

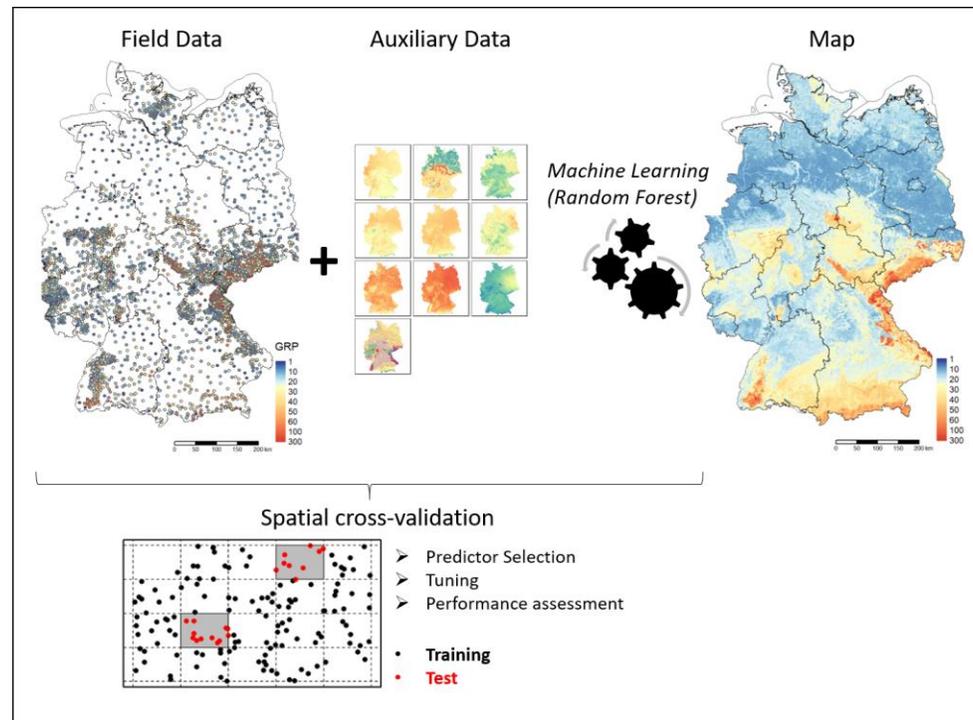


Radonkarten – Radonprognosen – Modellierung und Geostatistik

Dr. Eric Petermann

Hessisches Radonseminar

10.3.2022, virtuell





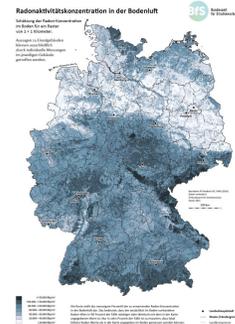
1. Hintergrund

- Warum Radonkarten?
- Stand der Dinge



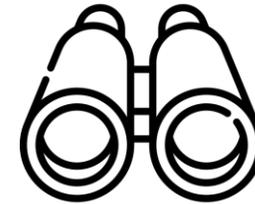
2. Kartierung

- Von der Messung zur Karte
- Interpolation, Geostatistik, Machine Learning & co



3. Radon-Karten

- Rn im Boden
- Was steckt drin?
- Interpretation



4. Ausblick

- Geogenes Radonpotenzial
- Radon in Gebäuden
- Europa



5. Fazit



1. Hintergrund

- Warum Radonkarten?
- Stand der Dinge



2. Kartierung

- Von der Messung zur Karte
- Interpolation, Geostatistik, Machine Learning & co



3. Radon-Karten

- Rn im Boden
- Was steckt drin?
- Interpretation



4. Ausblick

- Geogenes Radonpotenzial
- Radon in Gebäuden
- Europa



5. Fazit

Hintergrund

Warum Karten?

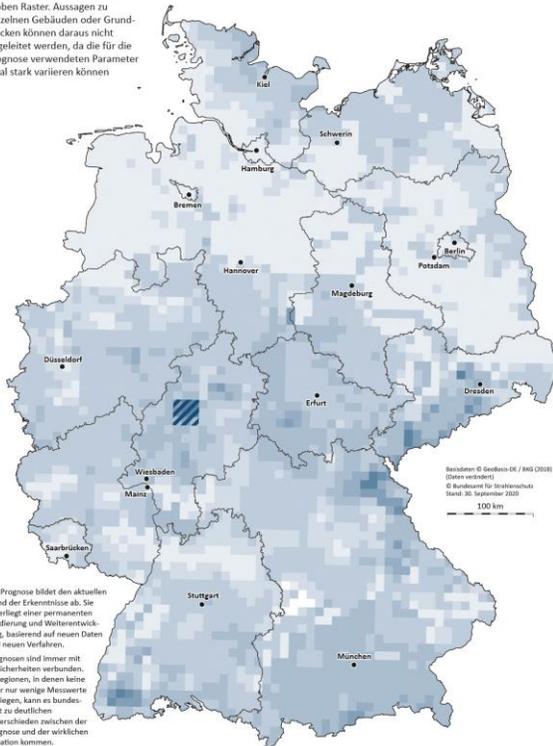
- Thematische Karten dienen der Quantifizierung und Visualisierung der räumlichen Verteilung eines Merkmals
- Entscheidungsfindung: Ausweisung von Radon-Vorsorgegebieten
- Information/Risikowahrnehmung/Sensibilisierung der Bevölkerung
- Bewertung: Räumliche Verteilung von Gesundheitsgefährdung, Abschätzung sanierungsbedürftiger Gebäude



Stand des Wissens – Rn-Karten BfS

Prognose des Radonpotenzials in Deutschland

Die Karte zeigt die regional zu erwartende Situation in einem groben Raster. Aussagen zu einzelnen Gebäuden oder Grundstücken können daraus nicht abgeleitet werden, da die für die Prognose verwendeten Parameter lokal stark variieren können.



Reaktionen © GeoBasis-DE / BfS (2018) (Daten verändert)
© Bundesamt für Strahlenschutz
Stand: 30. September 2020
100 km

Die Prognose bildet den aktuellen Stand der Erkenntnisse ab. Sie unterliegt einer permanenten Validierung und Weiterentwicklung, basierend auf neuen Daten und neuen Verfahren.

Prognosen sind immer mit Unsicherheiten verbunden. In Regionen, in denen keine oder nur wenige Messwerte vorliegen, kann es bundesweit zu deutlichen Unterschieden zwischen der Prognose und der wirklichen Situation kommen.

In den schraffierten Flächen weichen die Ergebnisse der Prognose nach Erkenntnissen des BfS offensichtlich von den lokalen Erfahrungswerten ab. Hier bedarf es einer gesonderten Validierung.

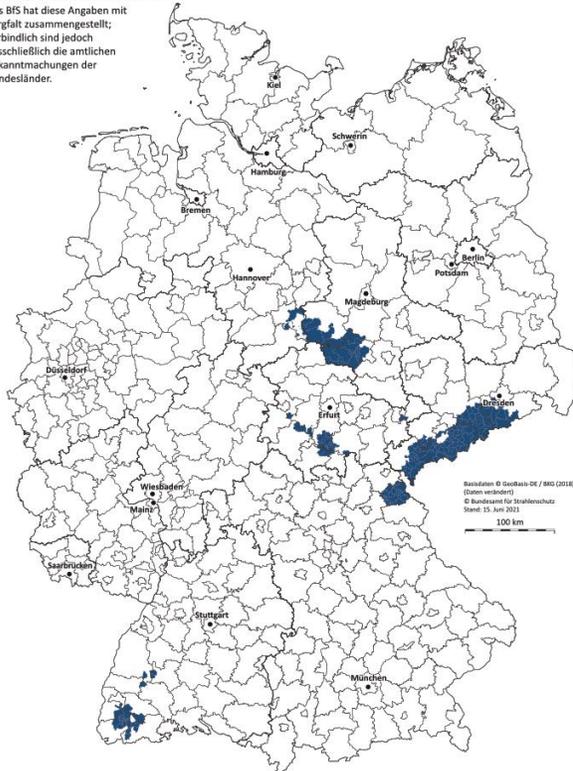


Geogenes Rn-Potenzial

Radon-Vorsorgegebiete

Die Karte bildet den Stand der Gebietsausweisungen der einzelnen Bundesländer vom 15. Juni 2021 ab.

Das BfS hat diese Angaben mit Sorgfalt zusammengestellt; verbindlich sind jedoch ausschließlich die amtlichen Bekanntmachungen der Bundesländer.



Reaktionen © GeoBasis-DE / BfS (2018) (Daten verändert)
© Bundesamt für Strahlenschutz
Stand: 15. Juni 2021
100 km

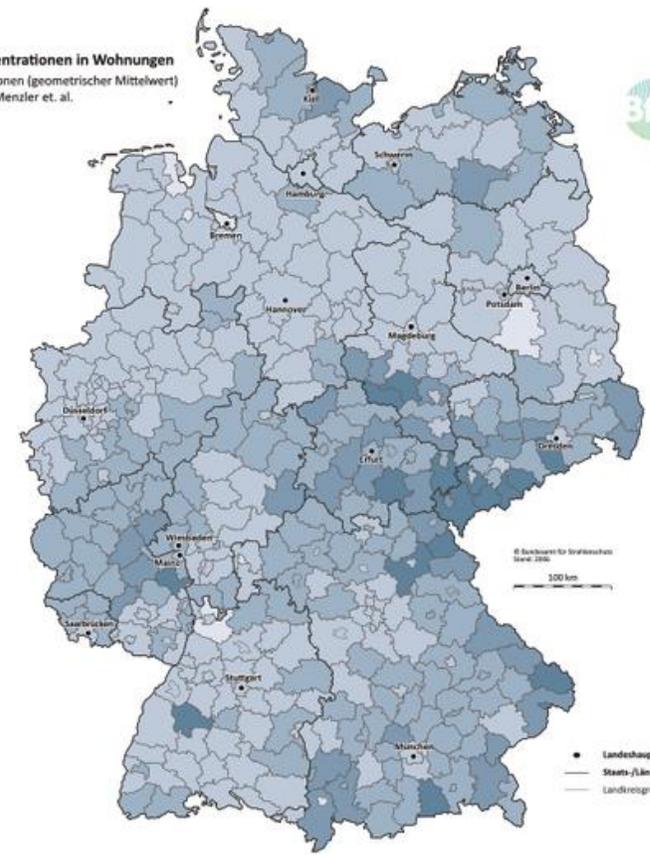


Rn-Vorsorgegebiete

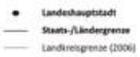
Durchschnittliche Radon-Konzentrationen in Wohnungen

Durchschnittliche Radon-Konzentrationen (geometrischer Mittelwert) in Wohnungen in Deutschland nach Menzler et. al.

Angaben zu Einzelgebäuden sind ausschließlich durch individuelle Messungen im jeweiligen Gebäude getroffen.



Reaktionen © Bundesamt für Strahlenschutz
Stand: 2016
100 km



Durchschnittl. Rn-Konzentration in Wohnungen



1. Hintergrund

- Warum Radonkarten?
- Stand der Dinge



2. Kartierung

- Von der Messung zur Karte
- Interpolation, Geostatistik, Machine Learning & co



3. Radon-Karten

- Rn im Boden
- Was steckt drin?
- Interpretation

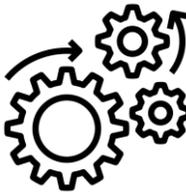


4. Ausblick

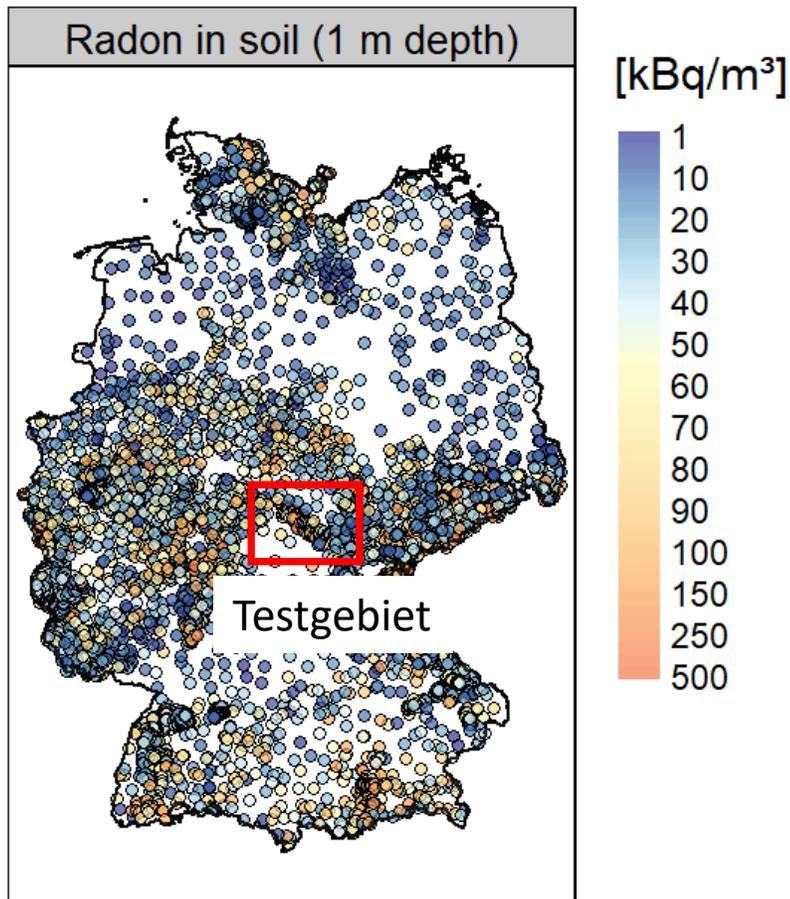
- Geogenes Radonpotenzial
- Radon in Gebäuden
- Europa



5. Fazit



Von der Messung zur Karte



Ausgangslage

- Rund 6.300 Bodenluftmessungen, > 50.000 Innenraummessungen
- Punktmessungen an unterschiedlichen Orten
- Räumliche Cluster; unterschiedliche Messpunktdichte

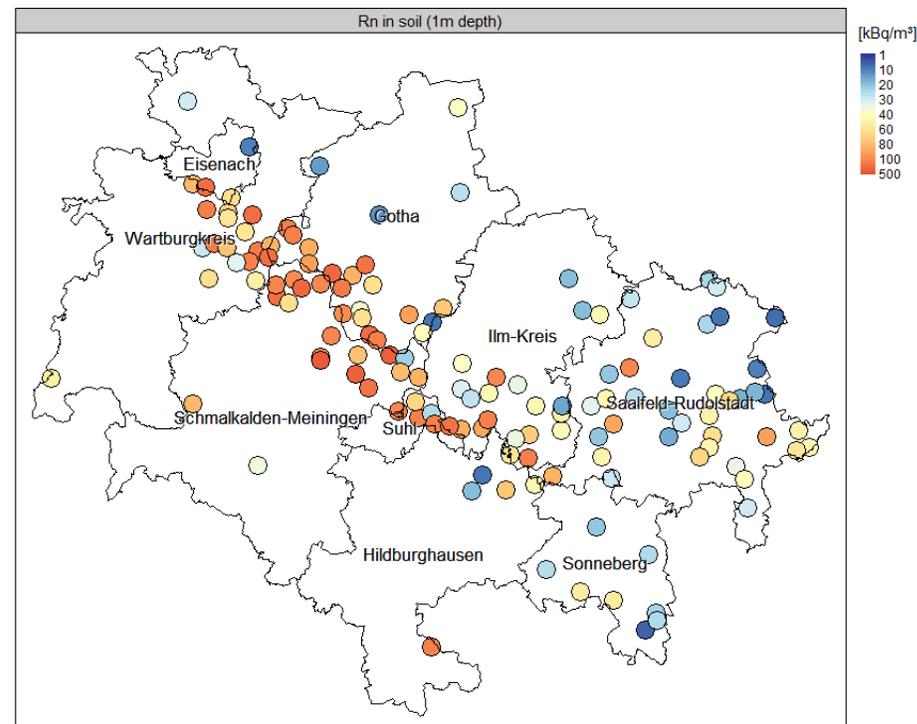
Ziel

- Darstellung **statist. Kenngrößen** (arithm. + geometrischer Mittelwert, Median, Perzentile) innerhalb von **Raumeinheiten** (Gitterzellen, Landkreisgrenzen, Gemeindegrenzen etc.)

