

Für Mensch & Umwelt

**KI-Lab**

Anwendungslabor für künstliche  
Intelligenz und Big Data

**Umwelt  
Bundesamt** 

**Fachtagung Bodenindikatoren (17.04.2024)**

# Wie kann KI dabei helfen, Datenlücken bei der Entwicklung bodenbezogener Indikatoren zu schließen?

Viola Rädle

Data Scientist

KI-Lab Leipzig, Umweltbundesamt

[ki-anwendungslabor@uba.de](mailto:ki-anwendungslabor@uba.de)

Wie kann KI dabei helfen, Datenlücken bei der Entwicklung bodenbezogener Indikatoren zu schließen?

# Das KI-Lab am Umweltbundesamt

Anwendungslabor für Künstliche Intelligenz und Big Data

Informieren • Involvieren • Begeistern



**Ziele:** Forschung, Entwicklung, Kompetenzaufbau, Beratung, Wissenstransfer

# Welche Arten von Datenlücken gibt es?

Bsp: Umfrage zu Einkommen

**Umfrage**

Geschlecht:

☐ m    ☐ w    ☐ d

Haarfarbe: \_\_\_\_\_

Alter: \_\_\_\_\_

Schuhgröße: \_\_\_\_\_

Einkommen: \_\_\_\_\_

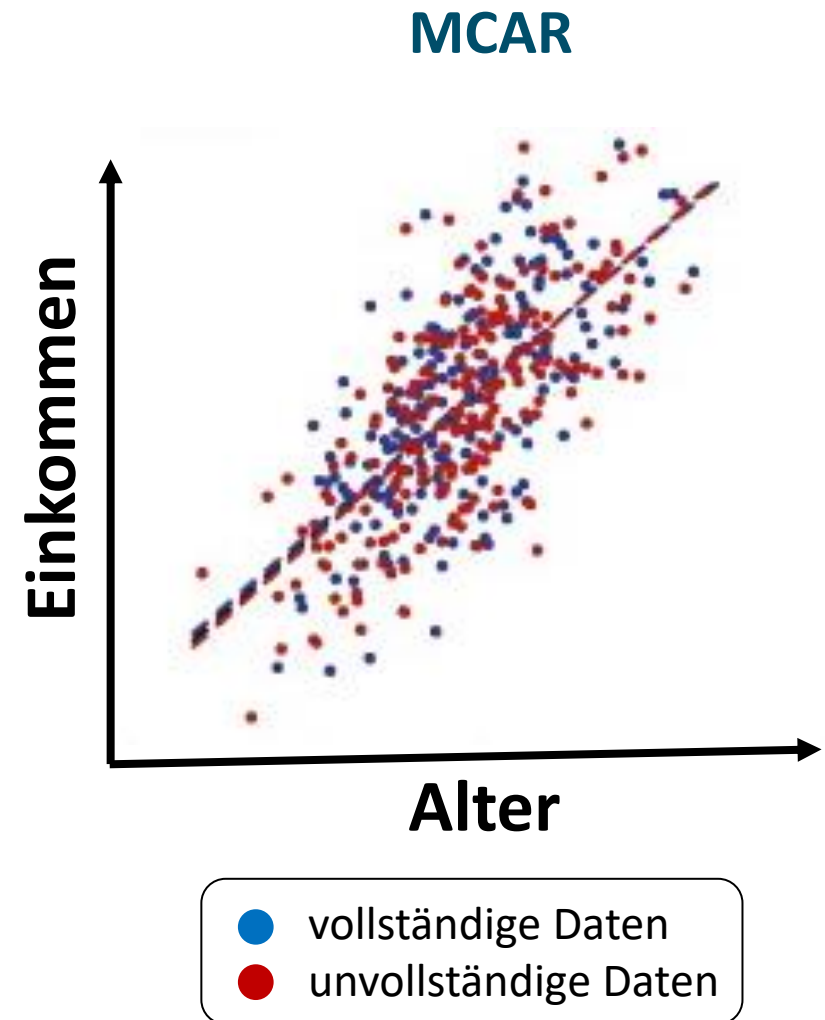


# Welche Arten von Datenlücken gibt es?

Bsp: Umfrage zu Einkommen

## Missing completely at random (MCAR):

- **kein Zusammenhang** mit erfassten Daten
- Bsp: technische Fehler, Übersehen eines Feldes



Quelle: <https://hushuli.github.io/Metabox-Blog.github.io/posts/2018-11-08-missing-value/>



