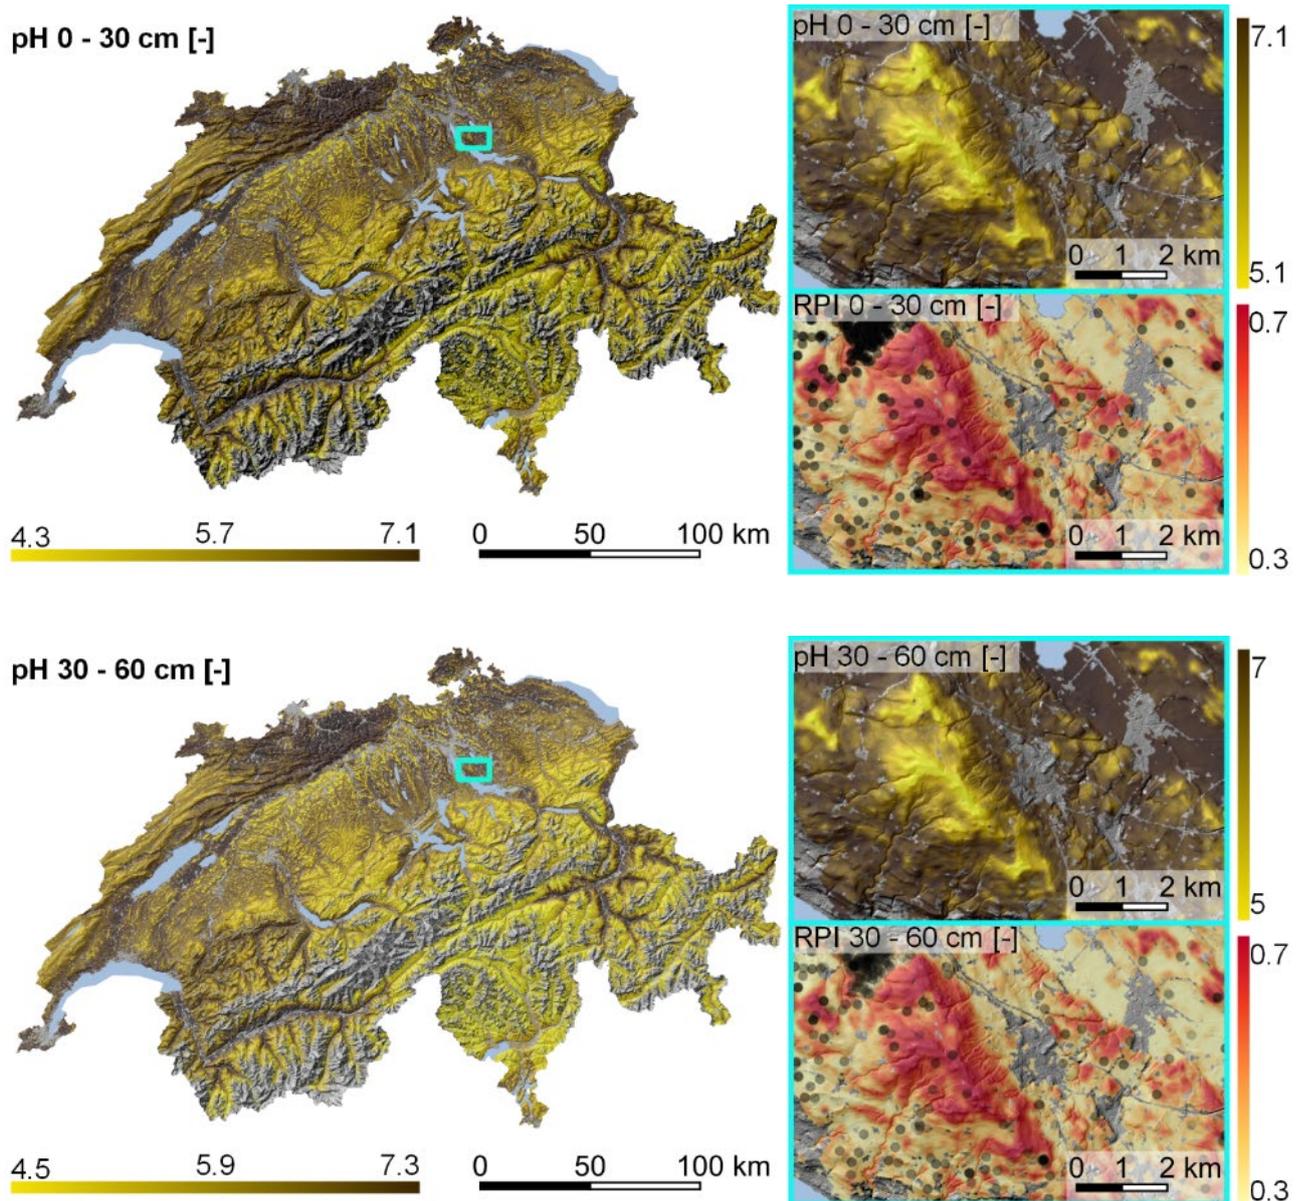
Die Prognosegüte und Prognoseunsicherheit der digitalen Kartierung von Kohlenstoffgehalten über alle Tiefenstufen und Landbedeckungen hinweg zeigt einen  $R^2$  von 0.77, einen RMSE von 0.55 und ein RPI von 0.39. Bezogen auf die Tiefenstufen zeigt das Modell die höchste Prognosegüte für 30-60 cm, gefolgt von 60-120 cm und 0-30 cm. Die Prognoseunsicherheit dagegen ist für 60-120 cm am höchsten, gefolgt von 0-30 cm und 30-60 cm. Bezogen auf die Landbedeckungen sind die Unterschiede in den Prognosegüten anhand der  $R^2$ -Werte marginal. Mittels RMSE weist Ackerland die beste Güte vor Grassland und Wald auf, während die Prognoseunsicherheit diesem Trend folgt. Der Einfluss der Kovariablen zu Terrain und Landnutzung auf die Prognosegüte übertrifft den Einfluss von Kovariablen zu «bare soil» und Klima (Abbildung 16a).