Methoden

- Aggregation: für Verwaltungseinheiten, Gitterzellen etc.
- Einfache Interpolation (nearest neighbour, inverse distance)
- Geostatistik
- Regressionsmodelle (u.a. Machine Learning)

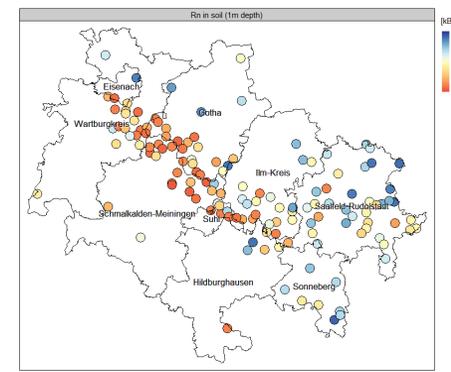
Von der Messung zur Karte – ein Beispiel: Thüringer Wald



- 9 Landkreise in und um den Thüringer Wald
- ungleiche Messpunktdichte

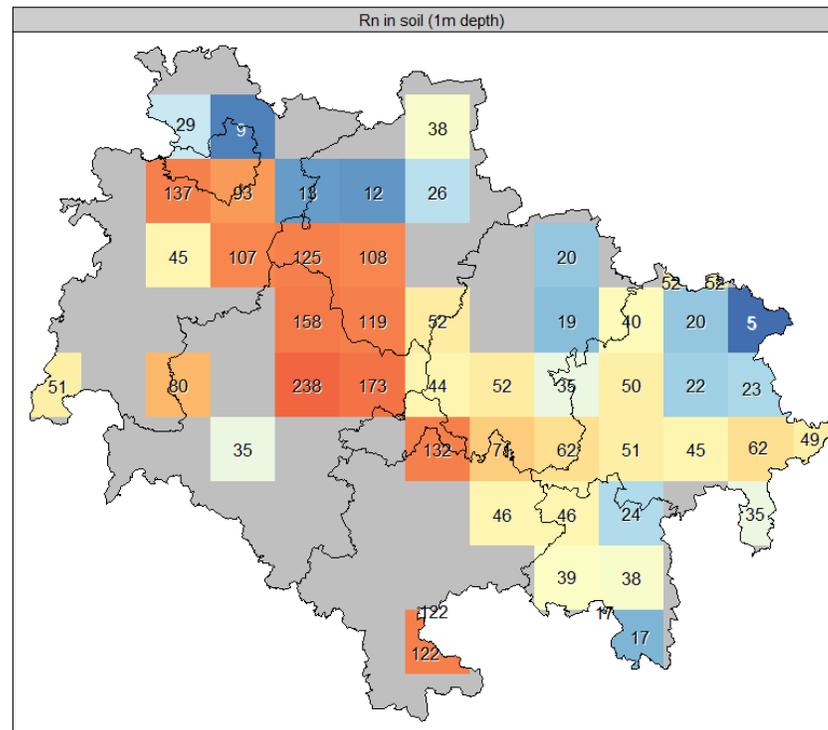
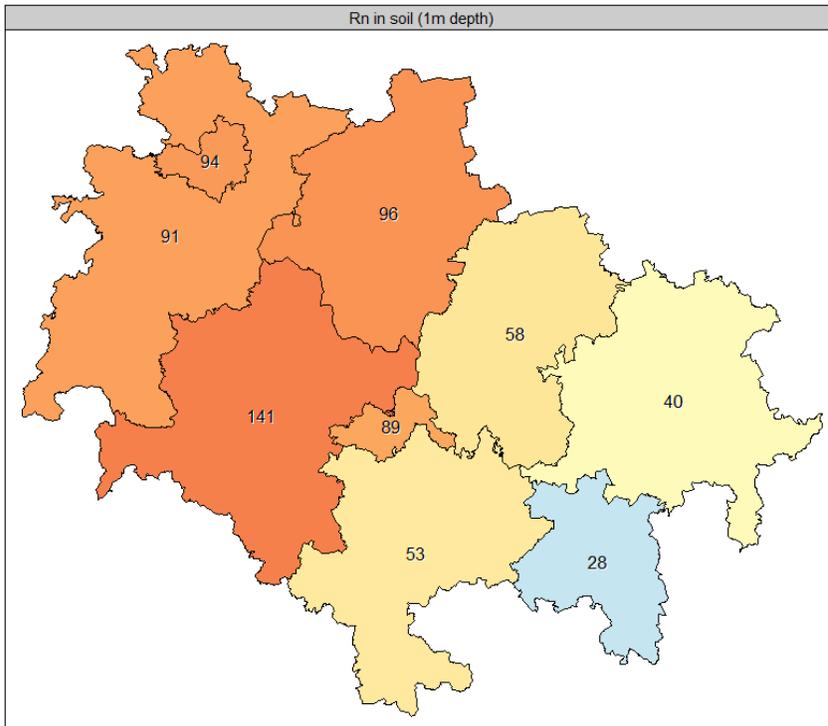


Von der Messung zur Karte - Aggregation

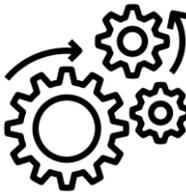


nach Landkreisen

10km-Gitterzellen

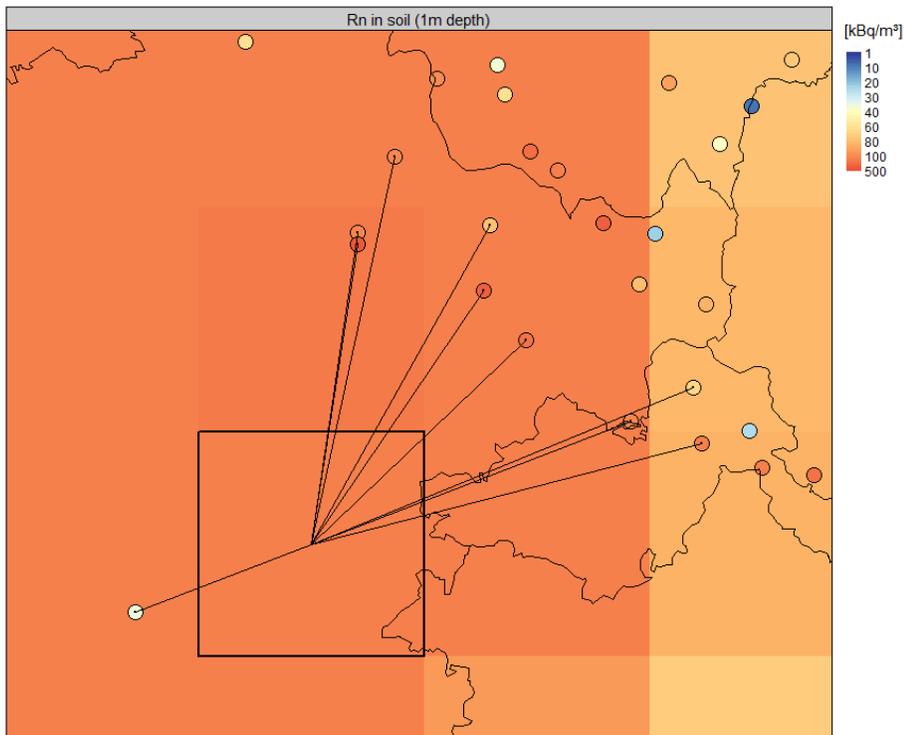


- ✓ sehr einfach umzusetzen
- ✓ intuitiv zu verstehen
- ✗ Genauigkeit stark abhängig von Messpunktdichte und -verteilung (Repräsentativität)
- ✗ Abhängig von Geometrie der Einheiten
- ✗ Keine Berücksichtigung von Messungen außerhalb der Aggregationseinheiten
- ✗ Kein Wert bei fehlenden Messungen



Von der Messung zur Karte – Interpolation (abstandsgewichtet)

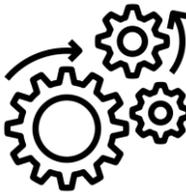
Inverse Distance Weighting



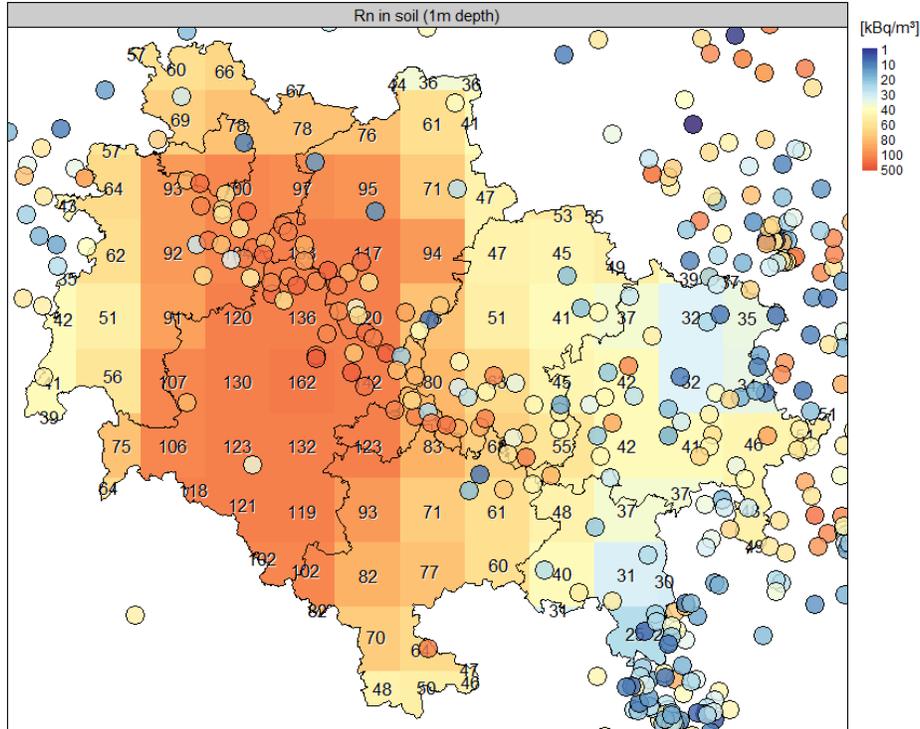
- nearest neighbours=10
- inverse distance power=1

„Everything is related to everything else, but near things are more related than distant things.“
– Waldo Tobler (1. Gesetz der Geographie)

- Berücksichtigung von Messungen außerhalb der Einheiten
- Prognosen für Orte ohne Messungen möglich unter Ausnutzung der räumlichen Autokorrelation (Tobler)
- kein explizites geostatistisches Modell
- optimale Anzahl der Nachbarn fallabhängig (Tuningparameter)

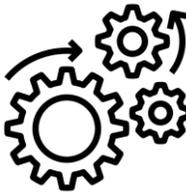


Von der Messung zur Karte – Interpolation (abstandsgewichtet)

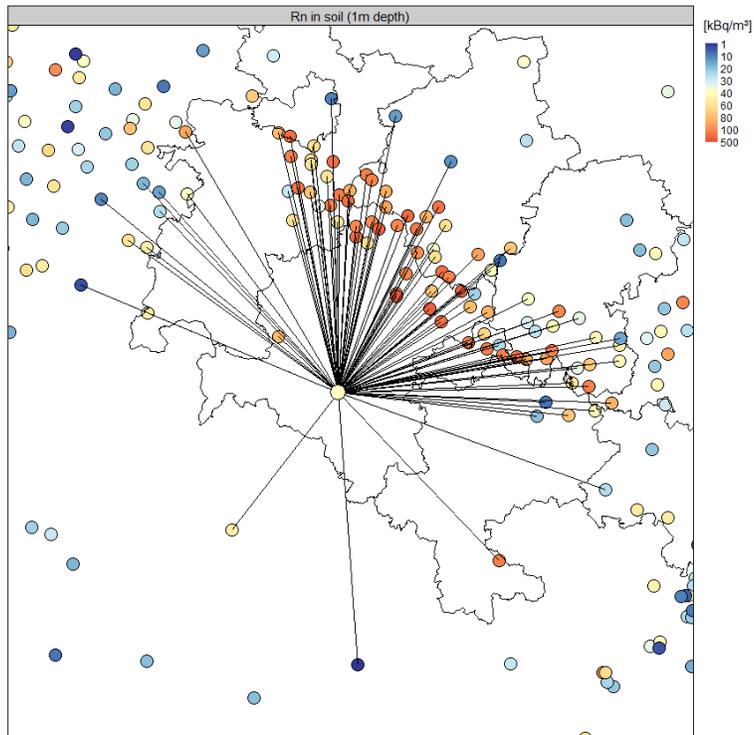


- nearest neighbours=10
- inverse distance power=1

- ✓ intuitiv zu verstehen und leicht zu implementieren
- ✗ für Größen mit geringer räumlicher Autokorrelation unterkomplex
- ✗ keine Berücksichtigung von Naturraumeigenschaften (Geologie etc.)
- ✗ Genauigkeit stark abhängig von Messpunktdichte und –verteilung (Repräsentativität)

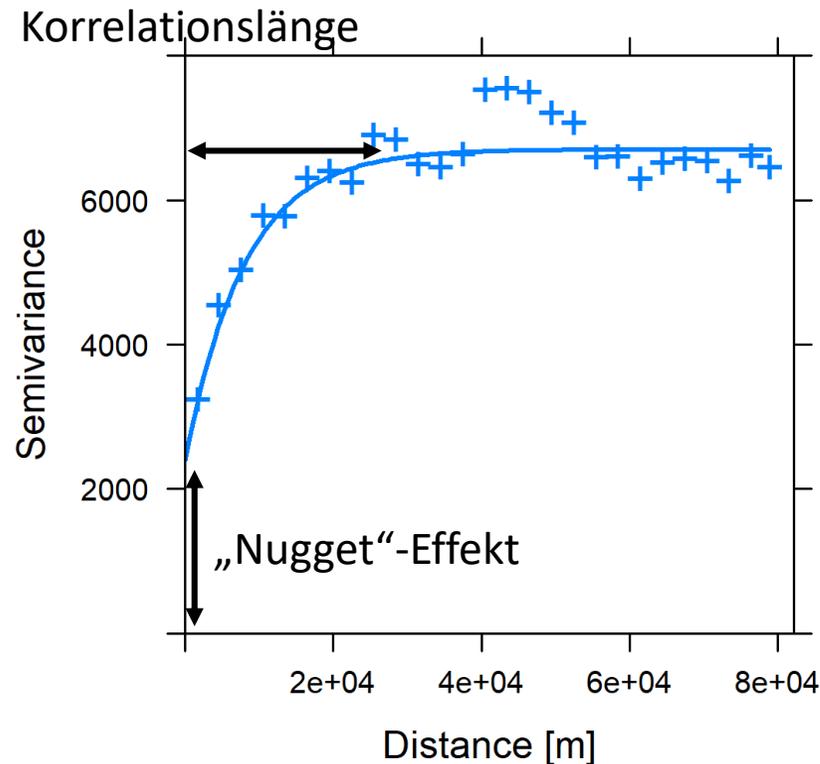


Von der Messung zur Karte - Geostatistik



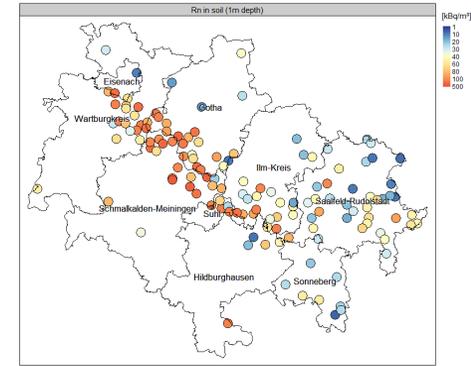
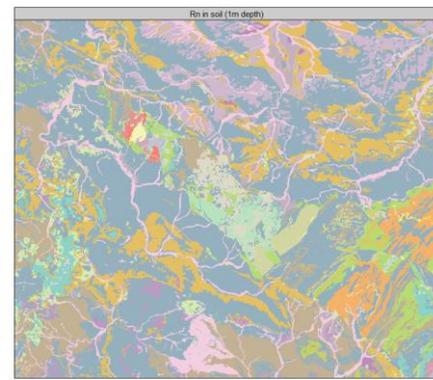
Beziehungen zu Messungen in ~ 50 km Entfernung