# Welche Arten von Datenlücken gibt es?

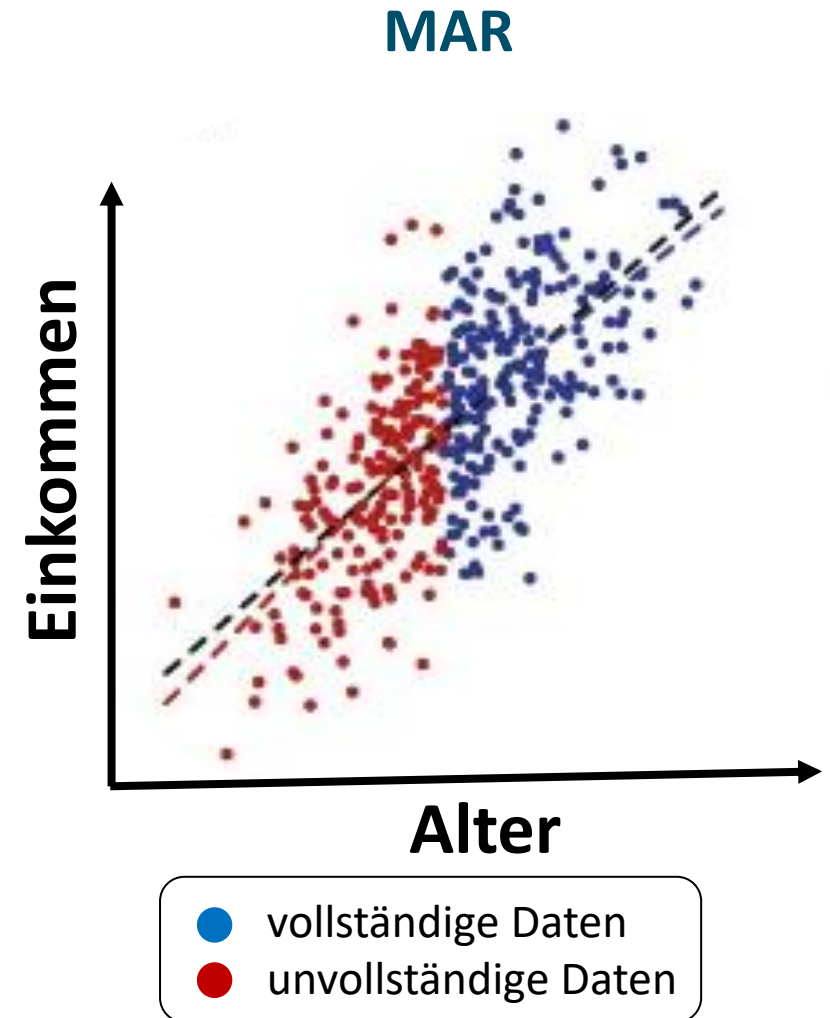
Bsp: Umfrage zu Einkommen

## Missing completely at random (MCAR):

- **kein Zusammenhang** mit erfassten Daten
- Bsp: technische Fehler, Übersehen eines Feldes

## Missing at random (MAR):

- Zusammenhang mit **anderer Variable**
- Bsp: Jüngere Menschen wollen keine Auskunft über ihr Einkommen geben



# Welche Arten von Datenlücken gibt es?

Bsp: Umfrage zu Einkommen

## Missing completely at random (MCAR):


- **kein Zusammenhang** mit erfassten Daten
- Bsp: technische Fehler, Übersehen eines Feldes

## Missing at random (MAR):

- Zusammenhang mit **anderer Variable**
- Bsp: Jüngere Menschen wollen keine Auskunft über ihr Einkommen geben

## Missing not at random (MNAR):

- Zusammenhang mit **lückenhafter Variable**
- Bsp: Menschen mit höherem Einkommen wollen keine Auskunft geben



# Welche Arten von Datenlücken gibt es?

## Beispiele aus der Umweltforschung

### Missing completely at random (MCAR):

- technische Probleme / Stromausfall
- finanzieller Aufwand der Messung
- Messpersonal erkrankt

### Missing at random (MAR):

- Monitoring der Wasserqualität in Industrienähe nicht möglich (Gelände abgesperrt)
- weniger Messstationen in schwer zugänglichen Gebieten als in Zivilisationsnähe
- Messfahrten aufgrund schlechter Witterungsbedingungen abgebrochen

### Missing not at random (MNAR):

- Monitoring der Artenvielfalt: bedrohte Arten sind schwieriger zu finden
- Sensor kann Werte oberhalb des Messbereichs nicht mehr erfassen
- Radioaktivitätsmessungen: Probenahme in kontaminierten Gebieten zu gefährlich