...



**Abbildung 16a:** Modellvalidierung für pH. (A) und (B): Prognosegüte (RMSE;  $R^2$ ) und -unsicherheit (RPI) für separate Tiefenstufen und Landbedeckungen (kleine Symbole markieren Einzelmodellergebnisse, grosse Symbole deren Mittelwert). (C): Heatmap der Prognosen (Predicted) vs. Validierungsdaten (Observed) über alle Tiefenstufen und Landbedeckungen. (D): Einfluss gruppierter Kovariablen auf die Prognose.

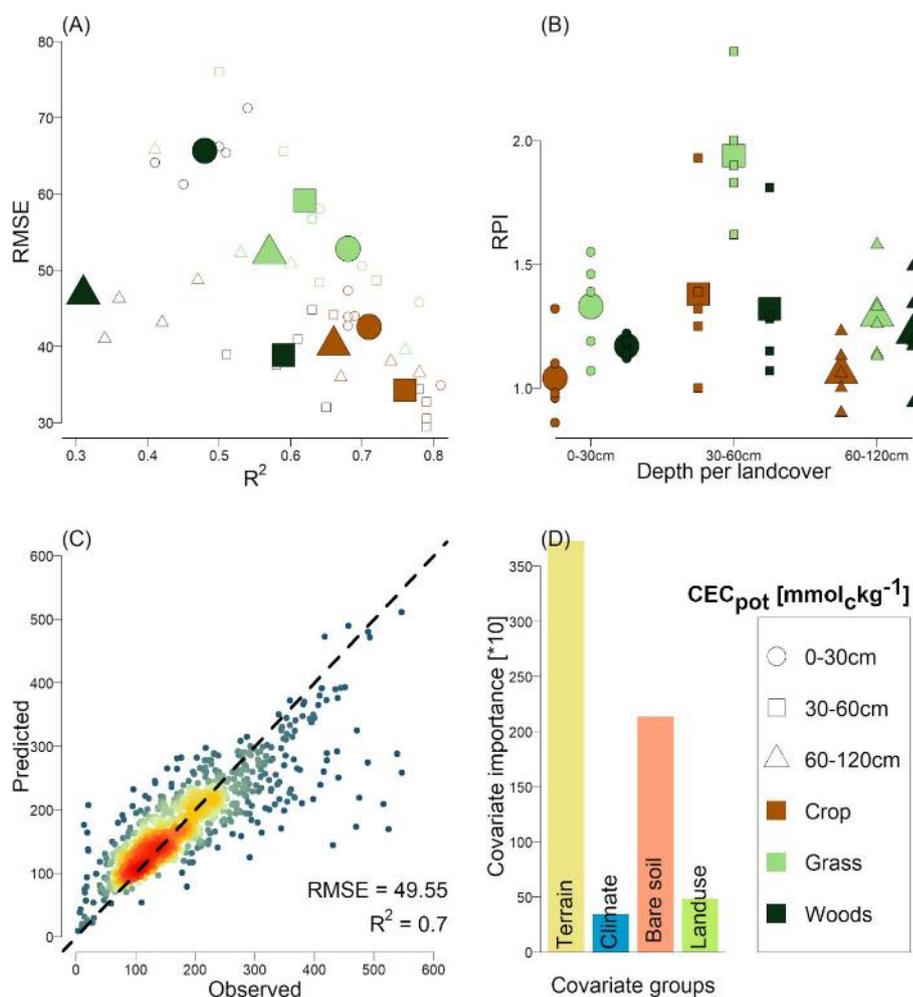
Die räumliche Verteilung der modellierten pH-Werte im Oberboden steht in deutlichem Zusammenhang mit der Landbedeckung. Flächig bewaldete Regionen der Alpensüdflanke, Teile des Mittellandes, sowie die höheren Lagen der Zentralalpen und Alpennordflanke zeigen die geringsten pH-Werte (kleiner 4.5). Im Bereich des westlichen Jura liegen die pH-Werte zwischen 4.5 und 6. Die höchsten (grösser 6) pH-Werte finden sich im westlichen Jura, sowie auf den landwirtschaftlich geprägten Flächen des Mittellandes, der Alpennordflanke und der Zentralalpen (Abbildung 16b).