Radon in soil (1 m depth)

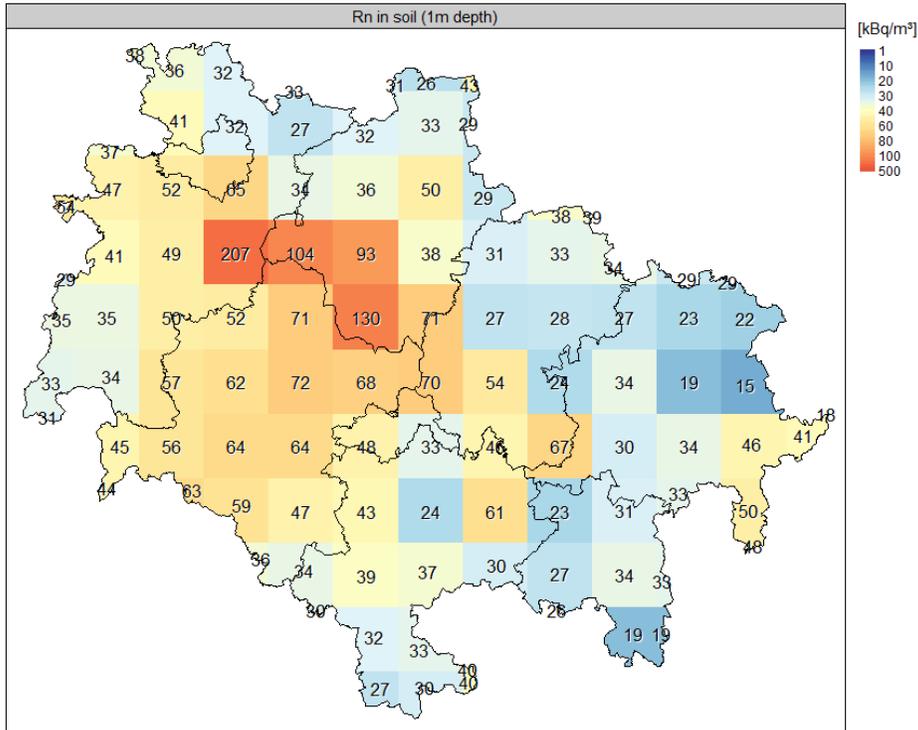


- Erstellung eines Variogramms
-> Varianz in Abhängigkeit von der Entfernung
- Bildung von Punktpaaren; Darstellung der mittleren Varianz
- Nugget-Effekt: Maß für Rauschen, kleinräumige Variabilität die nicht erklärt werden kann
- Korrelationslänge: Distanz über die ein Messwert noch für Prognosen an unbekanntem Ort verwendet werden kann

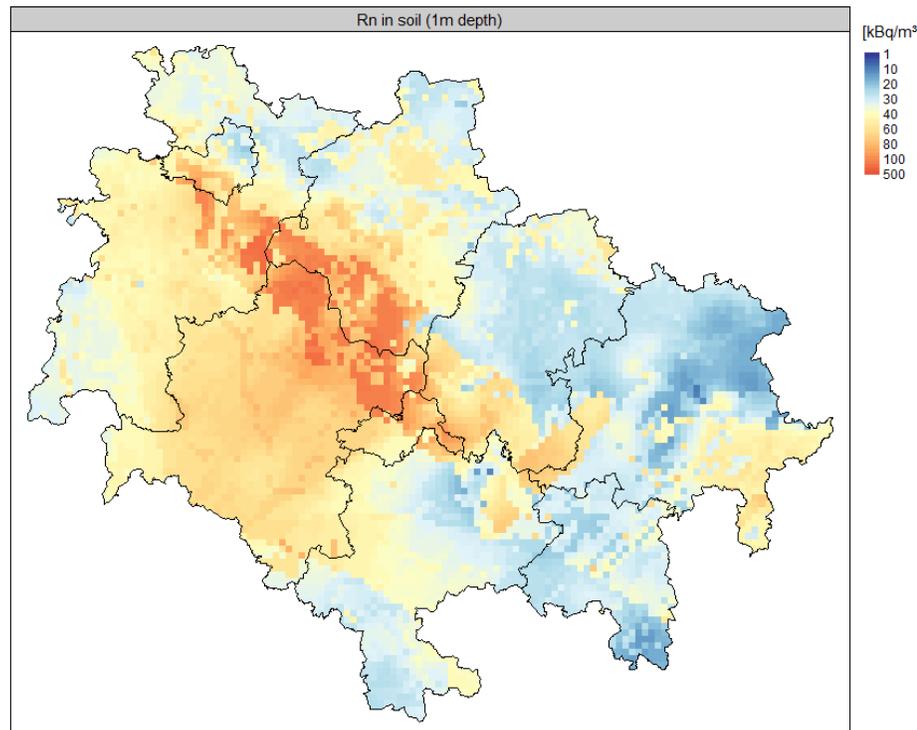
Von der Messung zur Karte – Geostatistik II



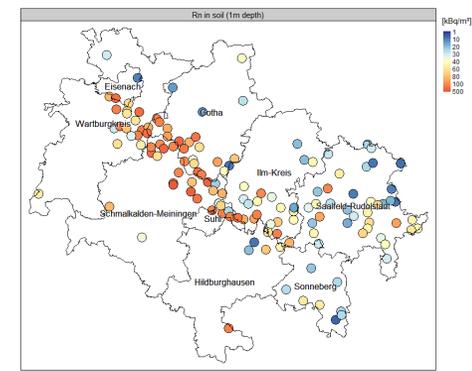
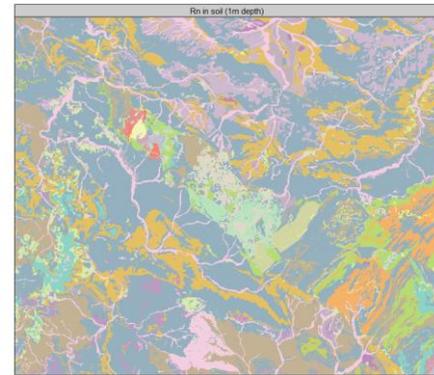
Kriging 10 km



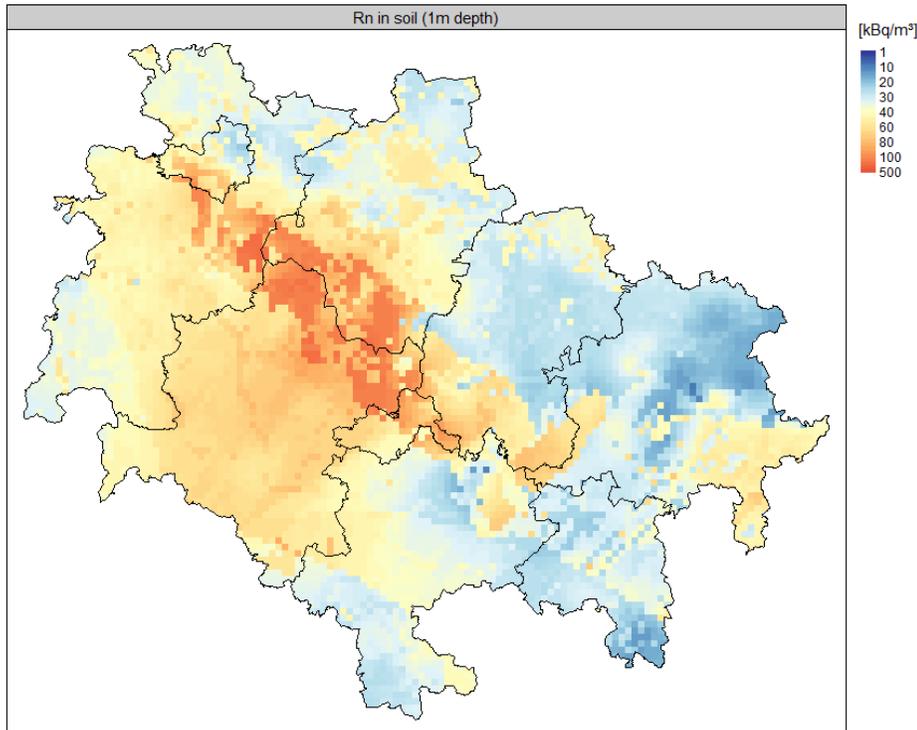
Kriging 1 km



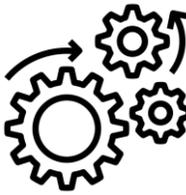
Von der Messung zur Karte – Geostatistik II



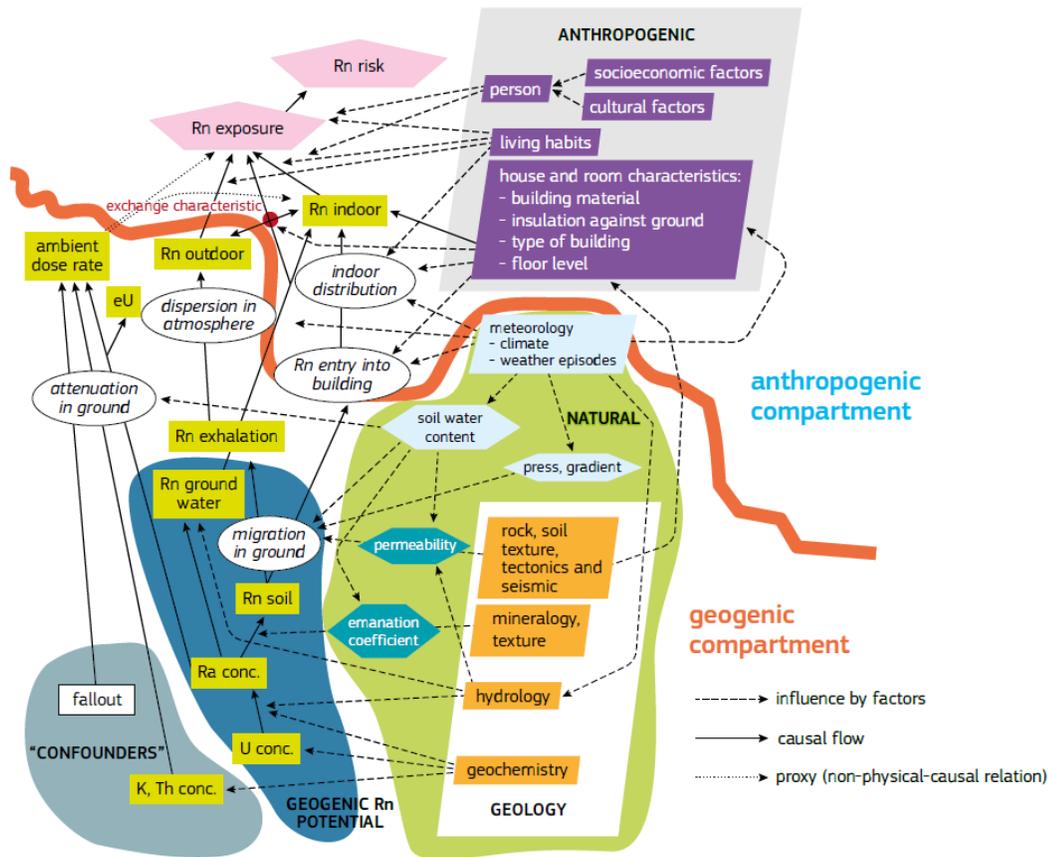
Kriging 1 km



- ✓ Berücksichtigung von Co-Variablen (Geologie)
- ✓ Explizites geostatistisches Modell für Prognose
- ✗ Implementierung weiterer Naturraumeigenschaften aufwändig
- ✓ ✗ betrachtet Messwerte als Realität (-> problematisch bei hoher Charakterisierungsunsicherheit von Einzelmessungen in Kombination mit geringer Messpunktdichte)



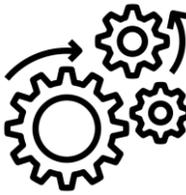
Von der Messung zur Karte – Machine Learning: Motivation



Herausforderung bei der Radonkartierung

- Sehr komplexes System
- Zusammenspiel verschiedener Faktoren
- Messungen (Boden) stellen nicht notwendigerweise Langzeitmittelwert dar -> zeitliche Variabilität (Witterung -> Störsignale)
- Einzelne Extremwerte (Witterung, Messfehler etc.) können in der Karte Einfluss in großen Gebieten haben
- ML kann zahlreiche Co-Variablen als Prädiktoren nutzen und komplexen Zusammenspiel Rechnung tragen
- ML geeignet für die Modellierung nicht-linearer Systeme

Cinelli et al (2019): European atlas of natural radiation



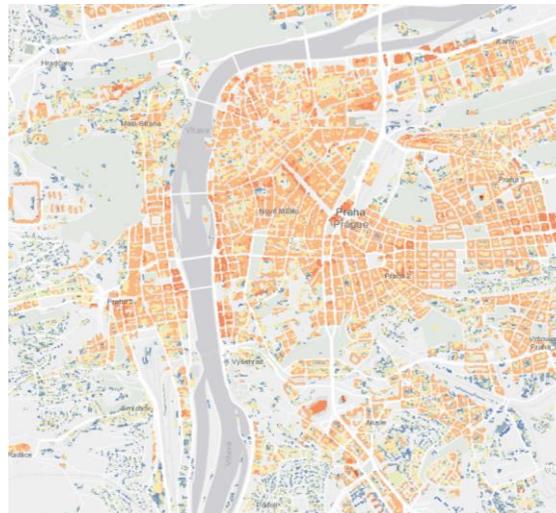
Von der Messung zur Karte – Machine Learning: Motivation II



https://www.esa.int/Space_in_Member_States/Germany/Die_Copernicus-Dienste

- Datenverfügbarkeit
 - Satellitenmissionen (NASA, ESA -> copernicus)
 - frei zugängliche Datensätze (national bis weltweit)
 - Citizen science
- **Nützlich für Erklärung/Modellierung von Radon (geogen und Innenraum)**

Gebäudehöhe->
Geschosszahl



<https://land.copernicus.eu/local/urban-atlas/building-height-2012?tab=mapview>

Safecast-> Monitoring Radioaktivität



<https://map.safecast.org/?y=50.0963&x=14.4014&z=14&l=1&m=0>

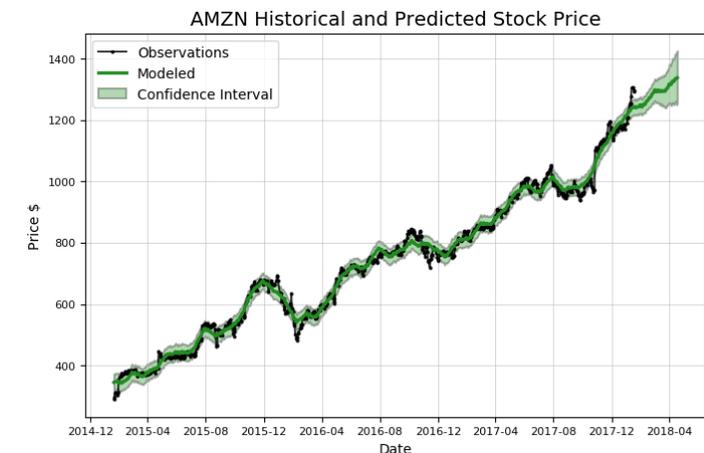
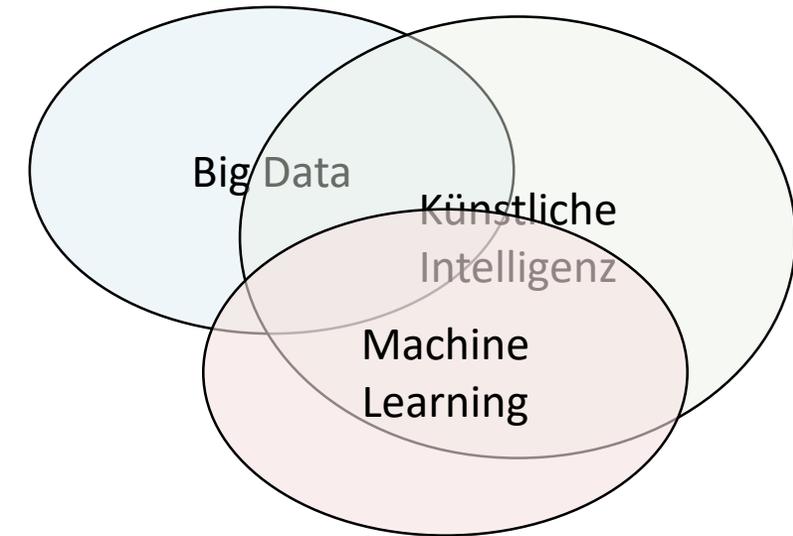


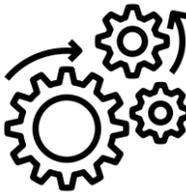
European Soil Database & soil properties

<https://esdac.jrc.ec.europa.eu/resource-type/european-soil-database-soil-properties>

Was Machine Learning?