# data imputation



## data dropping

lösche lückenhafte  
Messungen



# Der einfachste Weg: Data dropping

Lösche alle Messungen mit fehlenden Werten

Datum	Temperatur in °C	Wassergehalt in %	Leitfähigkeit in dS/m	pH	Stickstoff in %
20.03.2023		22.6	1.2	4.9	0.09
01.04.2023	12.5	20.4	1.8	5.2	0.07
13.04.2023	14.2	25.3		6.3	0.10
02.05.2023	15.6	33.7	1.9	5.0	
24.05.2023	16.4	30.1	2.1	5.7	0.12
	19.0	28.3	2.3	6.5	0.14
02.09.2023	18.7	35.8	2.6	6.8	0.11
17.09.2023	17.2		2.0	6.2	0.06

# Der einfachste Weg: Data dropping

Lösche alle Messungen mit fehlenden Werten

Datum	Temperatur in °C	Wassergehalt in %	Leitfähigkeit in dS/m	pH	Stickstoff in %
<del>20.03.2023</del>		<del>22.6</del>	<del>1.2</del>	<del>4.9</del>	<del>0.09</del>
01.04.2023	12.5	20.4	1.8	5.2	0.07
<del>13.04.2023</del>	<del>14.2</del>	<del>25.3</del>		<del>6.3</del>	<del>0.10</del>
<del>02.05.2023</del>	<del>15.6</del>	<del>33.7</del>	<del>1.9</del>	<del>5.0</del>	
24.05.2023	16.4	30.1	2.1	5.7	0.12
	<del>19.0</del>	<del>28.3</del>	<del>2.3</del>	<del>6.5</del>	<del>0.14</del>
02.09.2023	18.7	35.8	2.6	6.8	0.11
<del>17.09.2023</del>	<del>17.2</del>		<del>2.0</del>	<del>6.2</del>	<del>0.06</del>

# data imputation



## single imputation

fülle die Lücken mit  
anderem Wert

## data dropping

lösche lückenhafte  
Messungen

### uniVariat

- Hot-Deck
- Mittelwert/Median
- Regression

### multiVariat

- k-nearest-neighbors
- Random Forest
- Support Vector Machine
- multiple Regression
- Hauptkomponentenanalyse

# Hot-Deck-Imputation

Fülle die Datenlücke mit einem zufälligen Wert aus der Spalte


Datum	Temperatur in °C	Wassergehalt in %	Leitfähigkeit in dS/m	pH	Stickstoff in %
20.03.2023		22.6	1.2	4.9	0.09
01.04.2023	12.5	20.4	1.8	5.2	0.07
13.04.2023	14.2	25.3		6.3	0.10
02.05.2023	15.6	33.7	1.9	5.0	
24.05.2023	16.4	30.1	2.1	5.7	0.12
	19.0	28.3	2.3	6.5	0.14
02.09.2023	18.7	35.8	2.6	6.8	0.11
17.09.2023	17.2		2.0	6.2	0.06

