Case-Study zur Arbeitslosigkeit in Deutschland

Ziel der Case-Study

Deutschland hat europaweit eine der niedrigsten Arbeitslosenquoten:

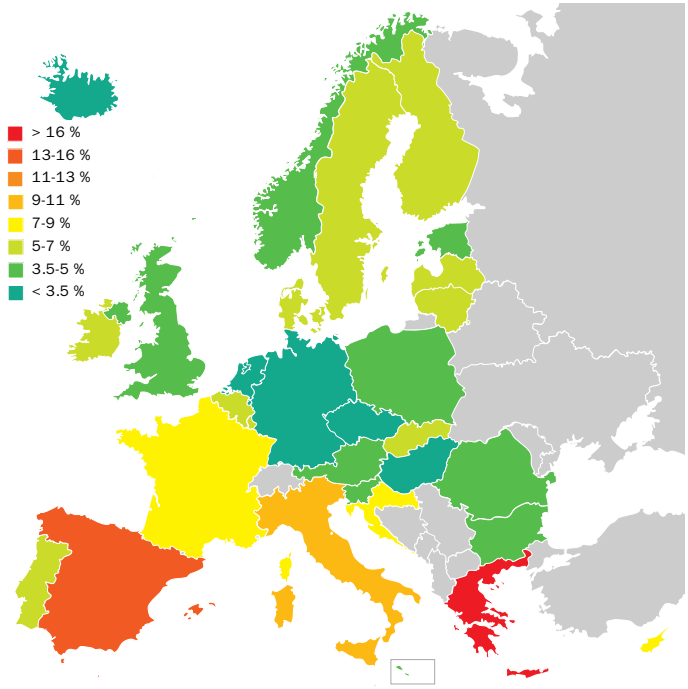

Quelle: Von Heycci - Daten von Eurostat, CC BY-SA 2.5

Ziel der Case-Study

Deutschland hat europaweit eine der niedrigsten Arbeitslosenquoten:

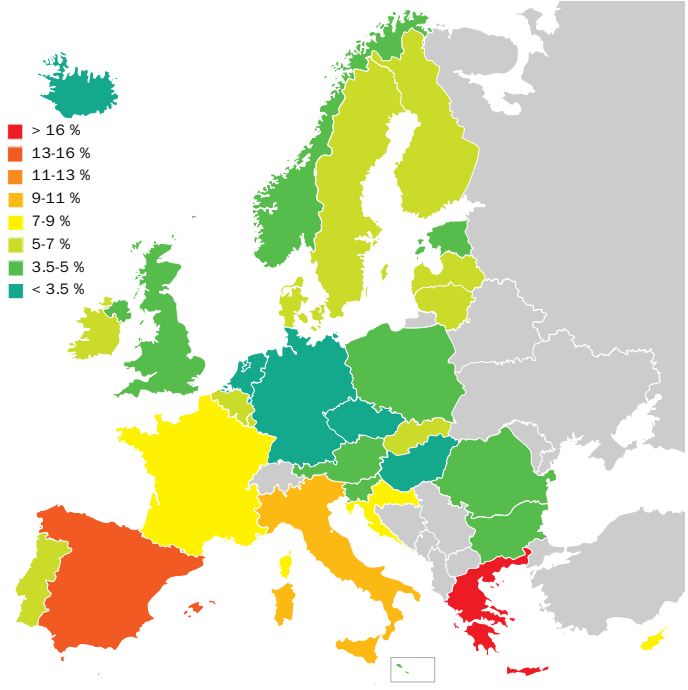

Quelle: Von Heycci - Daten von Eurostat, CC BY-SA 2.5

> Doch gilt dies für alle Regionen in Deutschland? Warum ist die Arbeitslosenquote in manchen Regionen höher als in anderen?

Dem wollen wir in dieser Case-Study auf den Grund gehen.

Ziele der Case Study

Diese Case-Study besteht aus **mehreren Teilen** und wird Sie durch die komplette Vorlesung als **konkretes Anschauungsobjekt** begleiten.

Diese Case-Study dient als:

- konkretes und umfangreiches Beispiel für ein Projekt
- ökonomische und geographische Kenntnisse über Deutschland erhalten
- Beispiel wie statistische und programmiertechnische Kenntnisse in der empirischen Arbeit eingesetzt werden können

Datensätze herunterladen

Ersten Teil der Case Study

- Daten einlesen
- Daten bearbeiten und in eine geeignete Form bringen (`tidy`)

Anwenden auf

- Daten zur Arbeitslosenstatistik
- Daten zur Verschuldung einzelner Landkreise bzw. Gemeinden
- Daten zum BIP

Wichtig für die Datenbeschaffung

- Zuverlässige und qualitativ hochwertige Datenquellen ausfinding machen
- Automatisierten Download programmieren
- Einlesen, verarbeiten und zusammenführen verschiedener Datensätze in R

Wichtig für die Datenbeschaffung

- Zuverlässige und qualitativ hochwertige Datenquellen ausfinding machen
- Automatisierten Download programmieren
- Einlesen, verarbeiten und zusammenführen verschiedener Datensätze in R

Verbindung zum 2. RTutor Problem Set:

- **Im Problem Set:** Kennzahlen zu verschiedenen Ländern der europäischen Union
- **Hier:** Kennzahlen innerhalb Deutschlands

Wichtig für die Datenbeschaffung

- Zuverlässige und qualitativ hochwertige Datenquellen ausfinding machen
- Automatisierten Download programmieren
- Einlesen, verarbeiten und zusammenführen verschiedener Datensätze in R

Verbindung zum 2. RTutor Problem Set:

- **Im Problem Set:** Kennzahlen zu verschiedenen Ländern der europäischen Union
- **Hier:** Kennzahlen innerhalb Deutschlands

Sowohl in der Case-Study als auch in den RTutor Problem Sets treffen Sie auf konkrete Probleme, die Sie mit ihren Kenntnissen aus der Vorlesung lösen sollen.