- Machine Learning ist Baustein von Künstlicher Intelligenz
 - Algorithmen die anhand von Beispielen lernen und die Zusammenhänge nach Beendigung des Lernprozesses verallgemeinern können
 - Erkennen von Mustern und Gesetzmäßigkeiten mit Hilfe statistischer Verfahren
 - können aus Daten oftmals mehr Information extrahieren als einfachere statist. Modelle
-
- Geeignet für hochkomplexe Systeme, Verarbeitung großer Datenmengen
 - Regression + Klassifikation
 - Beispiele: Sprach- und Texterkennung, Kreditkartenbetrug, Aktienmarktanalysen, Industrie 4.0 (z.B. autonome Fahrzeuge), predictive marketing (Google, Spotify etc.)



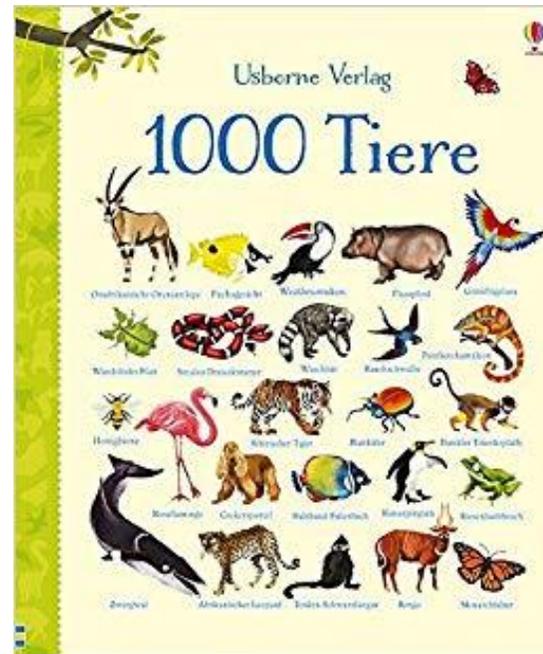


Von der Messung zur Karte – Machine Learning

Training



Test

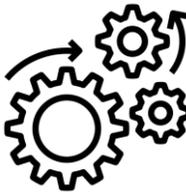


© Usborne Verlag; <https://www.amazon.de/1000-Tiere-Jessica-Greenwell/dp/1782321179>

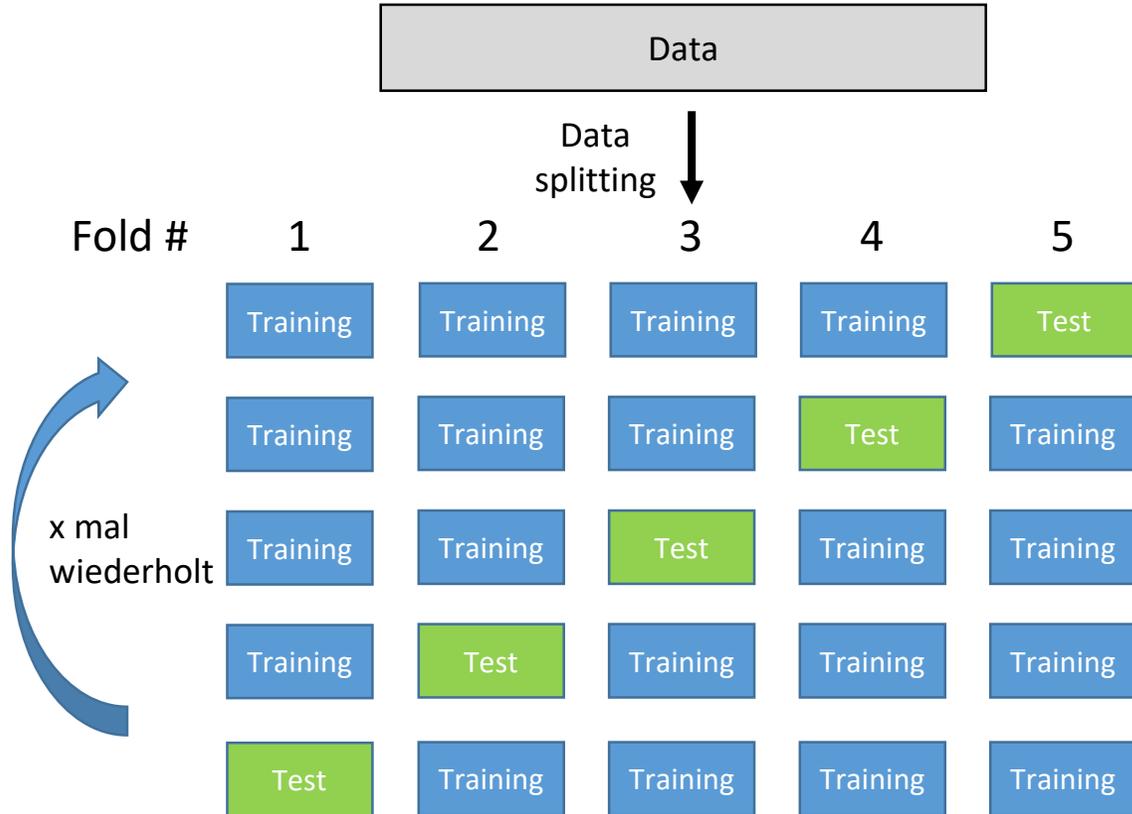
Grundprinzip überwachtetes Lernen

Beispiel: Wie lernen Kleinkinder Tiere zu unterscheiden?

- Zuordnung von Eigenschaften/Merkmalen (Form, Farbe, Proportionen) → Herstellen von Zusammenhängen
 - Gefahr der Überanpassung aufgrund der hohen Flexibilität (Fehlinterpretation von Zusammenhängen, z.B. Blickrichtung, relative Position zueinander)
- Testdaten notwendig um zu überprüfen, ob verallgemeinert werden kann oder ob nur auswendig gelernt wurde
- Klassifikation/Regression



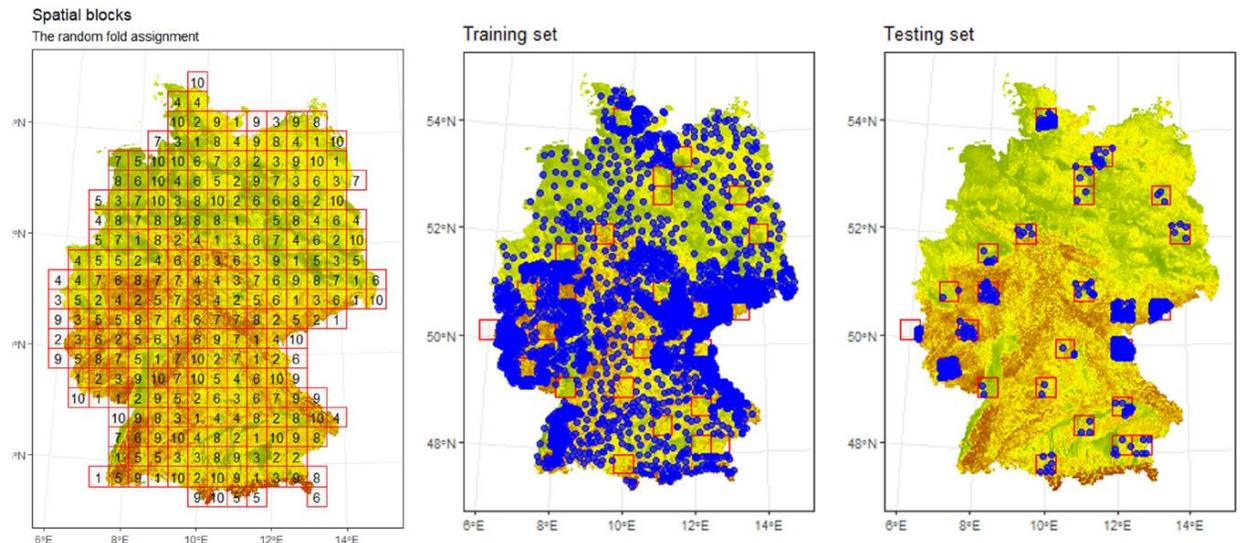
Modelbildung – Kreuzvalidierung



Voraussetzung: Unabhängigkeit von Trainings- und Testdaten

Problem: Räumliche Autokorrelation

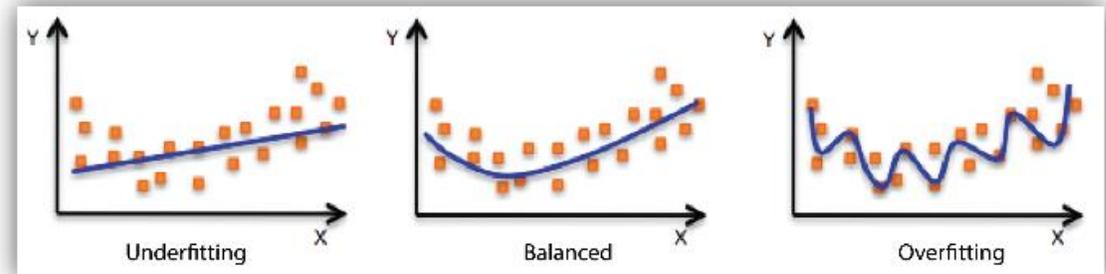
Lösung: Aufteilung in Trainings- und Testdaten mittels räumlichen Blöcken



- Roberts et al (2017), Ecography.
- Meyer et al. (2019), Ecological Modelling.

Modelbildung – Auswahl der Prädiktoren

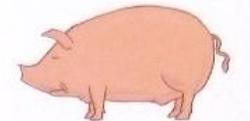
- Viele Kandidaten; $n > 100$
- nicht alle hilfreich für Prognose
- hoher Rechenaufwand
- Auswahl relevanter Prädiktoren
 - Prinzip der Sparsamkeit
 - Vermeidung *overfitting*
- Ziel: Finden der besten Prädiktorenkombination (Kriterium Testperformance)



<https://docs.aws.amazon.com/machine-learning/latest/dg/model-fit-underfitting-vs-overfitting.html>



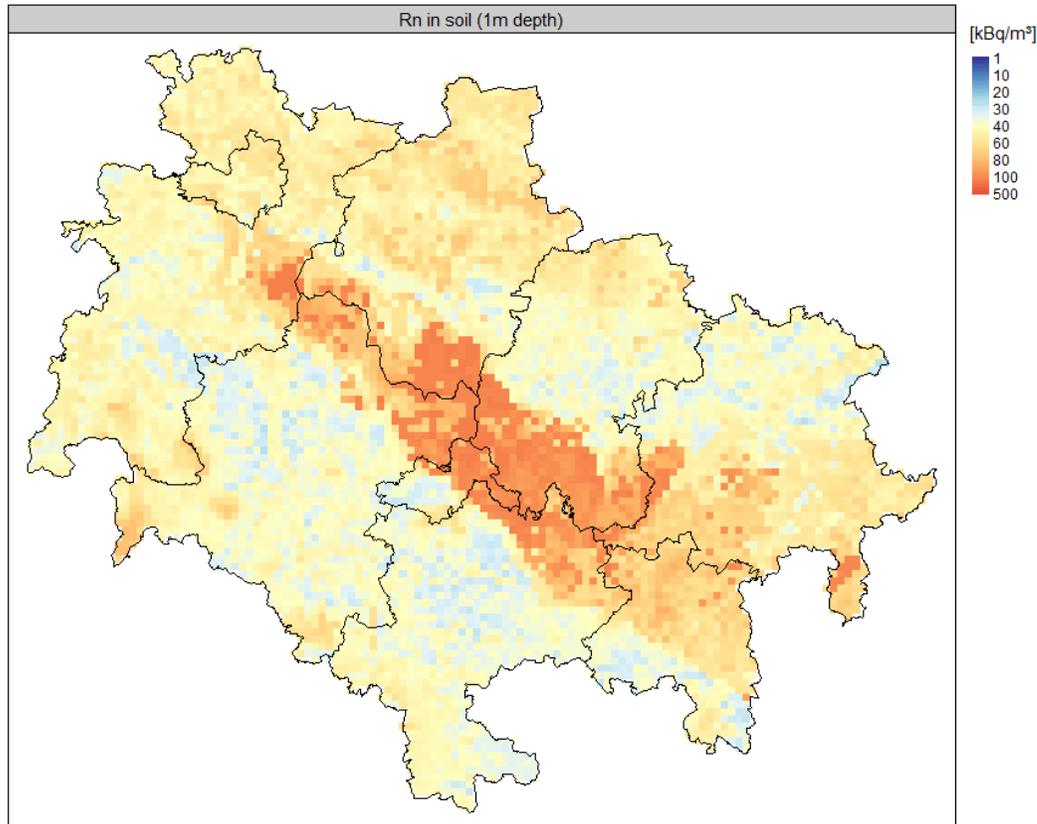
z.B., Blickrichtung



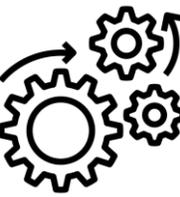
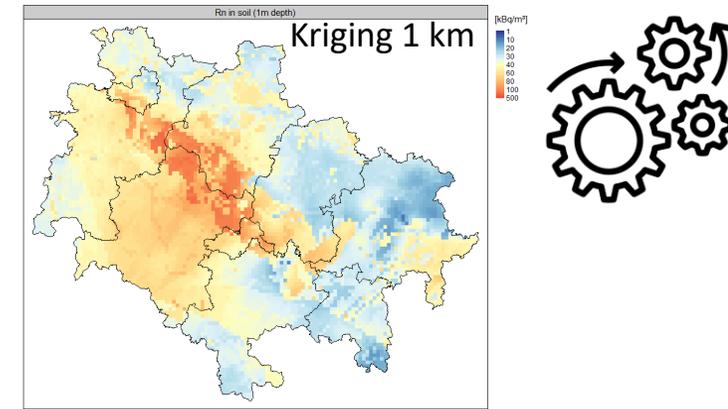
das Schwein