# Mean/Median Imputation

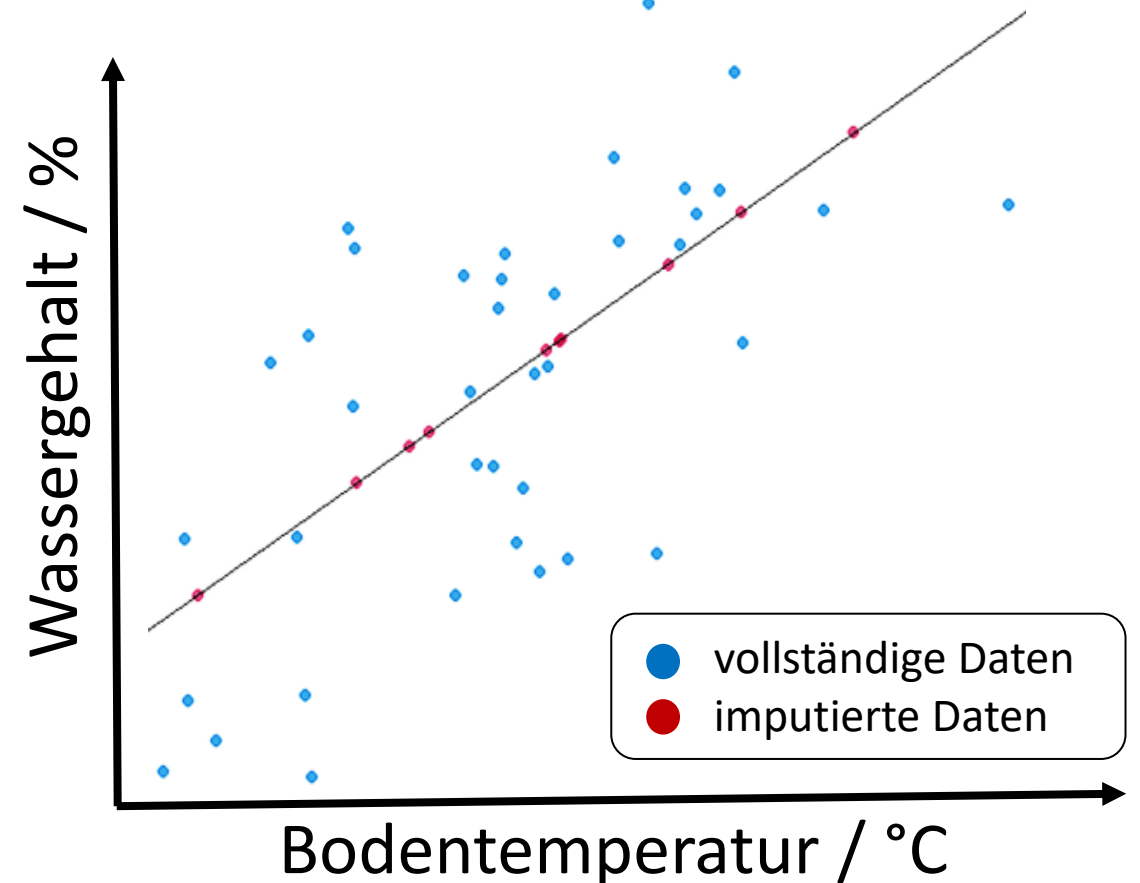
	Datum	Temperatur in °C	Wassergehalt in %	Leitfähigkeit in dS/m	pH	Stickstoff in %
	20.03.2023		22.6	1.2	4.9	0.09
	01.04.2023	12.5	20.4	1.8	5.2	0.07
	13.04.2023	14.2	25.3		6.3	0.10
	02.05.2023	15.6	33.7	1.9	5.0	
	24.05.2023	16.4	30.1	2.1	5.7	0.12
		19.0	28.3	2.3	6.5	0.14
	02.09.2023	18.7	35.8	2.6	6.8	0.11
	17.09.2023	17.2		2.0	6.2	0.06
Mean	29.05.2023	16.2	28.0	2.0		0.1
Median	02.05.2023	16.4	28.3	2.0		0.1



# Imputation durch... ...den Mittelwert



# ...Regression




Quelle: <https://www.missingdata.nl/missing-data/missing-data-methods/imputation-methods/>