Daten beschaffen

Woher beziehen wir unsere Informationen?

Daten beschaffen

Woher beziehen wir unsere Informationen?

- Die Informationen über die Verschuldung der **Gemeinden** finden wir auf den Seiten des Statistischen Bundesamts im Report: Integrierte Schulden der Gemeinden und Gemeindeverbände.
- Die Informationen zur Arbeitslosigkeit auf **Verwaltungsgemeinschaftsebene** finden wir auf den Seiten der Bundesagentur für Arbeit.
- Die Informationen zum BIP auf **Landkreisebene** finden wir auf den Seiten der Statistischen Ämter des Bundes und der Länder.

Daten beschaffen

Woher beziehen wir unsere Informationen?

- Die Informationen über die Verschuldung der **Gemeinden** finden wir auf den Seiten des Statistischen Bundesamts im Report: Integrierte Schulden der Gemeinden und Gemeindeverbände.
- Die Informationen zur Arbeitslosigkeit auf **Verwaltungsgemeinschaftsebene** finden wir auf den Seiten der Bundesagentur für Arbeit.
- Die Informationen zum BIP auf **Landkreisebene** finden wir auf den Seiten der Statistischen Ämter des Bundes und der Länder.

> Zuverlässige und qualitativ hochwertige Datenquellen ausfinding machen ✔️

Nötige Pakete laden

```
library(readxl)
library(skimr)
library(tidyverse)
```

```
## ── Attaching core tidyverse packages ──────────────────────── tidyverse 2.0.0 ──
## ✔ dplyr     1.1.2     ✔ readr     2.1.4
## ✔ forcats   1.0.0     ✔ stringr   1.5.0
## ✔ ggplot2   3.4.2     ✔ tibble    3.2.1
## ✔ lubridate 1.9.3     ✔ tidyr     1.3.0
## ✔ purrr     1.0.2
## ── Conflicts ────────────────────────────────────────── tidyverse_conflicts() ──
## ✖ dplyr::filter() masks stats::filter()
## ✖ dplyr::lag()    masks stats::lag()
## ℹ Use the conflicted package (<http://conflicted.r-lib.org/>) to force all conflicts to become errors
```

Daten herunterladen

- Daten können von URLs mit Befehlen aus den Paketen `readxl` und `readr` direkt eingelesen werden
  - Für Text und Excel-Dateien
- Allerdings, wenn URL nicht mehr verfügbar, was dann?
  - Daten immer mit `download.file()` herunterladen und in einem Unterordner `data` abspeichern!

Daten herunterladen

- Daten können von URLs mit Befehlen aus den Paketen `readxl` und `readr` direkt eingelesen werden
  - Für Text und Excel-Dateien
- Allerdings, wenn URL nicht mehr verfügbar, was dann?
  - Daten immer mit `download.file()` herunterladen und in einem Unterordner `data` abspeichern!

> Automatisierten Download programmieren (wird in der ausformulierten Case-Study gemacht) (✔️)

Daten herunterladen

- Daten können von URLs mit Befehlen aus den Paketen `readxl` und `readr` direkt eingelesen werden
  - Für Text und Excel-Dateien
- Allerdings, wenn URL nicht mehr verfügbar, was dann?
  - Daten immer mit `download.file()` herunterladen und in einem Unterordner `data` abspeichern!

> Automatisierten Download programmieren (wird in der ausformulierten Case-Study gemacht) (✔️)

Wir haben die Daten bereits im Github Repository `case-study-germany` heruntergeladen und abgespeichert. Klonen Sie dieses Repository von Github auf ihren PC!

Klonen Sie unsere Github Seite

- Gehen Sie auf die Github Seite des Projektkurses
- Klicken Sie auf des grünen "Code" Button
- Kopieren Sie sich die angezeigte HTTPS
- Gehen Sie in Github Desktop und fügen dort die kopierte HTTPS in "Clone a repository" -> "URL"

Hier eine Step-by-Step Anleitung

Wenn Sie zu Beginn der Woche in Github Desktop auf "Pull" klicken werden alle Vorlesungsinhalte automatisch aktualisiert, d.h. alle Vorlesungsfolien, die Case-Study, Tutorials etc.!

05:00

Daten einlesen

Unterschiedliche Dateien und unterschiedliche Tabellenblätter, was sollten wir verwenden?

```
# Öffnen des ZIP-Archivs
# Es sind zwei Tabellen in dem ZIP Archiv, wir interessieren uns für die Anzahl der Arbeitslosen und wählen d
alo_name <- as.character(unzip("../case-study/data/Arbeitslose_2021.xlsx.zip", list = TRUE)$Name)
alo_name <- alo_name[1]
unzip("../case-study/data/Arbeitslose_2021.xlsx.zip", alo_name)
```

Daten einlesen

Unterschiedliche Dateien und unterschiedliche Tabellenblätter, was sollten wir verwenden?

```
# Öffnen des ZIP-Archivs
# Es sind zwei Tabellen in dem ZIP Archiv, wir interessieren uns für die Anzahl der Arbeitslosen und wählen d
alo_name <- as.character(unzip("../case-study/data/Arbeitslose_2021.xlsx.zip", list = TRUE)$Name)
alo_name <- alo_name[1]
unzip("../case-study/data/Arbeitslose_2021.xlsx.zip", alo_name)
```