**Abbildung 16b:** Landesweite Hinweiskarte des pH für zwei Tiefenstufen, sowie beispielhaft für einen Ausschnitt aus dem Zürcher Oberland (Prognose und Prognoseunsicherheit RPI).

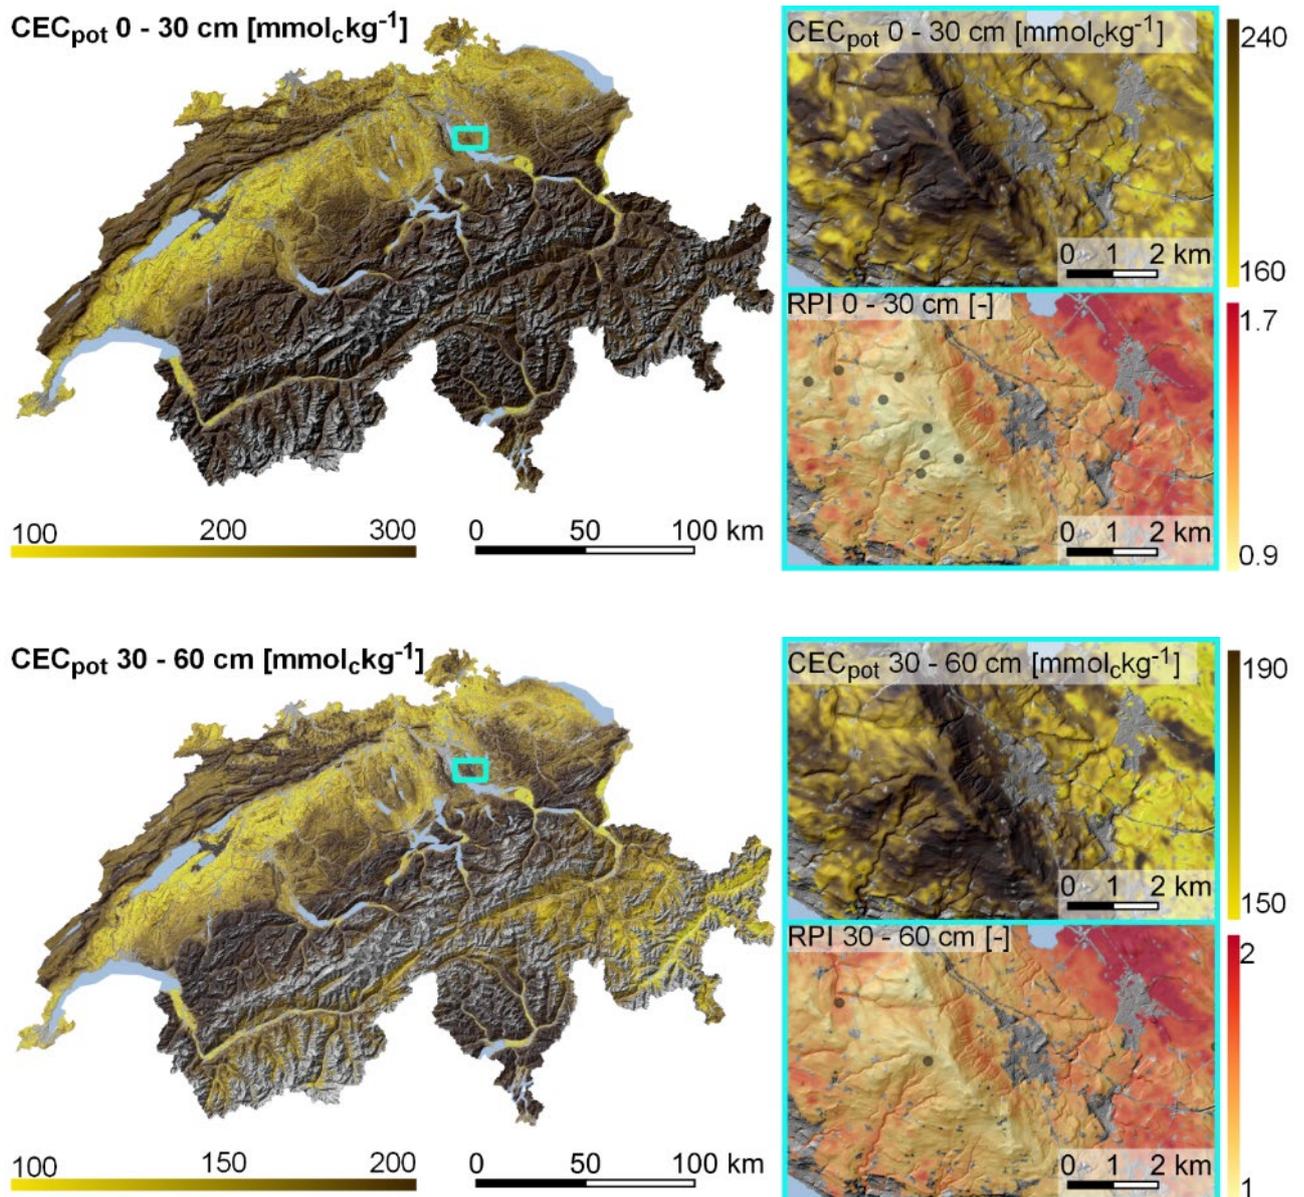
## Potenzielle Kationenaustauschkapazität ( $CEC_{pot}$ )