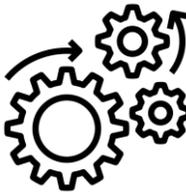
Von der Messung zur Karte – Machine Learning

Machine Learning (Random Forest)



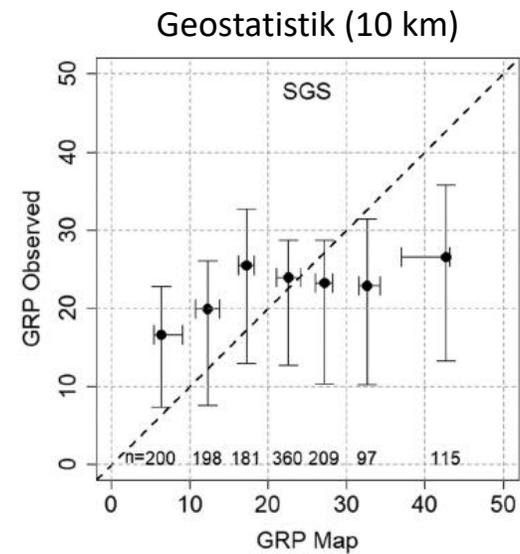
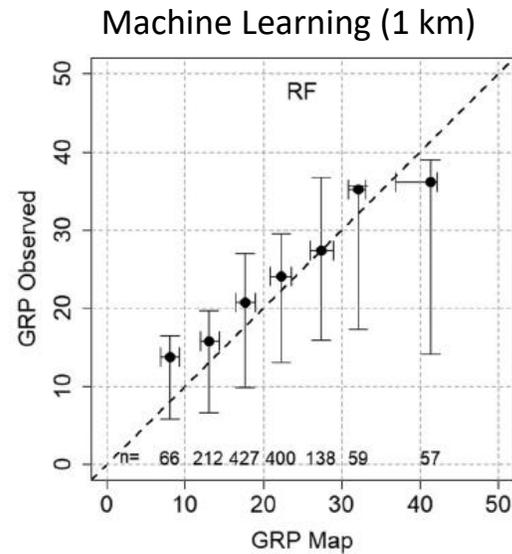
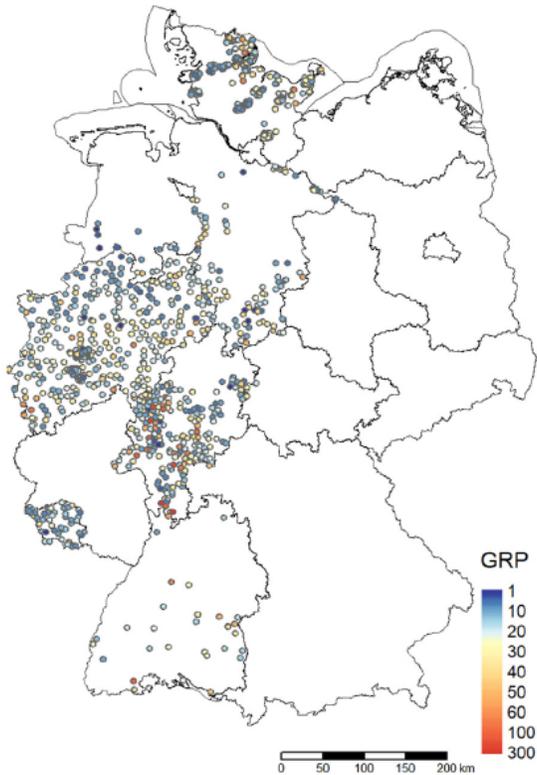
- ✓ Berücksichtigung einer Vielzahl von Naturraumeigenschaften
- ✓ Einfluss von Einzelmessungen verringert
- ✗ nur Informationen die in Prädiktoren steckt, erscheint letztlich in der Karte (Messwerte dienen der Kalibrierung und Wichtung der Prädiktoren)



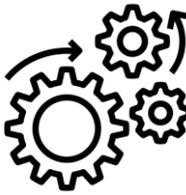


Von der Messung zur Karte – Machine Learning

- Testdaten: neue Messungen der Länder bis 2020
- deutlich bessere Prognose durch machine learning

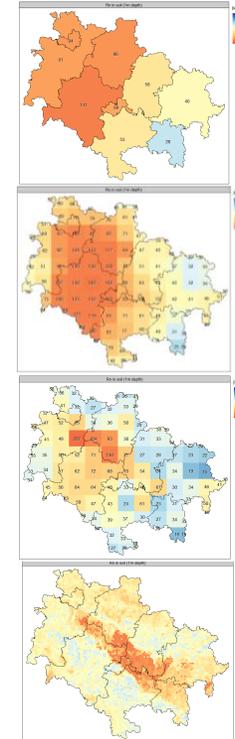


Petermann et al. 2021, Sci. Total Environ., 754



Zwischenfazit

Methode	Einbindung von Co-Variablen	Berechnung Unsicherheit/ Verteilung	Komplexität/ Implementierung
Aggregation	✗	✗	↘
Einfache Interpolation	Möglich (aber mit Einschränkungen)	✗	↔
Geostatistik	Möglich (aber mit Einschränkungen)	✓ (Annahme Normalverteilung)	↗
Machine Learning	✓	✓	↗



- Zellauflösung entscheidender Faktor
- Verwendung von Prädiktoren können die Prognose deutlich verbessern
- bei repräsentativer Messkampagne kann auch Aggregation gute Ergebnisse liefern





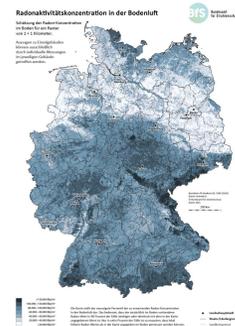
1. Hintergrund

- Warum Radonkarten?
- Stand der Dinge



2. Kartierung

- Von der Messung zur Karte
- Interpolation, Geostatistik, Machine Learning & co



3. Radon-Karten

- Rn im Boden
- Was steckt drin?
- Interpretation

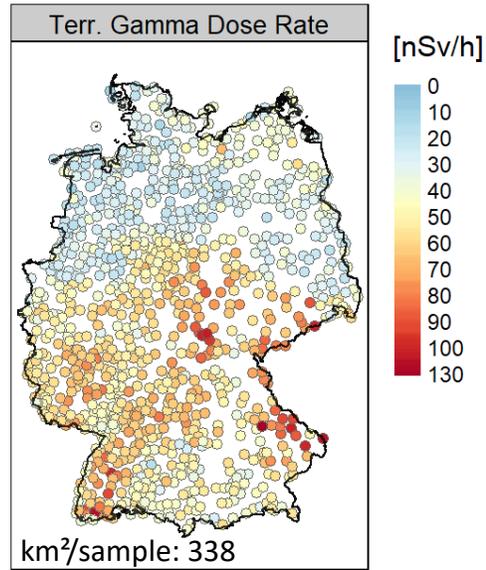
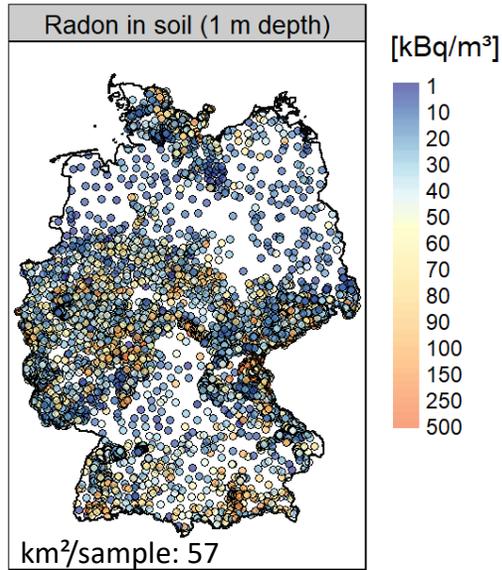
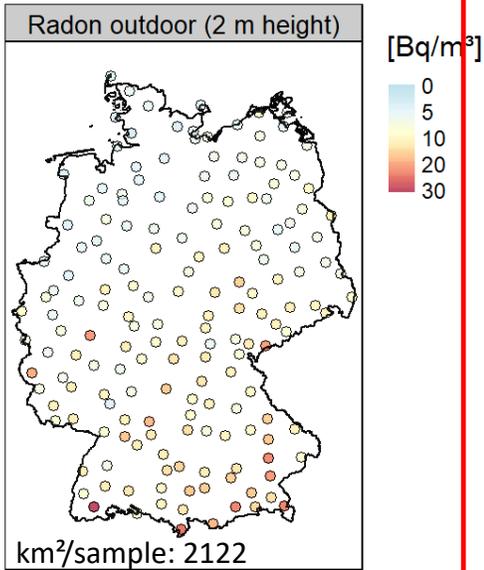


4. Ausblick

- Geogenes Radonpotenzial
- Radon in Gebäuden
- Europa



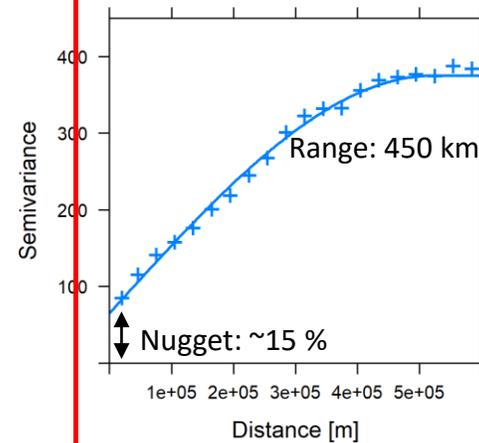
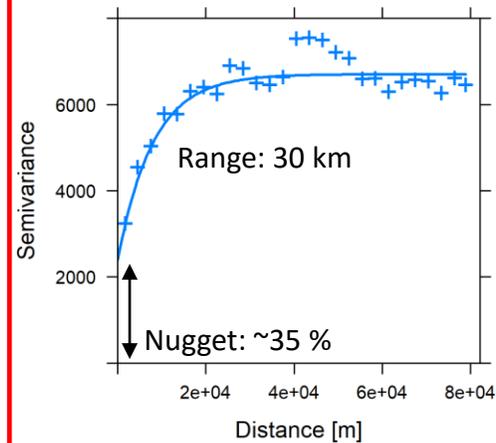
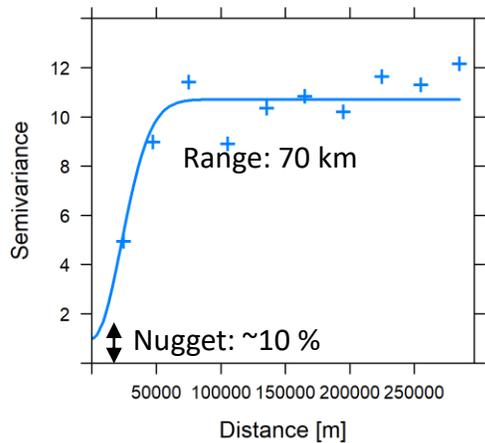
5. Fazit



Radon outdoor (2 m height)

Radon in soil (1 m depth)

Terr. Gamma Dose Rate



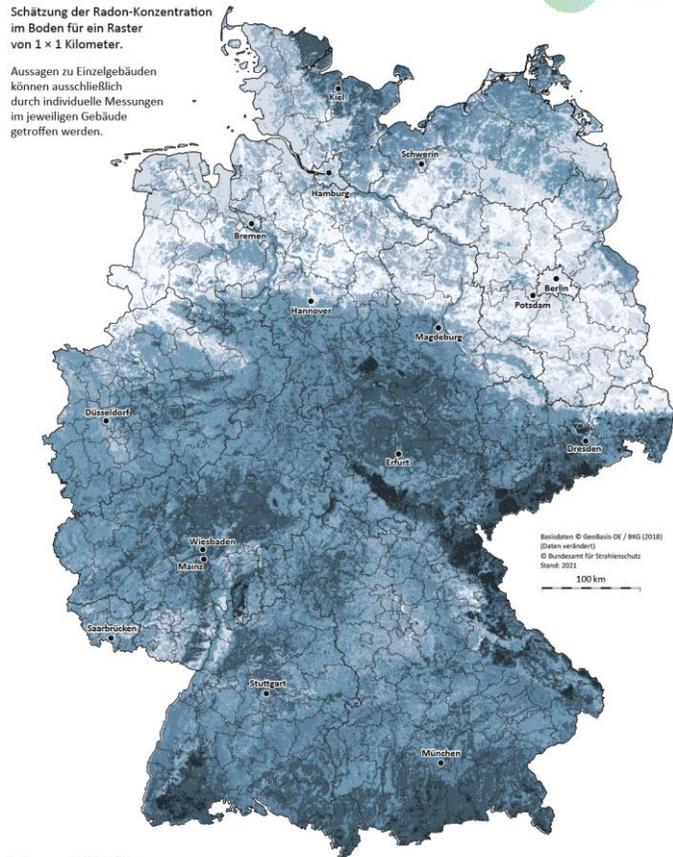
- Rn im Boden (genau wie GRP)
kurze Korrelationslänge
 - hohe kleinräumige Variabilität
- prädestiniert für Machine Learning

Radon-Bodenluftkarte

Radonaktivitätskonzentration in der Bodenluft

Schätzung der Radon-Konzentration
im Boden für ein Raster
von 1 x 1 Kilometer.

Aussagen zu Einzelgebäuden
können ausschließlich
durch individuelle Messungen
im jeweiligen Gebäude
getroffen werden.



Basisdaten © GeoBasis-DE / BGS (2018)
Daten verändert
© Bundesamt für Strahlenschutz
Stand: 2021

100 km

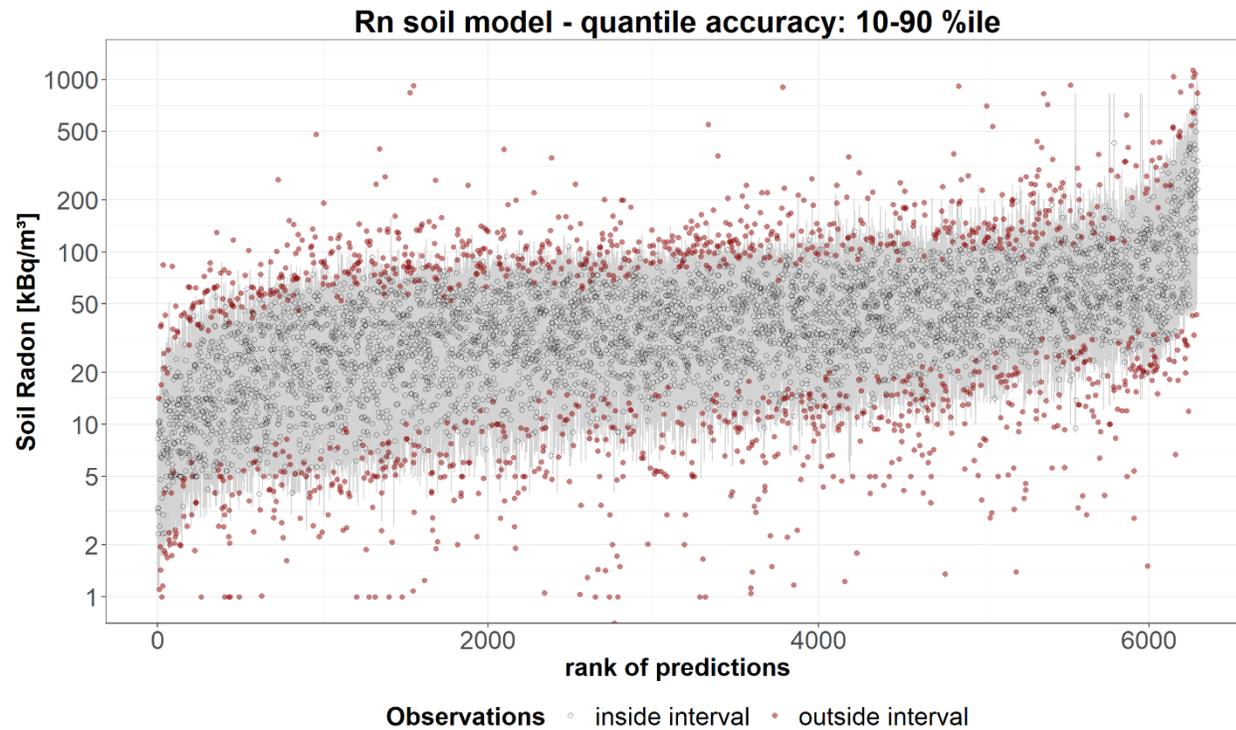


Die Karte stellt das neunzigste Perzentil der zu erwartenden Radon-Konzentration in der Bodenluft dar. Das bedeutet, dass der tatsächlich im Boden vorhandene Radon-Wert in 90 Prozent der Fälle niedriger oder identisch mit dem in der Karte angegebenen Wert ist. Nur in zehn Prozent der Fälle ist zu erwarten, dass lokal höhere Radon-Werte als in der Karte angegeben im Boden gemessen werden können.