Vermutung: Durch Tabellenblatt "Inhaltsverzeichnis" könnten wir schlauer werden

```r
alo_inhalt <- read_xlsx(alo_name, sheet = "Inhaltsverzeichnis")
head(alo_inhalt, 15)
```

```
## # A tibble: 15 × 1
##    Inhaltsverzeichnis
##    <chr>
##  1 <NA>
##  2 <NA>
##  3 Arbeitslose - Zeitreihe
##  4 <NA>
##  5 <NA>
##  6 Tabelle
##  7 Bestand an Arbeitslosen
##  8 Kreiszusammenfassung
##  9 Übersicht nach Kreisen
## 10 <NA>
## 11 Insgesamt
## 12 Rechtskreis
## 13 SGB III
## 14 SGB II
## 15 Geschlecht
```

```r
alo_inhalt <- read_xlsx(alo_name, sheet = "Inhaltsverzeichnis")
head(alo_inhalt, 15)
```

```
## # A tibble: 15 × 1
##    Inhaltsverzeichnis
##    <chr>
##  1 NA
##  2 NA
##  3 Arbeitslose - Zeitreihe
##  4 NA
##  5 NA
##  6 Tabelle
##  7 Bestand an Arbeitslosen
##  8 Kreiszusammenfassung
##  9 Übersicht nach Kreisen
## 10 NA
## 11 Insgesamt
## 12 Rechtskreis
## 13 SGB III
## 14 SGB II
## 15 Geschlecht
```

```r
alo_inhalt <- read_xlsx(alo_name, sheet = "Inhaltsverzeichnis")
head(alo_inhalt, 15)
```

```
## # A tibble: 15 × 1
##    Inhaltsverzeichnis
##    <chr>
##  1 NA
##  2 NA
##  3 Arbeitslose - Zeitreihe
##  4 NA
##  5 NA
##  6 Tabelle
##  7 Bestand an Arbeitslosen
##  8 Kreiszusammenfassung
##  9 Übersicht nach Kreisen
## 10 NA
## 11 Insgesamt
## 12 Rechtskreis
## 13 SGB III
## 14 SGB II
## 15 Geschlecht
```

Alternative: Schauen Sie sich die Excel-Datei in Excel oder LibreOffice an und entscheiden Sie dann, welches Tabellenblatt Sie einlesen möchten.

Spezifizieren welche Spalten eingelesen werden sollen

Welche Information benötigen wir aus der Tabelle

- Die Anzahl aller Arbeitslosen pro Gemeinde (d.h. SGB II und III gemeinsam) **aus dem Jahr 2021**
- Die Anzahl der Arbeitslosen pro Gemeinde für einen bestimmten Rechtskreis (z.B. nur SGB II)
- Die Anzahl der Arbeitslosen pro Gemeinde für einen bestimmten Rechtskreis und ein bestimmtes Alter (z.B. SGB II alle unter 25 Jahre)

Spezifizieren welche Spalten eingelesen werden sollen

Welche Information benötigen wir aus der Tabelle

- Die Anzahl aller Arbeitslosen pro Gemeinde (d.h. SGB II und III gemeinsam) **aus dem Jahr 2021**
- Die Anzahl der Arbeitslosen pro Gemeinde für einen bestimmten Rechtskreis (z.B. nur SGB II)
- Die Anzahl der Arbeitslosen pro Gemeinde für einen bestimmten Rechtskreis und ein bestimmtes Alter (z.B. SGB II alle unter 25 Jahre)

Spezifizieren welche Spalten eingelesen werden sollen

Welche Information benötigen wir aus der Tabelle

- Die Anzahl aller Arbeitslosen pro Gemeinde (d.h. SGB II und III gemeinsam) **aus dem Jahr 2021**
- Die Anzahl der Arbeitslosen pro Gemeinde für einen bestimmten Rechtskreis (z.B. nur SGB II)
- Die Anzahl der Arbeitslosen pro Gemeinde für einen bestimmten Rechtskreis und ein bestimmtes Alter (z.B. SGB II alle unter 25 Jahre)

> Was ist hier eine Beobachtung?

Spezifizieren welche Spalten eingelesen werden sollen

Welche Information benötigen wir aus der Tabelle

- Die Anzahl aller Arbeitslosen pro Gemeinde (d.h. SGB II und III gemeinsam) **aus dem Jahr 2021**
- Die Anzahl der Arbeitslosen pro Gemeinde für einen bestimmten Rechtskreis (z.B. nur SGB II)
- Die Anzahl der Arbeitslosen pro Gemeinde für einen bestimmten Rechtskreis und ein bestimmtes Alter (z.B. SGB II alle unter 25 Jahre)

> Was ist hier eine Beobachtung?

Weiterhin benötigen wir noch die "Gemeinde-ID" und den Gemeindenamen.

Wie können wir die von uns benötigte Information möglichst einfach extrahieren?

Spezifizieren welche Spalten eingelesen werden sollen

Welche Information benötigen wir aus der Tabelle

- Die Anzahl aller Arbeitslosen pro Gemeinde (d.h. SGB II und III gemeinsam) **aus dem Jahr 2021**
- Die Anzahl der Arbeitslosen pro Gemeinde für einen bestimmten Rechtskreis (z.B. nur SGB II)
- Die Anzahl der Arbeitslosen pro Gemeinde für einen bestimmten Rechtskreis und ein bestimmtes Alter (z.B. SGB II alle unter 25 Jahre)

> Was ist hier eine Beobachtung?

Weiterhin benötigen wir noch die "Gemeinde-ID" und den Gemeindenamen.

Wie können wir die von uns benötigte Information möglichst einfach extrahieren?