Prognosegüte und -unsicherheit der digitalen Kartierung von potenzieller Kationenaustauschkapazität über alle Tiefenstufen und Landbedeckungen hinweg zeigt einen  $R^2$  von 0.7, einen RMSE von 49.55 und ein RPI von 1.31. Bezogen auf die Tiefenstufen und mittels  $R^2$ -Werten erreicht das Modell die höchste Prognosegüte für 0-30 cm, gefolgt von 30-60 cm und 60-120 cm. Der RMSE zeigt die höchste Prognosegüte im Bereich 30-60 cm, während 0-30 cm die geringste Güte aufweist. Die Prognoseunsicherheit ist für 0-30 cm und 60-120 cm am geringsten. Bezogen auf die Landbedeckung zeigt das Modell die höchste Prognosegüte auf Ackerland, gefolgt von Grasland und Wald. Die Prognoseunsicherheit dagegen ist für Grasland am höchsten. Der Einfluss von Kovariablen zu Terrain und «bare soil» auf die Prognosegüte übertrifft den Einfluss von Landnutzungs- und Klima-Kovariablen (Abbildung 17a).



**Abbildung 17a:** Modellvalidierung für die potenzielle Kationenaustauschkapazität ( $CEC_{pot}$ ). (A) und (B): Prognosegüte (RMSE;  $R^2$ ) und -unsicherheit (RPI) für separate Tiefenstufen und Landbedeckungen (kleine Symbole markieren Einzelmodellergebnisse, grosse Symbole deren Mittelwert). (C): Heatmap der Prognosen (Predicted) vs. Validierungsdaten (Observed) über alle Tiefenstufen und Landbedeckungen. (D): Einfluss gruppiertter Kovariablen auf die Prognose.

Die räumliche Verteilung der modellierten potenziellen Kationenaustauschkapazität im Oberboden zeigt die niedrigsten Werte (kleiner  $200 \text{ mmol}_c\text{kg}^{-1}$ ) auf intensiv landwirtschaftlich geprägten Flächen des Mittellandes und der grösseren Alpentäler im Süden. Im Jura und den Grünlandflächen der Alpennordflanke betragen die Werte zwischen  $200 \text{ mmol}_c\text{kg}^{-1}$  und  $250 \text{ mmol}_c\text{kg}^{-1}$ . Die höchsten Werte finden sich in den Hochlagen der Alpennordflanke, der Zentralalpen und der Alpensüdflanke. (Abbildung 17b).