# Imputation durch...


## k-nearest-neighbours

Berechne den Mittelwert aus den Nachbarn

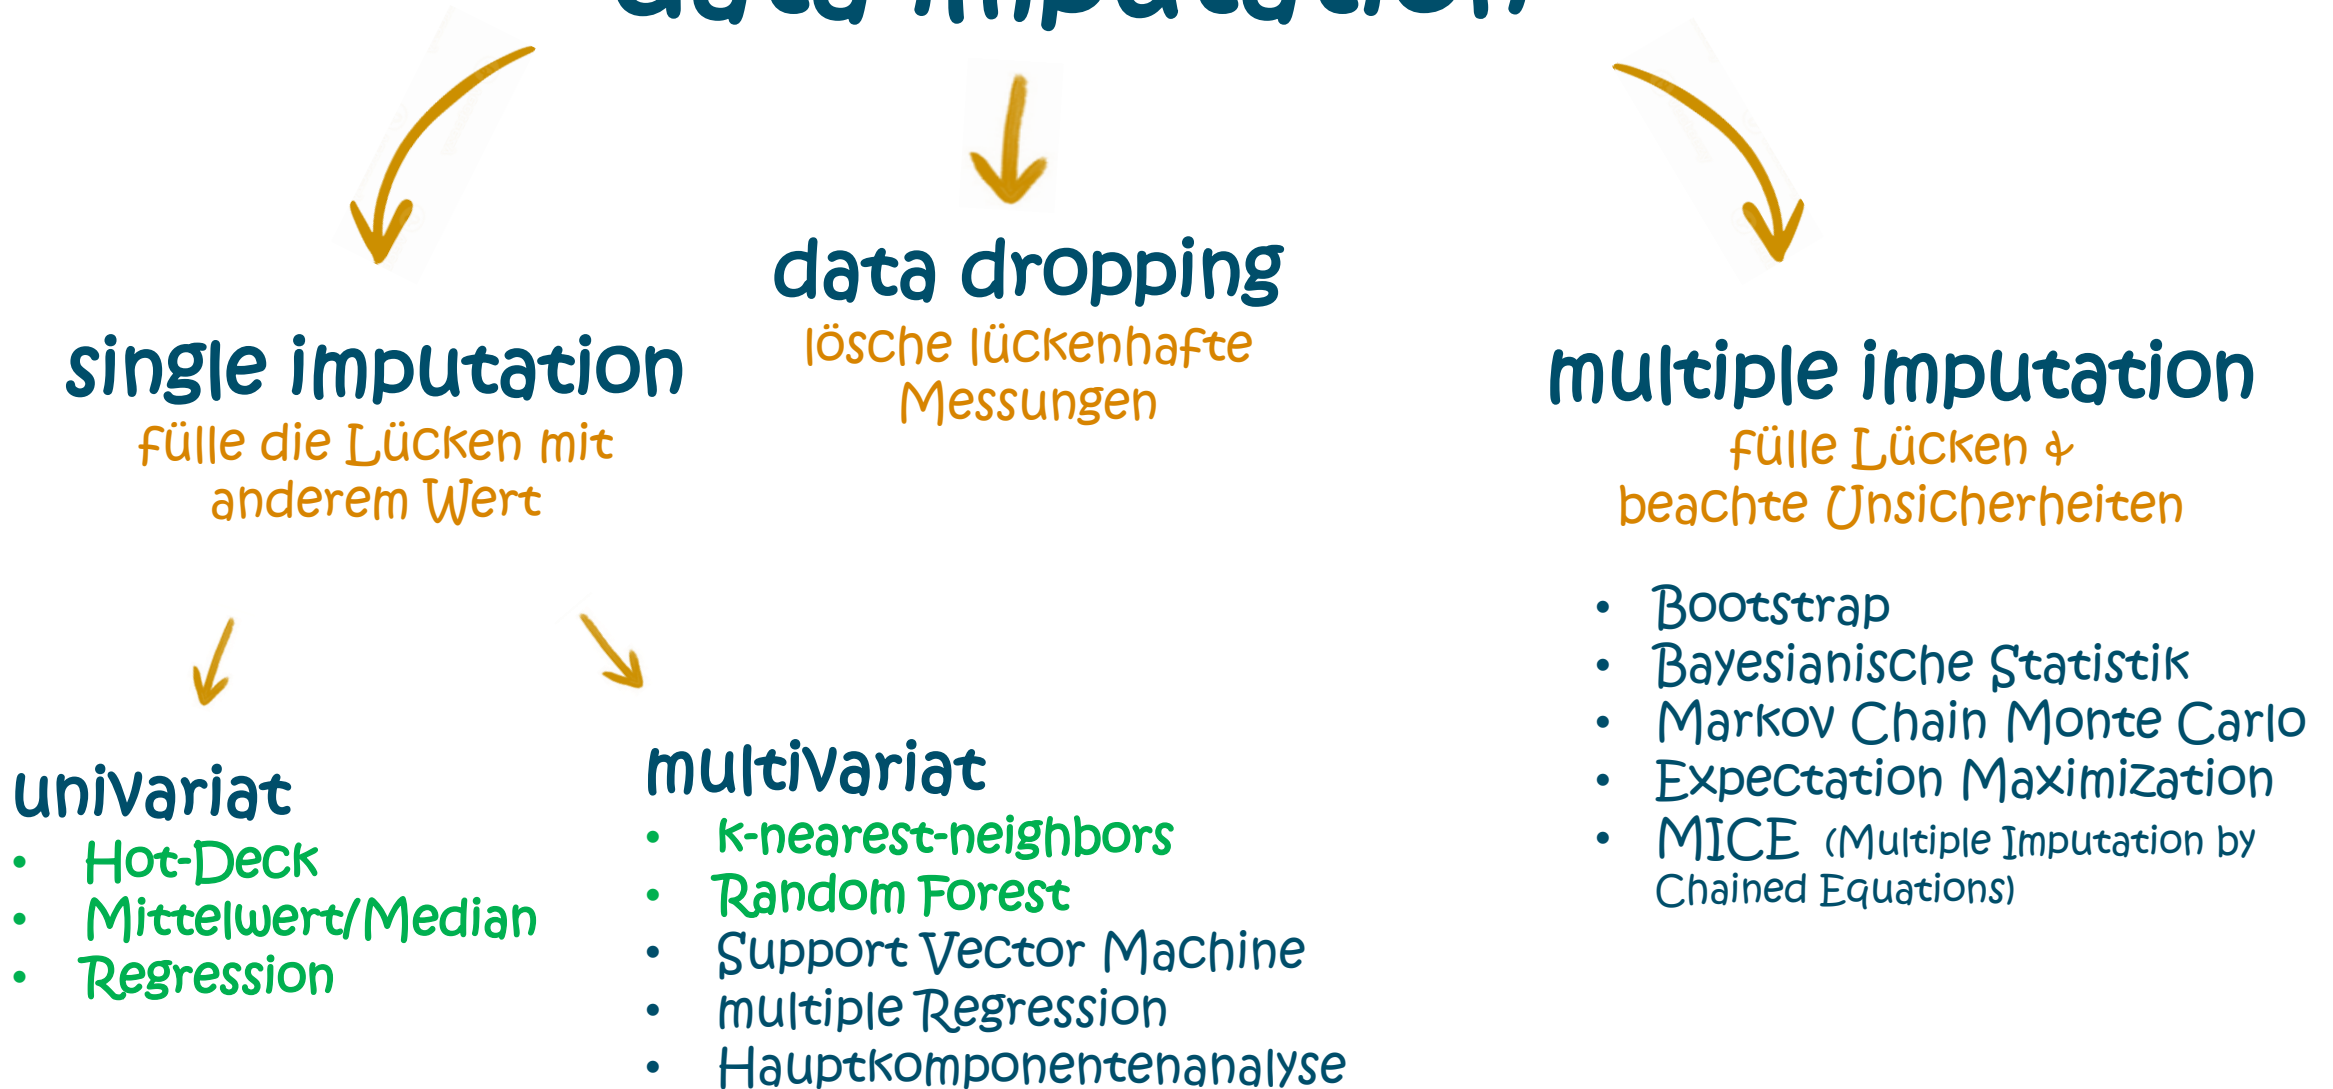


## random forest

Mittle über mehrere Entscheidungsbäume




# data imputation



# Imputation durch...

## Bootstrapping

Resampling zur Unsicherheitsabschätzung



# data imputation

## single imputation

fülle die Lücken mit  
anderem Wert

## data dropping

lösche lückenhafte  
Messungen

## multiple imputation

fülle Lücken &  
beachte Unsicherheiten

### uniVariat

- Hot-Deck
- Mittelwert/Median
- Regression

### multiVariat


- k-nearest-neighbors
- Random Forest
- Support Vector Machine
- multiple Regression
- Hauptkomponentenanalyse

- Bootstrap
- Bayesianische Statistik
- Markov Chain Monte Carlo
- Expectation Maximization
- MICE (Multiple Imputation by Chained Equations)