● Landeshauptstadt
— Staats-/Ländergrenze
— Landkreisgrenze

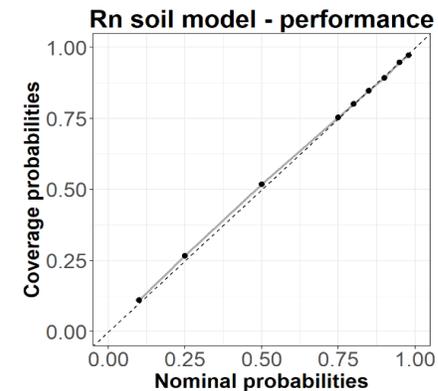
- ~ 6,300 Messwerte
- 90. Perzentil (Konservativität)
- Machine Learning (Random Forest)
- 1km-Auflösung

Radon-Bodenluftkarte – Performance

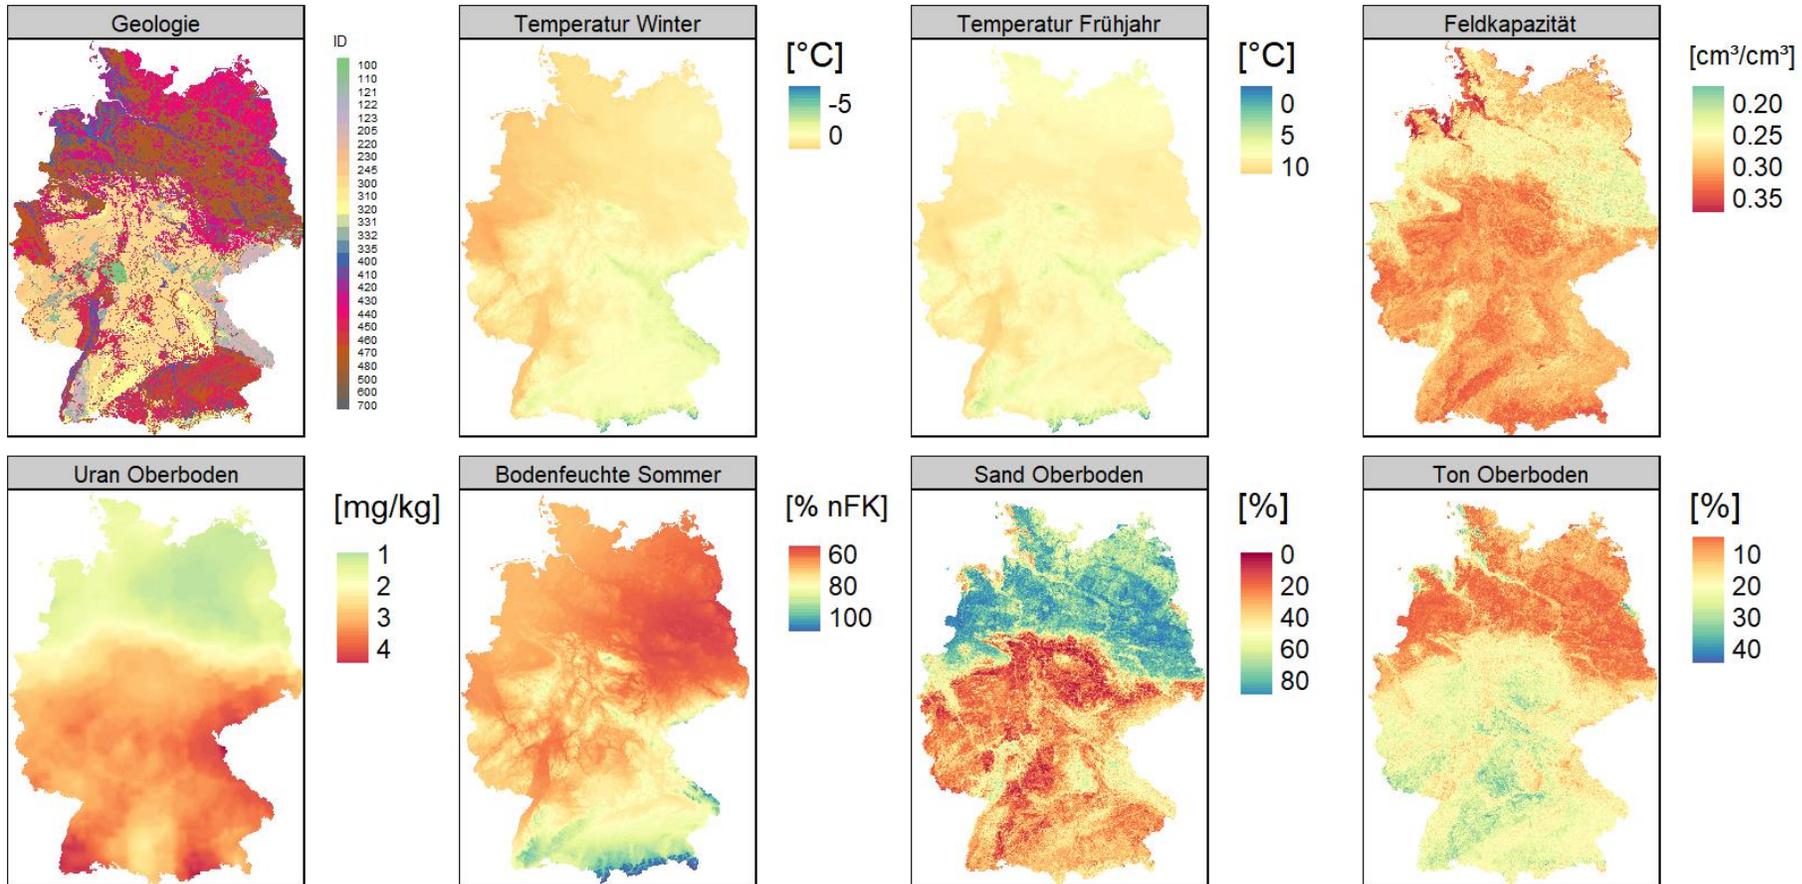


- sehr hohe Genauigkeit über alle Perzentile (räumlich kreuz-validiert)
- teilweise sehr große Residuen (Abweichung Messwert vs. Prognose)

10-fache räumliche Kreuzvalidierung				
Kriterium	innerhalb	außerhalb	Gesamt	Innerhalb [%]
10-90 %ile range	4924	1369	6293	78.2%
25-75 %ile range	3065	3228	6293	48.7%
Kriterium	oberhalb	unterhalb	Gesamt	unterhalb [%]
10%ile	5603	690	6293	11.0%
25%ile	4613	1680	6293	26.7%
50%ile	3031	3262	6293	51.8%
75%ile	1554	4739	6293	75.3%
80%ile	1254	5039	6293	80.1%
85%ile	965	5328	6293	84.7%
90%ile	680	5613	6293	89.2%
95%ile	335	5938	6273	94.7%
98%ile	169	6124	6293	97.3%



Radon-Bodenluftkarte: Prädiktoren

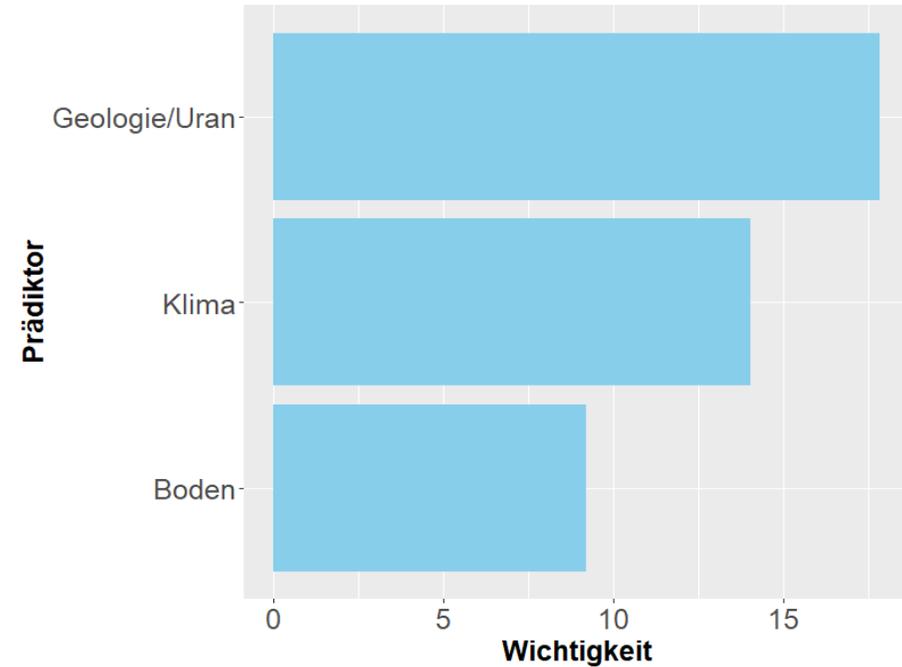
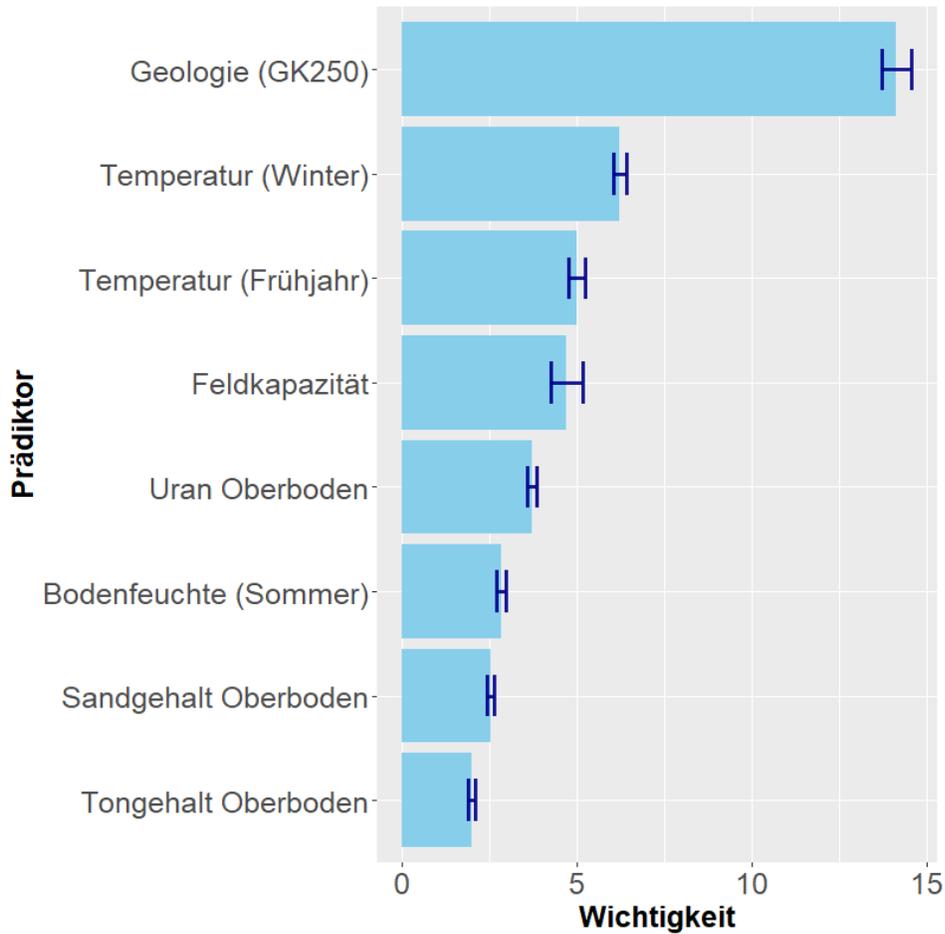


informative Prädiktoren
im finalen Modell



<https://www.castsoftware.com/blog/cracking-open-the-black-box-of-it-for-ceos>

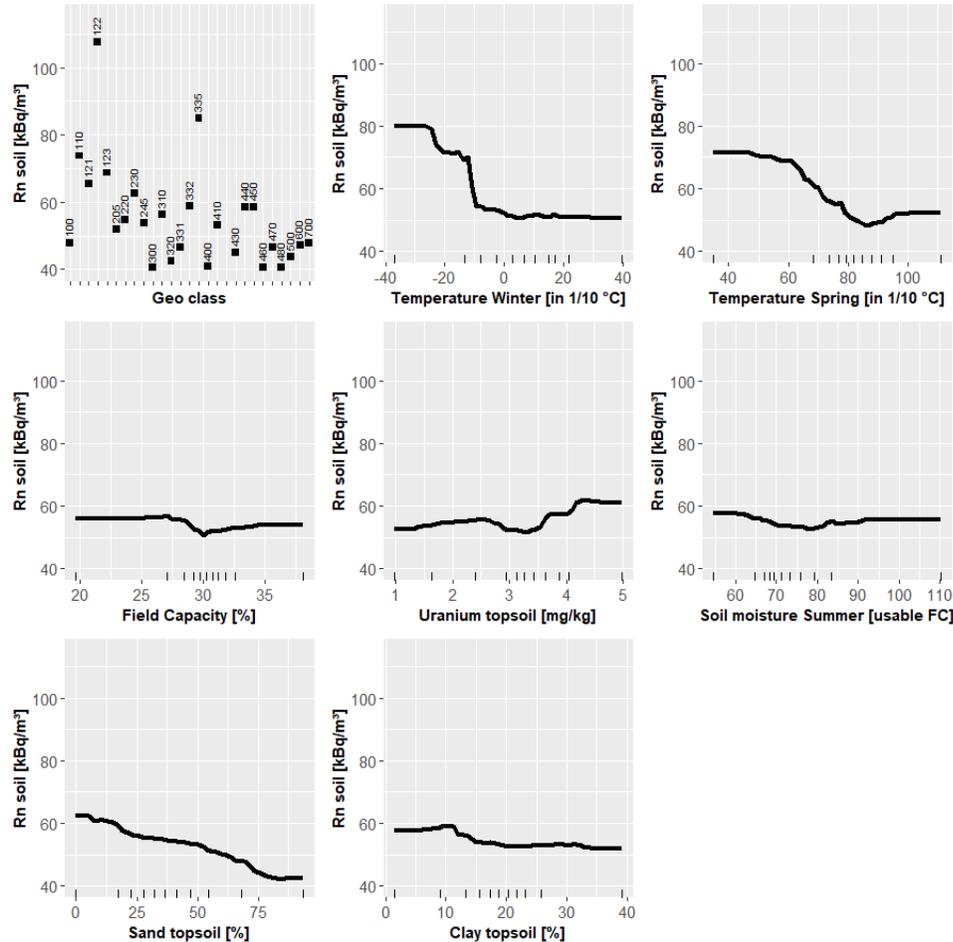
Radon-Bodenluftkarte – Modellinterpretation I: Variable importance