**Abbildung 17b:** Landesweite Hinweiskarte der potenziellen Kationenaustauschkapazität ( $\text{CEC}_{\text{pot}}$ ) für zwei Tiefenstufen, sowie beispielhaft für einen Ausschnitt aus dem Zürcher Oberland (Prognose und Prognoseunsicherheit RPI).

## 4 Einordnung der Ergebnisse

### *Prognosegüten im internationalen Vergleich*

Auf globaler und regionaler Ebene wurden in den vergangenen drei Dekaden zunehmend Methoden der digitalen Bodenkartierung angewendet, um flächendeckende, aktualisierbare und interpretierbare Bodeninformation bereitzustellen. Chen et al. (2022) haben in einer internationalen Übersichtsstudie 244 Einzelstudien zu digitalen Bodenkartierungen großflächiger Gebiete (grösser 10000 km<sup>2</sup>) zwischen 2003 und 2021 analysiert. Gemäss den Ergebnissen dieser Übersichtsstudie, liegen die Prognosegüten der vorliegenden Studie für alle Bodeneigenschaften im oberen Bereich. Im Vergleich zum Median der Prognosegüten der 244 Einzelstudien liegt die Prognosegüte für die SOC Hinweiskarte in der gleichen Größenordnung, jedoch für die weiteren Hinweiskarten für Bodeneigenschaften wesentlich höher (Tabelle 5).

*Tabelle 5: Vergleich der Prognosegüten zwischen dieser Studie (R<sup>2</sup> - Schweiz) und dem Median globaler sowie großflächiger (> 10000 km<sup>2</sup>) Einzelstudien der Jahre 2003 bis 2021 (R<sup>2</sup> – Median globaler Einzelstudien) für die Tiefenstufe 0-30 cm (siehe Chen et al., 2022).*

Bodeneigenschaft	R <sup>2</sup> - Schweiz	R <sup>2</sup> - Median globaler Einzelstudien	Veränderung
Ton	0.69	0.50	+28%
Schluff	0.65	0.50	+23%
Sand	0.75	0.50	+33%
SOC	0.50	0.49	+2%
pH	0.70	0.60	+14%
CEC <sub>pot</sub>	0.71	0.37	+45%

### *Beprobungsdichte versus Prognosegüte*

Die räumliche Dichte der Beprobungsstandorte ist über die Fläche der Schweiz hinweg und für alle analysierten Bodeneigenschaften sehr heterogen. Während die Beprobungsdichte für pH mit durchschnittlich 0.55 pro km<sup>2</sup> am höchsten ist, weisen Textureigenschaften (Ton-, Schluff- und Sandgehalt) und Kohlenstoffgehalt (SOC) Beprobungsdichten zwischen 0.25 und 0.35 pro km<sup>2</sup> auf. Die geringste Beprobungsdichte liegt für die potenzielle Kationenaustauschkapazität mit 0.06 pro km<sup>2</sup> vor. Für alle Bodeneigenschaften sind die Beprobungsdichten für das Ackerland am höchsten, während Grasland und Waldflächen im Schnitt nur ein Fünftel der Beprobungsdichte des Ackerlandes aufweisen (Tabelle 1). Zudem ist die räumliche Dichte der Beprobungsstandorte für das Mittelland und Teile des nördlichen Jura relativ hoch, während das südliche Jura, die Alpennordflanke, Zentralalpen und Alpensüdflanke eine deutlich geringere Beprobungsdichte aufweisen (Abbildungen 1 bis 6).

Die Prognosegüten der digitalen Bodenkartierung sind im Rahmen der heterogenen räumlichen Beprobungsdichte zu interpretieren. Je höher die Beprobungsdichte, desto höher ist die Prognosegüte. Dies spiegelt sich in den Ergebnissen der vorliegenden Studie wider, indem Prognosegüten generell mit zunehmender Beprobungsdichte von Waldflächen, Grasland zu Ackerland steigen, sowie für die Bodentiefe 60-120 cm bzw. 0-30 cm zur Bodentiefe 30-60 cm (Abbildungen 12a bis 17a).

### ***Gründigkeit und organische Böden***

In vielen Regionen der Schweiz, vorwiegend im Jura, an der Alpennordflanke, in den Zentralalpen und an der Alpensüdflanke sind die Böden häufig geringmächtiger als 120 cm. Die vorliegende Version der digitalen Kartierung mit den drei Tiefenstufen 0-30 cm, 30-60 cm und 60-120 cm kann die tatsächliche Gründigkeit der Böden mangels detaillierter Datenlage (noch) nicht abbilden. Die Anwendung der Hinweiskarten ist daher insbesondere für Regionen mit flachgründigen Böden limitiert. Dieser Aspekt sollte bei der Interpretation der Hinweiskarten, vor allem für die Tiefenstufe 60-120 cm, berücksichtigt werden.