- Der einfachste Weg: Die ersten acht Zeilen abzuschneiden und die Daten erst ab dort einzulesen.
- Anschließend behalten wir nur die ersten 3 Spalten

Bundesagentur für Arbeit
Statistik

Bestand an Arbeitslosen - Gesamt

Länder, Regierungsbezirke, Kreise und Gemeinden (Gebietsstand = Datenstand)

Zeitreihe, Datenstand: Februar 2021

Rechtskreis Insgesamt

Aus Datenschutzgründen und Gründen der statistischen Geheimhaltung werden Zahlenwerte von 1 oder 2 und Daten, aus denen rechnerisch auf einen solchen Zahlenwert geschlossen werden kann, anonymisiert.

zurück zum Inhalt

Region	Jahresdurchschnitte Jahresdurchschnitt 2020	Jahresdurchschnitte Jahresdurchschnitt 2021	Rechtskreis Insgesamt - Bestand an Arbeitslosen - Gesamt Januar 2020 (1)	Februar 2020 (2)	März 2020 (3)	April 2020 (4)	Mai 2020 (5)	Juni 2020 (6)	Juli 2020 (7)	August 2020 (8)	September 2020 (9)	Oktober 2020 (10)	November 2020 (11)	Dezember 2020 (12)	Rechtskre Januar 202 (13)
Deutschland	**2.695.444**	**2.613.489**	**2.425.523**	**2.395.604**	**2.335.367**	**2.643.744**	**2.812.986**	**2.853.307**	**2.910.008**	**2.955.487**	**2.847.148**	**2.759.780**	**2.699.133**	**2.707.242**	**2.900**
01 Schleswig-Holstein	**92.140**	**88.865**	**85.827**	**85.007**	**81.837**	**92.188**	**97.207**	**96.704**	**98.778**	**97.552**	**93.961**	**92.174**	**91.617**	**92.824**	**98**
01001 Flensburg, Stadt	**4.722**	**4.369**	**4.421**	**4.393**	**4.286**	**4.897**	**5.132**	**5.075**	**5.198**	**4.958**	**4.721**	**4.522**	**4.514**	**4.544**	**4**
01002 Kiel, Landeshauptstadt	**11.776**	**11.097**	**10.791**	**10.733**	**10.522**	**11.589**	**12.170**	**12.431**	**12.808**	**12.720**	**12.400**	**12.022**	**11.622**	**11.506**	**12**
01003 Lübeck, Hansestadt	**9.404**	**9.347**	**8.605**	**8.425**	**8.305**	**9.585**	**10.078**	**9.959**	**10.093**	**9.907**	**9.592**	**9.418**	**9.396**	**9.485**	**10**
01004 Neumünster, Stadt	**3.846**	**3.771**	**3.522**	**3.470**	**3.397**	**3.782**	**3.980**	**4.010**	**4.114**	**4.065**	**4.003**	**3.956**	**3.940**	**3.910**	**4**
01051 Dithmarschen	**4.261**	**4.143**	**4.278**	**4.180**	**4.012**	**4.412**	**4.609**	**4.490**	**4.416**	**4.329**	**4.048**	**3.978**	**4.052**	**4.331**	**4**
01053 Herzogtum Lauenburg	**5.785**	**5.603**	**5.177**	**5.146**	**5.127**	**5.758**	**6.078**	**6.128**	**6.283**	**6.270**	**6.037**	**5.892**	**5.738**	**5.784**	**6**
01054 Nordfriesland	**4.970**	**4.699**	**5.454**	**5.539**	**4.845**	**5.249**	**5.497**	**4.956**	**4.846**	**4.652**	**4.441**	**4.294**	**4.708**	**5.160**	**5**
01055 Ostholstein	**5.788**	**5.371**	**6.305**	**6.262**	**5.599**	**5.955**	**6.178**	**5.685**	**5.745**	**5.637**	**5.321**	**5.186**	**5.592**	**5.994**	**6**
01056 Pinneberg	**9.486**	**9.371**	**8.456**	**8.316**	**8.034**	**9.152**	**9.845**	**10.050**	**10.384**	**10.314**	**9.931**	**9.905**	**9.752**	**9.694**	**10**
01057 Plön	**3.149**	**2.854**	**2.927**	**2.877**	**2.756**	**3.136**	**3.301**	**3.323**	**3.462**	**3.386**	**3.269**	**3.172**	**3.093**	**3.088**	**3**
01058 Rendsburg-Eckernförde	**6.378**	**6.170**	**5.785**	**5.707**	**5.462**	**6.273**	**6.671**	**6.704**	**6.977**	**6.896**	**6.712**	**6.558**	**6.397**	**6.391**	**6**
01059 Schleswig-Flensburg	**5.694**	**5.567**	**5.348**	**5.324**	**5.202**	**5.740**	**5.937**	**5.816**	**5.975**	**6.031**	**5.758**	**5.727**	**5.694**	**5.775**	**6**
01060 Segeberg	**7.694**	**7.456**	**6.708**	**6.732**	**6.574**	**7.585**	**7.965**	**8.199**	**8.457**	**8.330**	**8.122**	**8.042**	**7.824**	**7.790**	**8**
01061 Steinburg	**4.179**	**4.250**	**3.670**	**3.587**	**3.580**	**4.189**	**4.447**	**4.521**	**4.526**	**4.536**	**4.315**	**4.277**	**4.230**	**4.266**	**4**
01062 Stormarn	**5.008**	**4.798**	**4.380**	**4.316**	**4.136**	**4.886**	**5.319**	**5.357**	**5.494**	**5.521**	**5.291**	**5.225**	**5.065**	**5.106**	**5**
02 Hamburg	**80.677**	**80.395**	**68.161**	**67.710**	**66.533**	**77.518**	**84.426**	**87.775**	**91.140**	**89.807**	**85.591**	**84.131**	**82.969**	**82.359**	**86**