<https://www.castsoftware.com/blog/cracking-open-the-black-box-of-it-for-ceos>

Radon-Bodenluftkarte – Modellinterpretation II: partial dependence plots

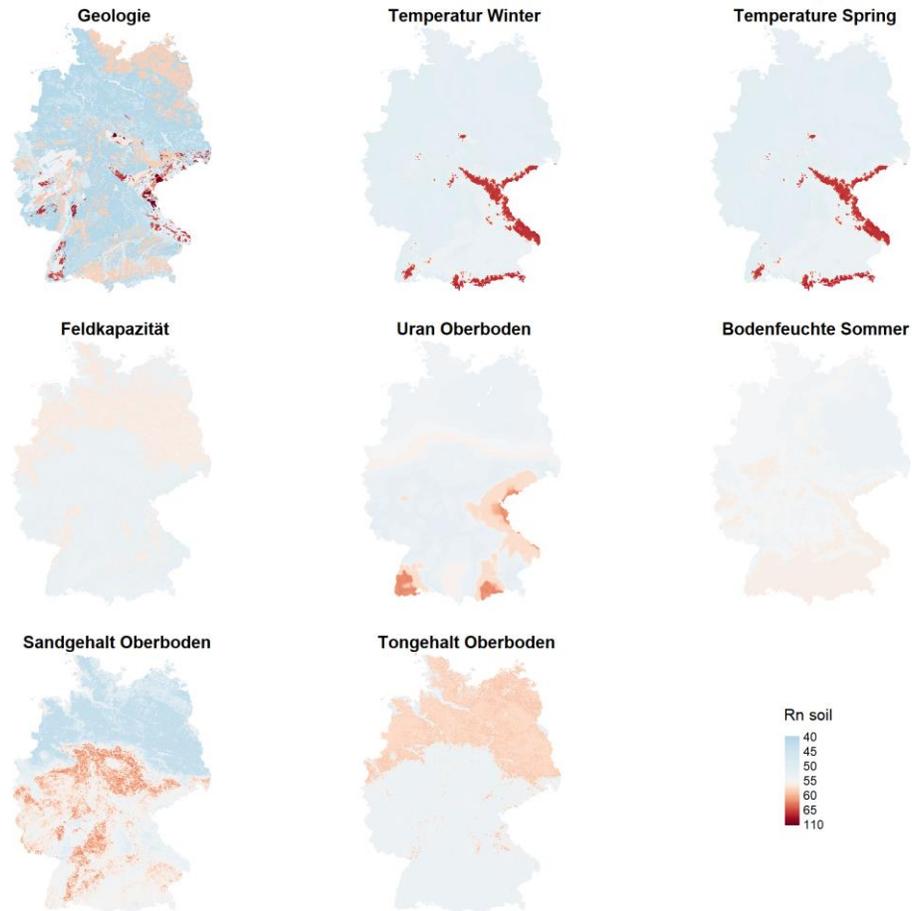


- Einfluss des Prädiktors auf Prognose
- Mittlerer Zusammenhang zwischen Prädiktorwert und Prognose
- unterstützt zu verstehen, warum das Modell an einem bestimmten Ort einen Wert prognostiziert
- Korrelation keine Kausalität !!!



<https://www.castsoftware.com/blog/cracking-open-the-black-box-of-it-for-ceos>

Radon-Bodenluftkarte – Modellinterpretation III: spatial dependence plots



- Einfluss des Prädiktors auf Prognose
- Mittleren Zusammenhang zwischen Prädiktorwert und Prognose
- unterstützt zu verstehen, warum das Modell an einem bestimmten Ort einen Wert prognostiziert
- Korrelation keine Kausalität !!!



1. Hintergrund

- Warum Radonkarten?
- Stand der Dinge



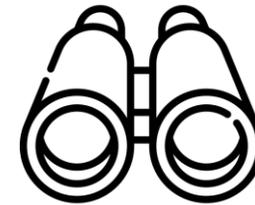
2. Kartierung

- Von der Messung zur Karte
- Interpolation, Geostatistik, Machine Learning & co



3. Radon-Karten

- Rn im Boden
- Was steckt drin?
- Interpretation



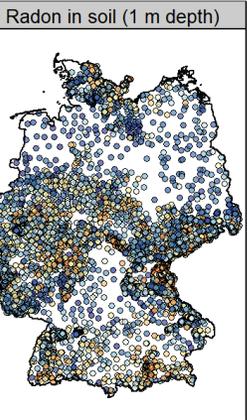
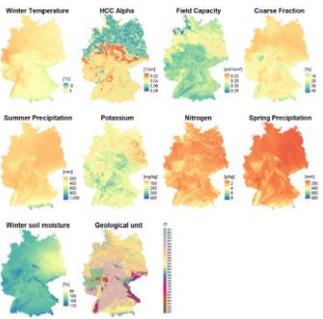
4. Ausblick

- Geogenes Radonpotenzial
- Radon in Gebäuden
- Europa

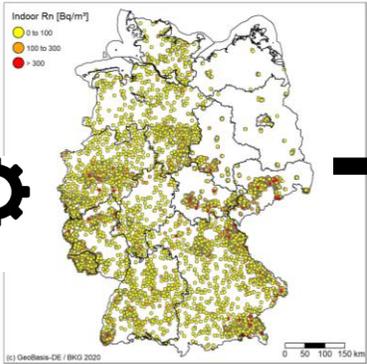
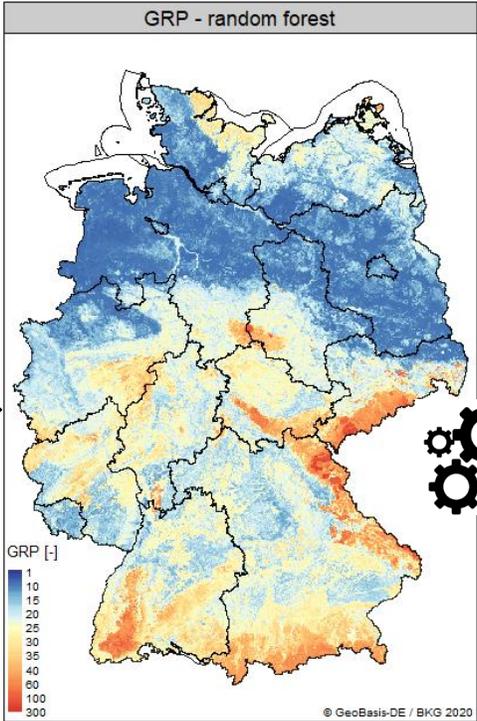


5. Fazit

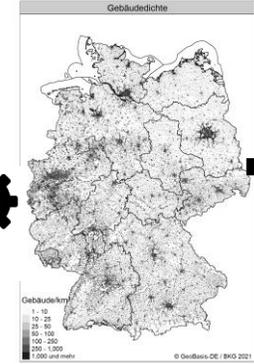
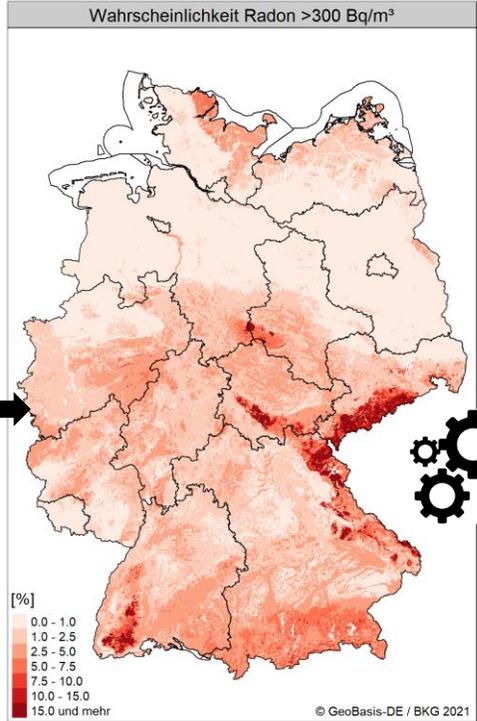
Betroffene Gebäude



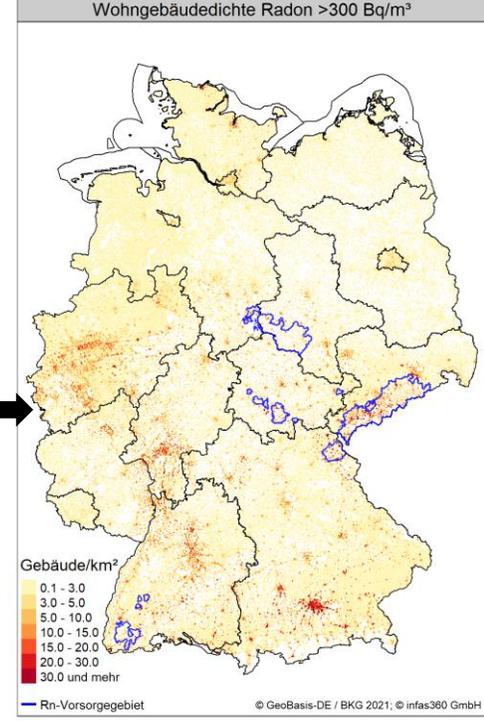
Geogenes Rn



Rn im Innenraum



Betroffene Gebäude



Radon	Wahrscheinlichkeit	Wohngebäude
> 100 Bq/m ³	11 %	~2,100,000
> 300 Bq/m ³	2 %	~350,000

Radon im Innenraum

„verwertbar“:
Messzeit = 365 Tage +/- 5 %
 (346 bis 383 Tage)

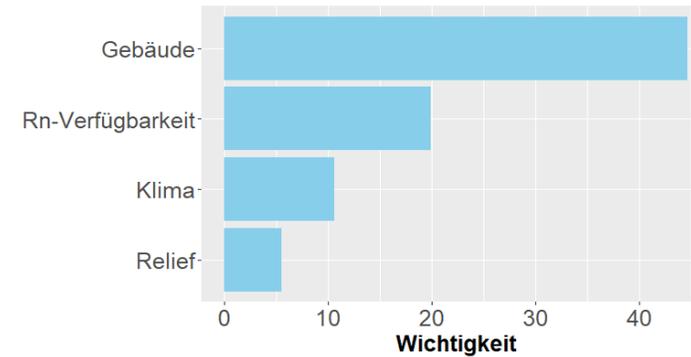
ca. 6 500 Gebäude
 ca. 13 000 Raumluftmessungen



BfS Strahlenschutzgespräch Radon 2.11.2021

Dr. Kemski/Dr. Gruber (AGES)

Prognose individueller Wohneinheiten



Gebäudeeigenschaften:

- Etage
- Baujahr
- Unterkellerung
- Anzahl Wohneinheiten
- Anzahl Personen im Haushalt
- ...

Klima:

- Temperatur
- Bodenfeuchte
- Niederschlag

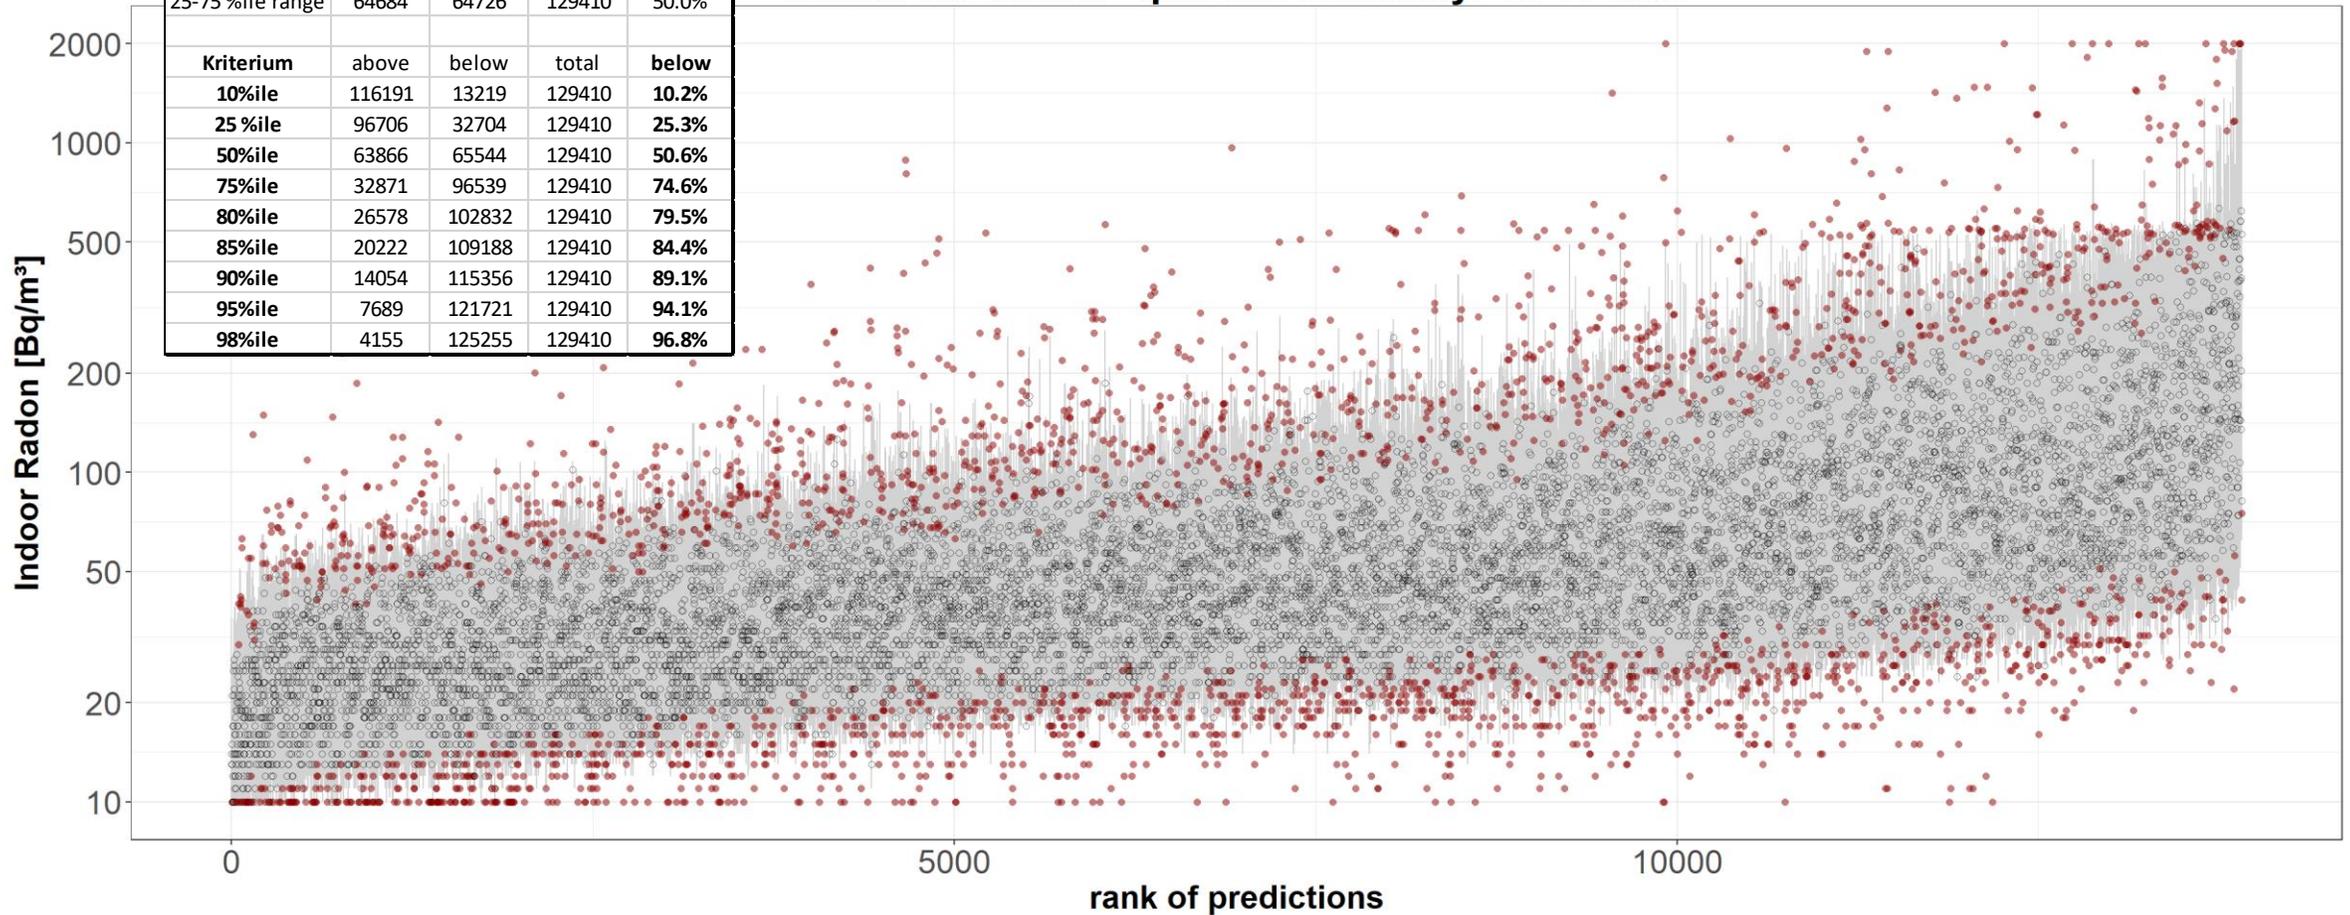
Relief:

- Hangneigung

Radon im Innenraum

10 x spatial cross-validated				
Kriterium	inside	outside	total	inside [%]
10-90 %ile range	102435	26975	129410	79.2%
25-75 %ile range	64684	64726	129410	50.0%
Kriterium	above	below	total	below
10%ile	116191	13219	129410	10.2%
25%ile	96706	32704	129410	25.3%
50%ile	63866	65544	129410	50.6%
75%ile	32871	96539	129410	74.6%
80%ile	26578	102832	129410	79.5%
85%ile	20222	109188	129410	84.4%
90%ile	14054	115356	129410	89.1%
95%ile	7689	121721	129410	94.1%
98%ile	4155	125255	129410	96.8%

Indoor Rn model - quantile accuracy: 10-90 %ile



Observations ◊ inside interval ● outside interval

Radon im Innenraum

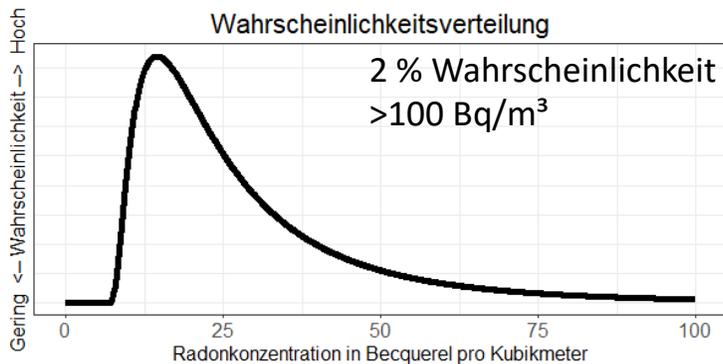
Berlin



im Boden verfügbares Radon



Hausart	Baujahr	Bauweise	Wohneinheiten	Personen	Unterkellerung	Fenster	Etage
freistehendes Haus	1919 - 1948	Massivhaus	3 - 6 WEs	2 P	vollständig	dicht/sehr dicht	1. Etage



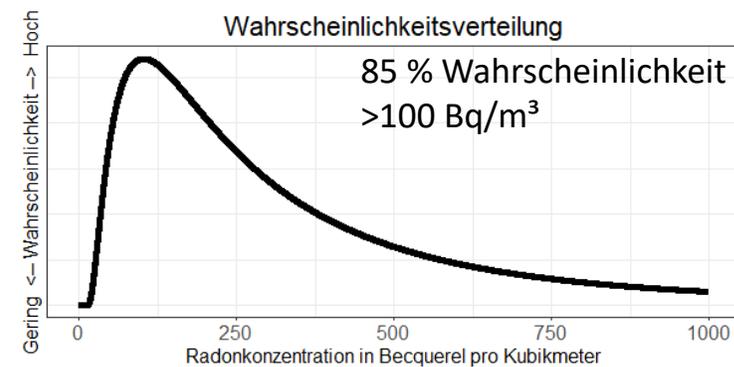
Schneeberg



im Boden verfügbares Radon

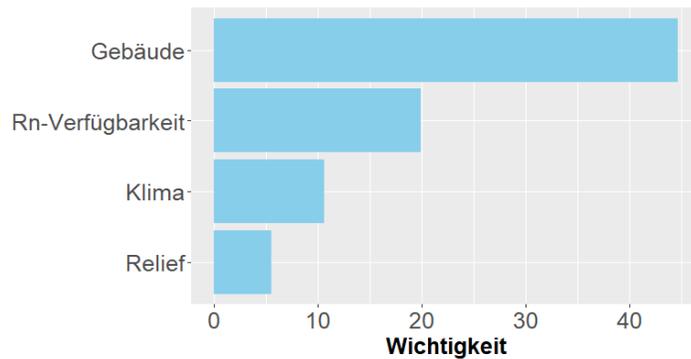


Hausart	Baujahr	Bauweise	Wohneinheiten	Personen	Unterkellerung	Fenster	Etage
freistehendes Haus	1919 - 1948	Massivhaus	1 WE	2 P	keine	dicht/sehr dicht	Erdgesc dicht



Radon im Innenraum

Prognose individueller Gebäude



Gebäudeeigenschaften:

- Etage
- Baujahr
- Unterkellerung
- Anzahl Wohneinheiten
- Anzahl Personen im Haushalt
- ...

Klima:

- Temperatur
- Bodenfeuchte
- Niederschlag

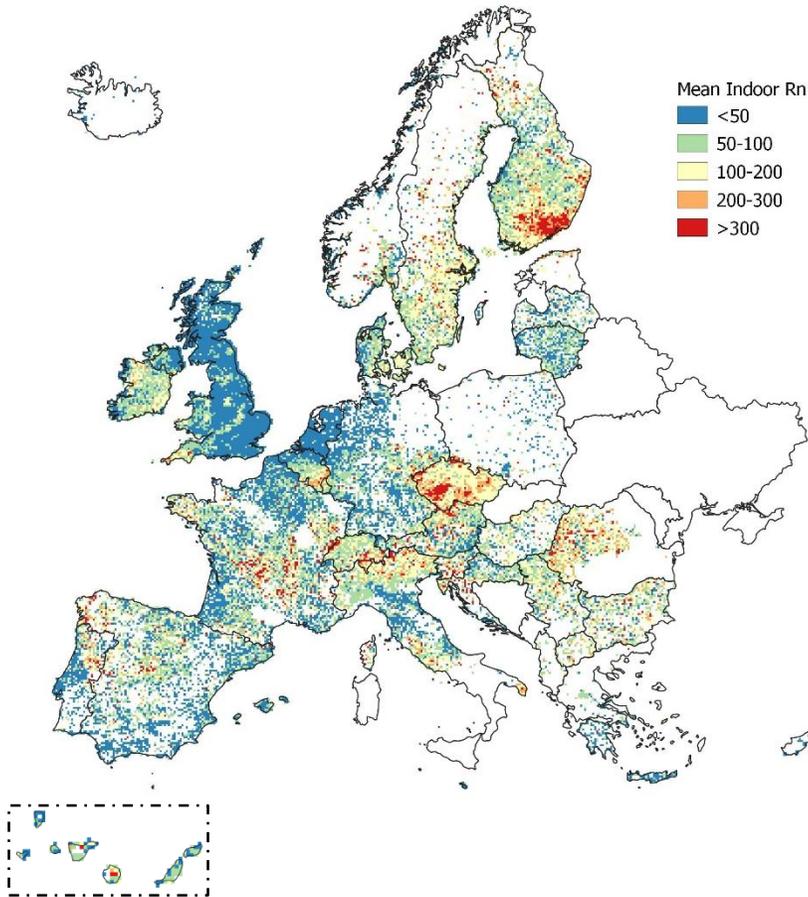
Relief:

- Hangneigung

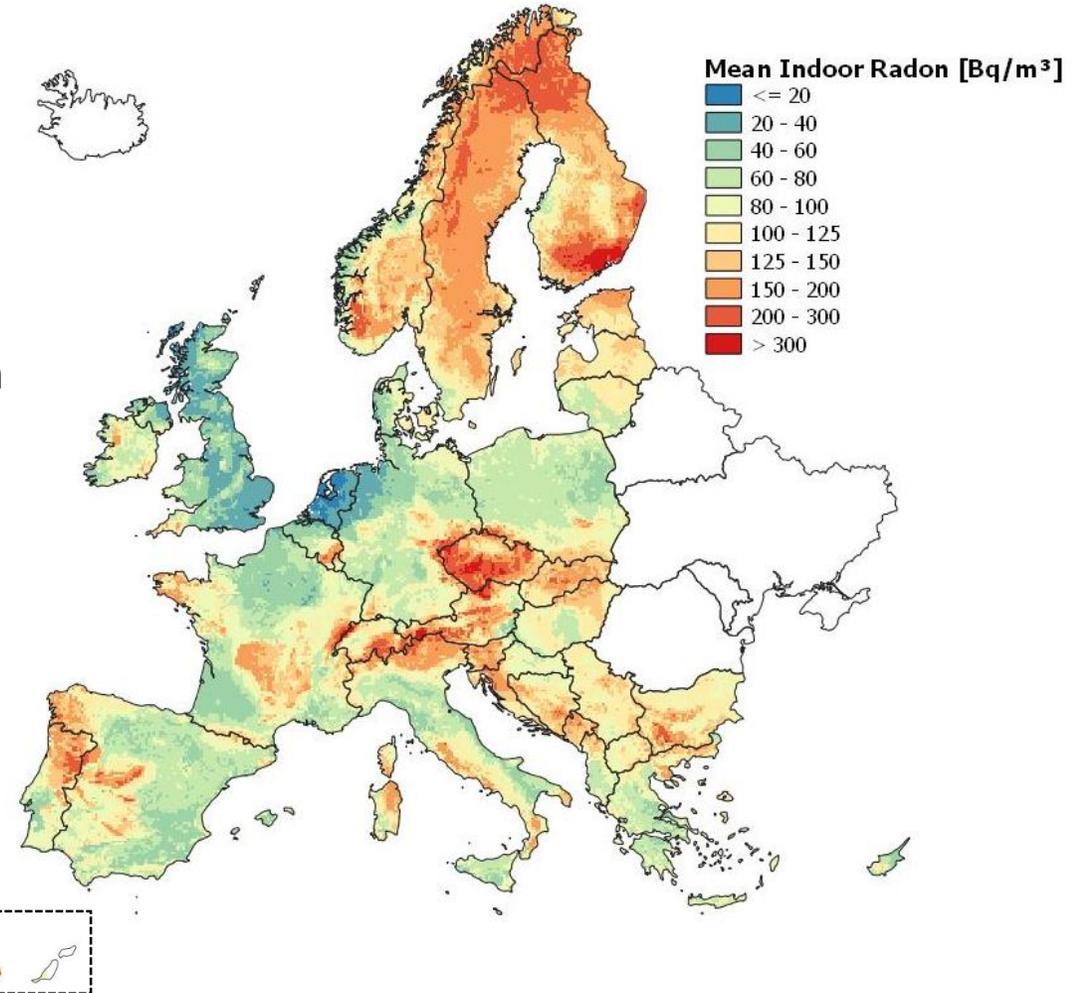
- 23,4 Mio. Gebäude, davon 18,9 Mio. Gebäude mit Wohnfunktion
- Punktdaten: Anzahl Einwohner, Haushalte, Geschoszahl, Gebäudetyp



Radon in Europa



- 1,2 Millionen Messungen aggregiert in 10 km*10 km Zellen
- 28.137 Zellen mit Daten
- Messanzahl zwischen 1 und 23.993 !!!



Data from JRC; European Atlas of natural radiation; Cinelli et al. 2018 J. Environ. Radioact.



Nächste Schritte

- Einbindung weiterer Prädiktoren (Uran im Boden/Gestein)
 - Abfrage aus Ländern
 - ggf. Erstellung bundesweiter Karten
 - Optimierung der geologischen Kartengrundlage (in Zusammenarbeit mit Landesbehörden)
 - Verbesserte Einbindung lokaler Informationen/Messwerte (z.B. Messwert in nicht kartierter geologischer Einheit); aber: Unterscheidung Rauschen (zeitliche Variabilität)/reales Signal schwierig
- > Hybride Machine-Learning-Verfahren
- Einbindung lokaler Messwerte
 - Gegenstand aktueller Forschung
 - BfS-interne Studie



1. Hintergrund

- Warum Radonkarten?
- Stand der Dinge



2. Kartierung

- Von der Messung zur Karte
- Interpolation, Geostatistik, Machine Learning & co



3. Radon-Karten

- Rn im Boden
- Was steckt drin?
- Interpretation



4. Ausblick

- Geogenes Radonpotenzial
- Radon in Gebäuden
- Europa



5. Fazit



Fazit

- viele Wege von der Messung zur Karte
- bei Vorhandensein umfangreicher Co-Variablen-Daten erzielt Machine Learning oftmals beste Ergebnisse
- bessere Einbindung lokaler Information?
- neue Radon-Bodenluftkarte
- weitere Karten folgen (geogenes Radonpotenzial, Innenraum)

Details...

Science of the Total Environment 754 (2021) 142291



Contents lists available at ScienceDirect

Science of the Total Environment

journal homepage: www.elsevier.com/locate/scitotenv



Mapping the geogenic radon potential for Germany by machine learning

Eric Petermann ^{a,*}, Hanna Meyer ^b, Madlene Nussbaum ^c, Peter Bossew ^a



Science of the Total Environment 780 (2021) 146601



Contents lists available at ScienceDirect

Science of the Total Environment

journal homepage: www.elsevier.com/locate/scitotenv



Mapping indoor radon hazard in Germany: The geogenic component

Eric Petermann ^{*}, Peter Bossew



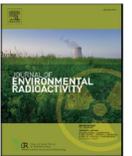
Journal of Environmental Radioactivity 244–245 (2022) 106833



Contents lists available at ScienceDirect

Journal of Environmental Radioactivity

journal homepage: www.elsevier.com/locate/jenvrad



Radon hazard vs. radon risk - On the effectiveness of radon priority areas

Eric Petermann ^{*}, Peter Bossew, Bernd Hoffmann



**Bundesamt
für Strahlenschutz**

Impressum

Bundesamt für Strahlenschutz
Postfach 10 01 49
38201 Salzgitter

Tel.: +49 30 18333-0
Fax: +49 30 18333-1885
E-Mail: ePost@bfs.de

www.bfs.de

Kontakt für Rückfragen

Dr. Eric Petermann
epetermann@bfs.de
+49 30 18333 - 4246