Weiterhin wird im Rahmen der digitalen Bodenkartierung zu Kohlenstoffgehalten keine Unterscheidung zwischen mineralischen und organischen Böden vorgenommen. Die Prognosemodelle beschränken sich in der jetzigen Version auf mineralische Böden, da die Beprobungsdichte für organische Böden überproportional gering ist. Das hat zur Folge, dass die Prognosegüte auf organischen Böden im Vergleich zu mineralischen Böden deutlich vermindert ist, wenngleich die räumliche Variation der Kohlenstoffgehalte plausibel beschrieben wird. Schätzungsweise beträgt der flächenmässige Anteil an organischen Böden in der Schweiz weniger als 5% (Wüst-Galley et al. 2015).

### ***Ausblick***

Im Einklang mit fortlaufenden Aktualisierungen des NABODAT-Datensatzes, sowie Aktualisierungen und Weiterentwicklungen der flächendeckenden Umweltvariablen sollen zukünftig die Hinweiskarten für Bodeneigenschaften aktualisiert werden. Zudem sollen in der kommenden Version weitere methodische Entwicklungen in Bezug zu den oben genannten Aspekten wie die Gründigkeit der Böden und der bessere Einbezug der organischen Böden adressiert werden. In weiteren Versionen soll so die räumliche Interpretierbarkeit der Hinweiskarten für Bodeneigenschaften verbessert werden.

## 5 Bereitstellung der Rasterkarten

Die landesweiten Hinweiskarten können zur Unterstützung der Konzeptphase und Feldarbeiten in kantonalen Bodenkartierungen dienen, werden aber oftmals für nationale und regionale Forschungsprojekte nachgefragt. Die Berechnung und Lieferung der Hinweiskarten erfolgt für die Nutzer:innen auf **Stufe Gemeinde, oder Kanton oder für die gesamte Schweiz**.

Die Datenlieferung erfolgt in einem zip-Dokument. In diesem befinden sich in einem Unterordner jeweils pro Bodeneigenschaft die Karten pro Tiefenstufe, und jeweils pro Tiefenstufe eine Karte mit den Prognosewerten und zusätzlich eine Karte mit der Unsicherheit der Prognosen (RPI: «Relative Prediction Interval» siehe Seite 21). Pro Bodeneigenschaft resultieren somit 6 Karten, beispielsweise für den Tongehalt (Clay) lauten die Dateinamen wie folgt:

Soil_clay_0_30_cm.tif	Tongehalt 0-30 cm
Soil_clay_0_30_cm_uncertainty.tif	Prognoseunsicherheit für diese Tiefe
Soil_clay_30_60_cm.tif	Tongehalt 30-60 cm
Soil_clay_30_60_cm_uncertainty.tif	Prognoseunsicherheit für diese Tiefe
Soil_clay_60_120_cm.tif	Tongehalt 60-120 cm
Soil_clay_60_120_cm_uncertainty.tif	Prognoseunsicherheit für diese Tiefe

Anfragen für diesen Service sind über das online-Formular auf der KOBO-Webseite zu stellen. Nach Bearbeitung der Anfrage werden dem Nutzer die Daten per Link als Download zur Verfügung gestellt. Ihr Feedback ist für uns sehr wichtig. So können wir Ihre Anregungen aufnehmen und die Hinweiskarten für Bodeneigenschaften stets weiterentwickeln. Teilen Sie uns daher gerne Ihre Erfahrungen und Verbesserungswünsche mit. Nutzen Sie hierfür folgenden Kontakt: [service@ccsols.ch](mailto:service@ccsols.ch).