02000 Hamburg, Freie und Hansestadt	**80.677**	**80.395**	**68.161**	**67.710**	**66.533**	**77.518**	**84.426**	**87.775**	**91.140**	**89.807**	**85.591**	**84.131**	**82.969**	**82.359**	**86**
03 Niedersachsen	**251.377**	**243.021**	**230.000**	**227.926**	**220.490**	**246.761**	**261.588**	**264.855**	**269.582**	**276.410**	**263.257**	**255.407**	**249.156**	**251.096**	**267**
031 Statistische Region Braunschwe	**50.066**	**48.055**	**45.076**	**44.726**	**43.787**	**49.419**	**52.468**	**53.135**	**54.077**	**55.517**	**52.689**	**51.148**	**49.408**	**49.336**	**52**
03101 Braunschweig, Stadt	**7.563**	**7.340**	**6.731**	**6.567**	**6.394**	**7.420**	**7.801**	**7.983**	**8.131**	**8.499**	**7.990**	**7.924**	**7.666**	**7.654**	**8**
03102 Salzgitter, Stadt	**5.399**	**5.002**	**4.835**	**4.886**	**4.795**	**5.360**	**5.699**	**5.745**	**5.800**	**5.913**	**5.758**	**5.559**	**5.266**	**5.176**	**5**
03103 Wolfsburg, Stadt	**3.504**	**3.599**	**2.947**	**3.002**	**2.968**	**3.396**	**3.720**	**3.764**	**3.815**	**3.879**	**3.784**	**3.701**	**3.529**	**3.548**	**3**
03151 Gifhorn	**4.279**	**4.150**	**3.937**	**3.877**	**3.732**	**4.132**	**4.432**	**4.515**	**4.629**	**4.829**	**4.531**	**4.372**	**4.210**	**4.154**	**4**
03153 Goslar	**4.756**	**4.527**	**4.353**	**4.243**	**4.143**	**4.797**	**5.162**	**5.118**	**5.103**	**5.143**	**4.890**	**4.724**	**4.637**	**4.756**	**5**
03154 Helmstedt	**3.096**	**3.018**	**2.931**	**2.812**	**2.808**	**3.008**	**3.160**	**3.192**	**3.299**	**3.323**	**3.273**	**3.174**	**3.111**	**3.058**	**3**
03155 Northeim	**3.977**	**3.802**	**3.786**	**3.626**	**3.499**	**4.054**	**4.298**	**4.369**	**4.251**	**4.287**	**3.954**	**3.871**	**3.797**	**3.931**	**4**
03157 Peine	**3.796**	**3.740**	**3.297**	**3.358**	**3.292**	**3.711**	**3.920**	**3.918**	**4.058**	**4.219**	**4.065**	**3.993**	**3.884**	**3.833**	**4**
03158 Wolfenbüttel	**3.127**	**3.038**	**2.788**	**2.842**	**2.778**	**3.092**	**3.274**	**3.310**	**3.397**	**3.563**	**3.315**	**3.113**	**3.009**	**3.047**	**3**
03159 Göttingen	**10.568**	**9.840**	**9.471**	**9.513**	**9.378**	**10.449**	**11.002**	**11.221**	**11.594**	**11.862**	**11.129**	**10.717**	**10.299**	**10.179**	**10**
032 Statistische Region Hannover	**78.580**	**78.518**	**70.434**	**70.055**	**68.354**	**76.192**	**80.780**	**82.654**	**84.521**	**86.567**	**83.312**	**81.276**	**79.170**	**79.648**	**83**
03241 Region Hannover	**47.396**	**48.229**	**41.548**	**41.324**	**40.671**	**45.457**	**48.549**	**49.986**	**51.277**	**52.504**	**50.862**	**49.562**	**48.270**	**48.736**	**51**
03251 Diepholz	**5.607**	**5.362**	**5.093**	**4.944**	**4.770**	**5.449**	**5.822**	**5.873**	**6.037**	**6.216**	**5.926**	**5.855**	**5.622**	**5.675**	**5**
03252 Hameln-Pyrmont	**5.261**	**5.169**	**5.010**	**5.007**	**4.750**	**5.169**	**5.389**	**5.452**	**5.509**	**5.693**	**5.473**	**5.314**	**5.231**	**5.131**	**5**
03254 Hildesheim	**9.614**	**9.572**	**8.651**	**8.793**	**8.705**	**9.579**	**9.996**	**10.166**	**10.291**	**10.553**	**10.041**	**9.721**	**9.433**	**9.442**	**9**
03255 Holzminden	**2.375**	**2.326**	**2.307**	**2.315**	**2.215**	**2.300**	**2.404**	**2.403**	**2.470**	**2.567**	**2.408**	**2.408**	**2.324**	**2.378**	**2**
03256 Nienburg (Weser)	**3.605**	**3.448**	**3.398**	**3.342**	**3.120**	**3.593**	**3.763**	**3.809**	**3.883**	**3.914**	**3.699**	**3.580**	**3.559**	**3.602**	**3**
03257 Schaumburg	**4.723**	**4.412**	**4.427**	**4.330**	**4.123**	**4.645**	**4.857**	**4.965**	**5.054**	**5.120**	**4.903**	**4.836**	**4.731**	**4.684**	**4**

```
alo_skip <- read_xlsx(alo_name, sheet = "Gesamt", sk
```

```r
alo_skip <- read_xlsx(alo_name, sheet = "Gesamt", sk

alo_skip
```

```