# Limitierungen von Imputation

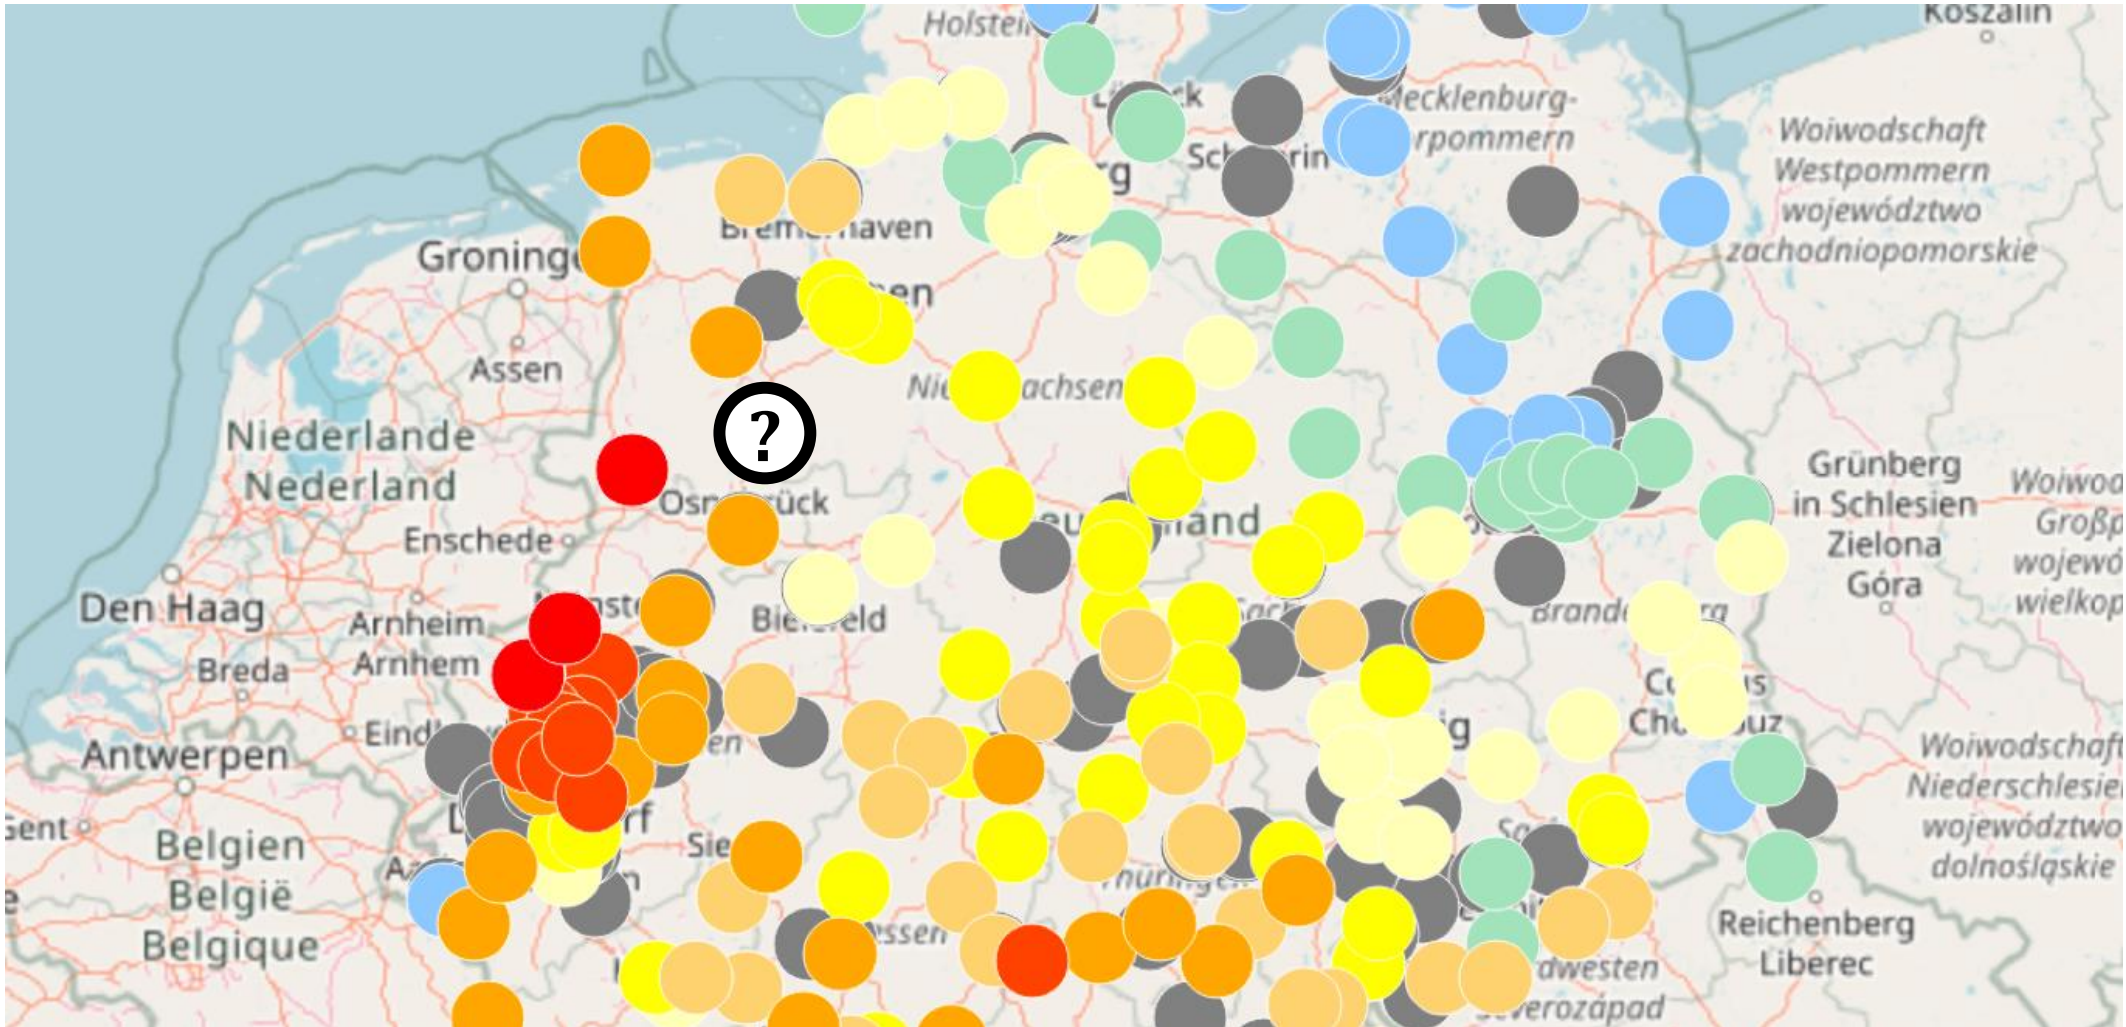
## Entzauberung von Künstlicher Intelligenz