## 6 Literatur

- Agroscope, 2023. Swiss reference methods of the research institutes Agroscope. <https://www.agroscope.admin.ch/agroscope/en/home.html>. (Accessed April 2023).
- BDM, 2023. Biodiversitätsmonitoring Schweiz. <https://biodiversitymonitoring.ch/index.php/de/>.
- Behrens T., Schmidt K., MacMillan R.A., Viscarra Rossel R.A., 2017. Multiscale contextual spatial modelling with the Gaussian scale space. *Geoderma*, 310, 128–137.
- Behrens T., Schmidt K., MacMillan R.A., Viscarra Rossel R.A., 2018. Multi-scale digital soil mapping with deep learning. *Scientific reports*, 8 (1), 15244.
- Behrens T., Schmidt K., Zhu A.X., Scholten T., 2010: The ConMap approach for terrain-based digital soil mapping. *European Journal of Soil Science* 61, 133-143.
- Behrens T., Viscarra Rossel R. A., Kerry R., MacMillan R.A., Schmidt K., Lee J., Scholten T., Zhu A.-X., 2019: The relevant range of scales for multi-scale contextual spatial modelling. *Scientific Reports* 9: 14800.
- Behrens T., Viscarra Rossel R.A., 2020. On the interpretability of predictors in spatial data science: the information horizon. *Scientific Reports*, 10 (1), 16737.
- Bishop T.F.A., McBratney A.B., Laslett G.M., 1999. Modelling soil attribute depth functions with equal-area quadratic smoothing splines. *Geoderma* 91, 27-45.
- Breiman L., 2001. Random Forests. *Machine Learning* 45, 5-32.
- Brevik EC., 2013: The potential impact of climate change on soil properties and processes and corresponding influence on food security. *Agriculture* 3, 398-417.
- Chen S., Arrouays D., Mulder V.L., Poggio L., Minasny B., Roudier P., Libohova Z., Lagacherie P., Shi Z., Hannam J., Meersmans J., Richer-de-Forges A.C., Walter C., 2022: Digital mapping of GlobalSoilMap soil properties at broad scale: A review. *Geoderma* 409, 115567.
- De Vries FT., Thebault E., Liiri M., Birkhofer K., et al., 2013 : Soil food web properties explain ecosystem services across European land use systems. *PNAS* 35, 14296-14301.
- Demattê J.A.M., Fongaro C.T., Rizzo R., Silvero N.E.Q., Safanelli J.L., 2018. Geospatial Soil Sensing System (GEOS3): A powerful data mining procedure to retrieve soil spectral reflectance from satellite images. *Remote Sensing of Environment* 212, 161-175.
- Dokuchaev V.V., 1883. Russian chernozem. In: *Selected Works of V.V. Dokuchaev, Volume 1*. Moscow, 1948 (ed. S. Monson), pp. 14– 419. Israel Program for Scientific Translations Ltd. (for USDA-NSF), Jerusalem, Israel.
- ESA, 2023: European Space Agency: Sentinel- 2. [https://www.esa.int/Applications/Observing\\_the\\_Earth/Copernicus/Sentinel-2](https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2).
- Frei C., 2014: Interpolation of temperature in a mountainous region using non-linear profiles and Euclidean distances. *International Journal of Climatology* 34, 1585-1605.
- Frei C., Schöll R., Fukutome S., Schmidli J., Vidale P., 2006: Future change of precipitation extremes in Europe – Intercomparison of scenarios from regional climate tools. *Journal of Geophysical Research* 111, D6.
- Frei C., Willi M., Stöckli R., Dürr B., 2015. Spatial analysis of sunshine duration in complex terrain by non-contemporaneous combination of station and satellite data. *International Journal of Climatology* 35, 4471-4790.
- García M.J.L., Caselles V., 1991. Mapping burns and natural reforestation using thematic Mapper data. *Geocarto International* 6, 31-37.