## # A tibble: 11,233 × 27
##    ...1       Jahresdurchschnitte ...3  Rechtskreis Insgesam…¹ ...5  ...6  ...
##    <chr>      <chr>               <chr> <chr>                  <chr> <chr> <ch
##  1 <NA>       Jahresdurch-schnitt Jahr… 43831                  43862 43891 439
##  2 Region     2020                2021  1                      2     3     4
##  3 Deutschla… 2695444.0833333335  2613… 2425523                2395… 2335… 264
##  4 01 Schles… 92139.666666666672  8886… 85827                  85007 81837 921
##  5 01001 Fle… 4721.75             4369… 4421                   4393  4286  489
##  6 01001000 … 4721.75             4369… 4421                   4393  4286  489
##  7 01002 Kie… 11776.166666666666  1109… 10791                  10733 10522 115
##  8 01002000 … 11776.166666666666  1109… 10791                  10733 10522 115
##  9 01003 Lüb… 9404                9346… 8605                   8425  8305  958
## 10 01003000 … 9404                9346… 8605                   8425  8305  958
## # i 11,223 more rows
## # i abbreviated name:
## #   ¹`Rechtskreis Insgesamt - Bestand an Arbeitslosen - Gesamt...4`
## # i 20 more variables: ...8 <chr>, ...9 <chr>, ...10 <chr>, ...11 <chr>,
## #   ...12 <chr>, ...13 <chr>, ...14 <chr>, ...15 <chr>,
## #   `Rechtskreis Insgesamt - Bestand an Arbeitslosen - Gesamt...16` <chr>,
## #   ...17 <chr>, ...18 <chr>, ...19 <chr>, ...20 <chr>, ...21 <chr>, …
```

```r
alo_skip <- read_xlsx(alo_name, sheet = "Gesamt", sk

alo_skip %>%
  select(c(`...1`, Jahresdurchschnitte, `...3`))
```

```
## # A tibble: 11,233 × 3
##    ...1                          Jahresdurchschnitte ...3
##    <chr>                         <chr>               <chr>
##  1 <NA>                          Jahresdurch-schnitt Jahresdurch-schnitt
##  2 Region                        2020                2021
##  3 Deutschland                   2695444.0833333335  2613489
##  4 01 Schleswig-Holstein         92139.666666666672  88864.75
##  5 01001 Flensburg, Stadt        4721.75             4369.166666666667
##  6 01001000 Flensburg, Stadt     4721.75             4369.166666666667
##  7 01002 Kiel, Landeshauptstadt  11776.166666666666  11096.833333333334
##  8 01002000 Kiel, Landeshauptstadt 11776.166666666666 11096.833333333334
##  9 01003 Lübeck, Hansestadt      9404                9346.9166666666661
## 10 01003000 Lübeck, Hansestadt   9404                9346.9166666666661
## # i 11,223 more rows
```

```r
alo_skip <- read_xlsx(alo_name, sheet = "Gesamt", sk

alo_skip %>%
  select(c(`...1`, Jahresdurchschnitte, `...3`)) %>%
  mutate(Regionalschluessel = str_extract(`...1`, "[
         Gemeinde = str_extract(`...1`, "[A-Z].*"))
```

```
## # A tibble: 11,233 × 5
##    ...1                    Jahresdurchschnitte ...3  Regionalschluessel Gemeir
##    <chr>                   <chr>               <chr> <chr>              <chr>
##  1 <NA>                    Jahresdurch-schnitt Jahr… <NA>               <NA>
##  2 Region                  2020                2021  <NA>               Regior
##  3 Deutschland             2695444.0833333335  2613… <NA>               Deutsc
##  4 01 Schleswig-Holstein   92139.666666666672  8886… 01                 Schles
##  5 01001 Flensburg, Stadt  4721.75             4369… 01001              Flensb
##  6 01001000 Flensburg, St… 4721.75             4369… 01001000           Flensb
##  7 01002 Kiel, Landeshaup… 11776.166666666666  1109… 01002              Kiel,
##  8 01002000 Kiel, Landesh… 11776.166666666666  1109… 01002000           Kiel,
##  9 01003 Lübeck, Hansesta… 9404                9346… 01003              Lübeck
## 10 01003000 Lübeck, Hanse… 9404                9346… 01003000           Lübeck
## # i 11,223 more rows
```

```r
alo_skip <- read_xlsx(alo_name, sheet = "Gesamt", sk

alo_skip %>%
  select(c(`...1`, Jahresdurchschnitte, `...3`)) %>%
  mutate(Regionalschluessel = str_extract(`...1`, "[
         Gemeinde = str_extract(`...1`, "[A-Z].*"))
  mutate(alo = as.numeric(`...3`))
```

```
## # A tibble: 11,233 × 6
##    ...1            Jahresdurchschnitte ...3  Regionalschluessel Gemeinde     a
##    <chr>           <chr>               <chr> <chr>              <chr>      <db
##  1 <NA>            Jahresdurch-schnitt Jahr… <NA>               <NA>     NA
##  2 Region          2020                2021  <NA>               Region    2.02
##  3 Deutschland     2695444.0833333335  2613… <NA>               Deutsch…  2.61
##  4 01 Schleswig-H… 92139.666666666672  8886… 01                 Schlesw…  8.89
##  5 01001 Flensbur… 4721.75             4369… 01001              Flensbu…  4.37
##  6 01001000 Flens… 4721.75             4369… 01001000           Flensbu…  4.37
##  7 01002 Kiel, La… 11776.166666666666  1109… 01002              Kiel, L…  1.11
##  8 01002000 Kiel,… 11776.166666666666  1109… 01002000           Kiel, L…  1.11
##  9 01003 Lübeck, … 9404                9346… 01003              Lübeck,…  9.35
## 10 01003000 Lübec… 9404                9346… 01003000           Lübeck,…  9.35
## # i 11,223 more rows
```