Quelle: <https://de.statista.com/statistik/daten/studie/5564/umfrage/monatliche-durchschnittstemperatur-in-deutschland/>

# Räumliche Datenlücken


## Bsp: Messstationen für Luftqualität



Quelle: <https://www.umweltbundesamt.de/daten/luft/luftdaten>


# Räumliche Interpolation

global vs. lokal (Methode: *inverse distance weight*)



# Räumliche Interpolation



Lokale Interpolation (Methode: *inverse distance weight*)



Messstationen

fester Radius  $r_{\max}$

variabler Radius  $r_{\max}$

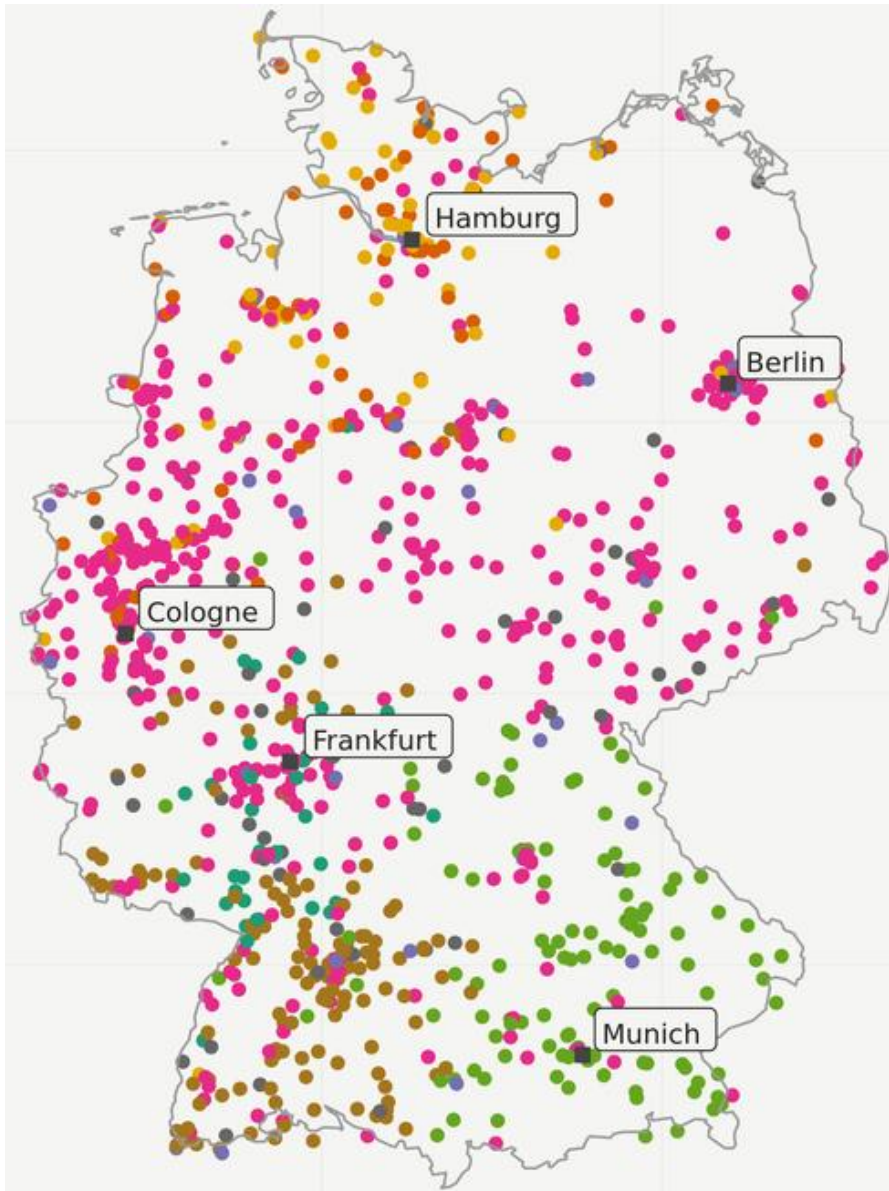


**Danke fürs Zuhören 😊**

**Jetzt: Eure Fragen!**







**Dialect**

- babbeln
- klönen
- plaudern
- quatschen
- ratschen
- schnacken
- schwätzen