- Gee G.W., Bauder J., Klute A., 1986. Methods of soil analysis, part 1, physical and mineralogical methods. Soil Science Society of America Book Series, Inc. Madison, Wisconsin, 404-410.
- Gray J.M., Bishop T.F.A., Wilford J.R., 2016. Lithology and soil relationships for soil modelling and mapping. *Catena* 147, 429-440.
- Gregorutti B., Michel B., Saint-Pierre P., 2015. Grouped variable importance with random forests and application to multiple functional data analysis. *Computational Statistics & Data Analysis* 90, 15-35.
- Gubler A., Wächter D., Schwab P., 2018. Homogenisierung von Bodenkohlenstoff-Daten: Harmonisierung der Resultate aus Nassoxidation (FAL-Methode) und Trockenveraschung. *Agroscope Science* 62, 2018.
- Guisan, A., Weiss, S.B., Weiss, A.D., 1999: GLM versus CCA spatial modelling of plant species distribution. *Plant Ecology* 143, 107-122.
- Haghighi F., Gorji M., Shorafa M., 2010: A study of the effects of land use changes on soil physical properties and organic matter. *Land degradation and development* 21, 496-502.
- Jenny H., 1941. Factors of soil formation. McGraw-Hill, N.Y. & London.
- Keller A., Franzen J., Knüsel P., Papritz A., Zürrer M. 2018: Bodeninformations-Plattform Schweiz (BIP-CH). Thematische Synthese TS4 des Nationalen Forschungsprogramms «Nachhaltige Nutzung der Ressource Boden» (nfp 68), Bern. S. 124. <http://www.nfp68.ch/de/news-medien/publikationen>
- Kiss R., 2004. Determination of drainage network in digital elevation model, utilities and limitations *Journal of Hungarian Geomathematics*, vol.2, p.16-29.
- Knecht M., Lüscher C., Borer F. 2017. Bedürfnisabklärungen Bodeninformationen. Zuhanden Bundesamt für Umwelt BAFU. Ambio GmbH, Zürich.
- Loiseau T., Richer-de-Forges A.C., Martelet G., Bialkowski A., Nehlig P., Arrouays D., 2020. Could airborne gamma-spectrometric data replace lithological maps as covariate for digital soil mapping of topsoil particle-size distribution? A case study in Western France. *Geoderma Regional* 22, 200295.
- Lüscher C. 2004. Leitfaden Bodenkartierung Bodendaten – ein Werkzeug für Planung,
- McBratney A.B., Mendonça-Santos M.L., Minasny B., 2003. On digital soil mapping. *Geoderma* 117, 3–52.
- Meinshausen N., 2006. Quantile Regression Forests. *Journal of Machine Learning Research* 7, 983-999.
- Meteoswiss, 2023. Bundesamt für Meteorologie und Klimatologie, Schweiz: Räumliche Klimaanalysen. <https://www.meteoschweiz.admin.ch/home/klima/schweizer-klima-im-detail/raeumliche-klimaanalysen.html>.
- NABODAT, 2023. Nationales Bodeninformationssystem, Schweiz. <https://nabodat.ch/index.php/de/>.
- Poggio L., Gimona A., 2017. 3D Mapping of soil texture in Scotland. *Geoderma Regional* 9, 5-16.
- Pribyl D.W., 2010. A critical review of the conventional SOC to SOM conversion factor. *Geoderma* 156, 75-83.
- Quinn P.F., Beven K.J., Chevallier P., Planchon O., 1991. The prediction of hillslope flow paths for distributed hydrological modelling using digital terrain models. *Hydrological Processes* 5, 59–79.

- Rehbein K., Ch. Sprecher, A. Keller. 2019. Übersicht Stand Bodenkartierung in der Schweiz – Ergänzung des Bodenkartierungskataloges Schweiz um Bodeninformationen aus Meliorationsprojekten, Agroscope, Servicestelle NABODAT, Zürich.
- Riley, S.J., DeGloria, S.D., Elliot, R., 1999. A terrain ruggedness index that quantifies topographic heterogeneity. *Intermountain Journal of Sciences* 5, 23-27.
- Rouse J.W., Haas R.H., Schell J.A., Deering D.W., 1974: Monitoring vegetation systems in the Great Plains with ERTS. Third ERTS-Symposium, Washington D.C. 1973.
- Sen, P.K., 1968: Estimates of the regression coefficient based on Kendall's Tau. *Journal of the American Statistical Association* 63, 1379-1389.
- Swisstopo, 2023. Bundesamt für Landestopografie, Schweiz: Das topographische Landschaftsmodell TLM. <https://www.swisstopo.admin.ch/de/wissen-fakten/topografisches-landschaftsmodell.html>.
- USGS, 2023: U.S. Geological Survey: Landsat Data Products. <https://www.usgs.gov/core-science-systems/nli/landsat/landsat-collection-2-level-2-science-products>.
- Vökt U., Pazeller A. (2002): Bodeneignungskarte der Schweiz 1:200 000 – Qualität und Aussagekraft der Archivdokumente. BGS (Hrsg.).
- Wilson M.F.J, O'Connell B., Brown C., Guinan J.C., Grehan A.J., 2007. Multiscale terrain analysis of multibeam bathymetry data for habitat mapping on the continental slope. *Marine Geodesy* 30, 3–35.
- Wu, D., Wu H., Zhao, X., Zhou, T., Tang, B., Zhao, W., Jia, K., 2014: Evaluation of spatiotemporal variations of global fractional vegetation cover based on GIMMS NDVI data from 1982 to 2011. *Remote Sensing* 6, 4217-4239.
- Wüst-Galley C., A. Grünig, J. Leifeld. 2015. Locating Organic Soils for the Swiss Greenhouse Gas Inventory. *Agroscope Science No. 26 / 2015*.
- Zevenbergen L.W., Thorne C.R., 1987: Quantitative analysis of land surface topography. *Earth Surface Processes Landforms* 12, 47-56.
- Žížala D., Minařík R., Skála J., Beitlerová, H., Juřicová A., Reyes Rojas J., Penížek V., Zádorová T., 2022. High-resolution agriculture soil property maps from digital soil mapping methods, Czech Republic. *Catena* 212, 106024.