```r
alo_skip <- read_xlsx(alo_name, sheet = "Gesamt", sk

alo_skip %>%
  select(c(`...1`, Jahresdurchschnitte, `...3`)) %>%
  mutate(Regionalschluessel = str_extract(`...1`, "[
         Gemeinde = str_extract(`...1`, "[A-Z].*"))
  mutate(alo = as.numeric(`...3`)) %>%
  select(-c(`...1`, Jahresdurchschnitte, `...3`))
```

```
## # A tibble: 11,233 × 3
##    Regionalschluessel Gemeinde                  alo
##    <chr>              <chr>                   <dbl>
##  1 <NA>               <NA>                     NA
##  2 <NA>               Region                 2021
##  3 <NA>               Deutschland         2613489
##  4 01                 Schleswig-Holstein    88865.
##  5 01001              Flensburg, Stadt       4369.
##  6 01001000           Flensburg, Stadt       4369.
##  7 01002              Kiel, Landeshauptstadt 11097.
##  8 01002000           Kiel, Landeshauptstadt 11097.
##  9 01003              Lübeck, Hansestadt      9347.
## 10 01003000           Lübeck, Hansestadt      9347.
## # i 11,223 more rows
```

```r
alo_skip <- read_xlsx(alo_name, sheet = "Gesamt", sk

alo_skip %>%
  select(c(`...1`, Jahresdurchschnitte, `...3`)) %>%
  mutate(Regionalschluessel = str_extract(`...1`, "[
         Gemeinde = str_extract(`...1`, "[A-Z].*"))
  mutate(alo = as.numeric(`...3`)) %>%
  select(-c(`...1`, Jahresdurchschnitte, `...3`)) %>
  filter(!is.na(alo))
```

```
## # A tibble: 11,182 × 3
##    Regionalschluessel Gemeinde                  alo
##    <chr>              <chr>                   <dbl>
##  1 <NA>               Region                   2021
##  2 <NA>               Deutschland           2613489
##  3 01                 Schleswig-Holstein      88865.
##  4 01001              Flensburg, Stadt         4369.
##  5 01001000           Flensburg, Stadt         4369.
##  6 01002              Kiel, Landeshauptstadt  11097.
##  7 01002000           Kiel, Landeshauptstadt  11097.
##  8 01003              Lübeck, Hansestadt       9347.
##  9 01003000           Lübeck, Hansestadt       9347.
## 10 01004              Neumünster, Stadt        3771.
## # i 11,172 more rows
```

```
alo_skip <- read_xlsx(alo_name, sheet = "Gesamt", sk

alo_skip %>%
  select(c(`...1`, Jahresdurchschnitte, `...3`)) %>%
  mutate(Regionalschluessel = str_extract(`...1`, "[
         Gemeinde = str_extract(`...1`, "[A-Z].*"))
  mutate(alo = as.numeric(`...3`)) %>%
  select(-c(`...1`, Jahresdurchschnitte, `...3`)) %>
  filter(!is.na(alo))
```

```
## # A tibble: 11,182 × 3
##    Regionalschluessel Gemeinde                    alo
##    <chr>              <chr>                     <dbl>
##  1 <NA>               Region                     2021
##  2 <NA>               Deutschland             2613489
##  3 01                 Schleswig-Holstein       88865.
##  4 01001              Flensburg, Stadt          4369.
##  5 01001000           Flensburg, Stadt          4369.
##  6 01002              Kiel, Landeshauptstadt   11097.
##  7 01002000           Kiel, Landeshauptstadt   11097.
##  8 01003              Lübeck, Hansestadt        9347.
##  9 01003000           Lübeck, Hansestadt        9347.
## 10 01004              Neumünster, Stadt         3771.
## # i 11,172 more rows
```

```
#Abspeichern als Datensatz data_alo

data_alo <- alo_skip %>%
  select(c(`...1`, Jahresdurchschnitte, `...3`)) %>%
  mutate(Regionalschluessel = str_extract(`...1`, "[[:digit:]]+"),
         Gemeinde = str_extract(`...1`, "[A-Z].*")) %>%
  mutate(alo = as.numeric(`...3`)) %>%
  select(-c(`...1`, Jahresdurchschnitte, `...3`)) %>%
  filter(!is.na(alo))

data_alo <- data_alo[-c(1,2),]
```

Konsistenzcheck

- Machen die Angaben Sinn und sind die Daten in sich konsistent?
- Externe Datenquelle suchen und intern auf konsistenz prüfen.
- Informationen aggregieren und mit anderen Quellen vergleichen

Konsistenzcheck

- Machen die Angaben Sinn und sind die Daten in sich konsistent?
- Externe Datenquelle suchen und intern auf konsistenz prüfen.
- Informationen aggregieren und mit anderen Quellen vergleichen
- Zunächst: Anzahl an Arbeitslosen für jedes **Bundesland** in 2021.
  - zweistelligen `Regionalschluessel`
  - "Buchstaben" für jeden `Regionalschluessel` zählen (`nchar()` (number of characters))
- **Alternative Datenquelle:** Die Anzahl der Arbeitslosen für das Jahr 2021 unterteilt nach Ländern der Arbeitsagentur
  - Wichtig: Tabellenblatt 8

```
data_alo
```

```
## # A tibble: 11,180 × 3
##    Regionalschluessel Gemeinde                 alo
##    <chr>              <chr>                  <dbl>
##  1 01                 Schleswig-Holstein     88865.
##  2 01001              Flensburg, Stadt        4369.
##  3 01001000           Flensburg, Stadt        4369.
##  4 01002              Kiel, Landeshauptstadt 11097.
##  5 01002000           Kiel, Landeshauptstadt 11097.
##  6 01003              Lübeck, Hansestadt      9347.
##  7 01003000           Lübeck, Hansestadt      9347.
##  8 01004              Neumünster, Stadt       3771.
##  9 01004000           Neumünster, Stadt       3771.
## 10 01051              Dithmarschen            4143.
## # i 11,170 more rows
```

```
data_alo %>%
  filter(nchar(Regionalschluessel) == 2)
```

```
## # A tibble: 16 × 3
##    Regionalschluessel Gemeinde                 alo
##    <chr>              <chr>                  <dbl>
##  1 01                 Schleswig-Holstein     88865.
##  2 02                 Hamburg                80395.
##  3 03                 Niedersachsen         243021.
##  4 04                 Bremen                 39292.
##  5 05                 Nordrhein-Westfalen   718220.
##  6 06                 Hessen                178086.
##  7 07                 Rheinland-Pfalz       112137.
##  8 08                 Baden-Württemberg     247774.
##  9 09                 Bayern                262186.
## 10 10                 Saarland               36156.
## 11 11                 Berlin                198401.
## 12 12                 Brandenburg            78463.
## 13 13                 Mecklenburg-Vorpommern 62410.
## 14 14                 Sachsen               124743.
## 15 15                 Sachsen-Anhalt         81093.
## 16 16                 Thüringen              62249.
```

```r
data_alo %>%
  filter(nchar(Regionalschluessel) == 2) %>%
  rename(bundesland = Regionalschluessel)
```

```
## # A tibble: 16 × 3
##    bundesland Gemeinde                   alo
##    <chr>      <chr>                    <dbl>
##  1 01         Schleswig-Holstein      88865.
##  2 02         Hamburg                 80395.
##  3 03         Niedersachsen          243021.
##  4 04         Bremen                  39292.
##  5 05         Nordrhein-Westfalen    718220.
##  6 06         Hessen                 178086.
##  7 07         Rheinland-Pfalz        112137.
##  8 08         Baden-Württemberg      247774.
##  9 09         Bayern                 262186.
## 10 10         Saarland                36156.
## 11 11         Berlin                 198401.
## 12 12         Brandenburg             78463.
## 13 13         Mecklenburg-Vorpommern  62410.
## 14 14         Sachsen                124743.
## 15 15         Sachsen-Anhalt          81093.
## 16 16         Thüringen               62249.
```

```r
# Abspeichern als check_alo_bundesland

check_alo_bundesland <- data_alo %>%
  filter(nchar(Regionalschluessel) == 2) %>%
  rename(bundesland = Regionalschluessel)
```

```
check_alo_bundesland
```

```
## # A tibble: 16 × 3
##    bundesland Gemeinde                  alo
##    <chr>      <chr>                   <dbl>
##  1 01         Schleswig-Holstein      88865.
##  2 02         Hamburg                 80395.
##  3 03         Niedersachsen          243021.
##  4 04         Bremen                  39292.
##  5 05         Nordrhein-Westfalen    718220.
##  6 06         Hessen                 178086.
##  7 07         Rheinland-Pfalz        112137.
##  8 08         Baden-Württemberg      247774.
##  9 09         Bayern                 262186.
## 10 10         Saarland                36156.
## 11 11         Berlin                 198401.
## 12 12         Brandenburg             78463.
## 13 13         Mecklenburg-Vorpommern  62410.
## 14 14         Sachsen                124743.
## 15 15         Sachsen-Anhalt          81093.
## 16 16         Thüringen               62249.
```

```
include_graphics("./figs/Alo_Laender.png")
```

Deutschland und Länder
Berichtsjahr: 2021

Region	Insgesamt		Be
	absolut	Anteil in %	
	1	2	
Deutschland	2.613.489	100	
Westdeutschland	2.006.132	76,8	
Ostdeutschland	607.357	23,2	
01 Schleswig-Holstein	88.865	3,4	
02 Hamburg	80.395	3,1	
03 Niedersachsen	243.021	9,3	
04 Bremen	39.292	1,5	
05 Nordrhein-Westfalen	718.220	27,5	
06 Hessen	178.086	6,8	
07 Rheinland-Pfalz	112.137	4,3	
08 Baden-Württemberg	247.774	9,5	
09 Bayern	262.186	10,0	
10 Saarland	36.156	1,4	
11 Berlin	198.401	7,6	
12 Brandenburg	78.463	3,0	
13 Mecklenburg-Vorpommern	62.410	2,4	
14 Sachsen	124.743	4,8	
15 Sachsen-Anhalt	81.093	3,1	
16 Thüringen	62.249	2,4	

```
check_alo_bundesland
```

```
## # A tibble: 16 × 3
##    bundesland Gemeinde                  alo
##    <chr>      <chr>                   <dbl>
##  1 01         Schleswig-Holstein      88865.
##  2 02         Hamburg                 80395.
##  3 03         Niedersachsen          243021.
##  4 04         Bremen                  39292.
##  5 05         Nordrhein-Westfalen    718220.
##  6 06         Hessen                 178086.
##  7 07         Rheinland-Pfalz        112137.
##  8 08         Baden-Württemberg      247774.
##  9 09         Bayern                 262186.
## 10 10         Saarland                36156.
## 11 11         Berlin                 198401.
## 12 12         Brandenburg             78463.
## 13 13         Mecklenburg-Vorpommern  62410.
## 14 14         Sachsen                124743.
## 15 15         Sachsen-Anhalt          81093.
## 16 16         Thüringen               62249.
```

```
include_graphics("./figs/Alo_Laender.png")
```

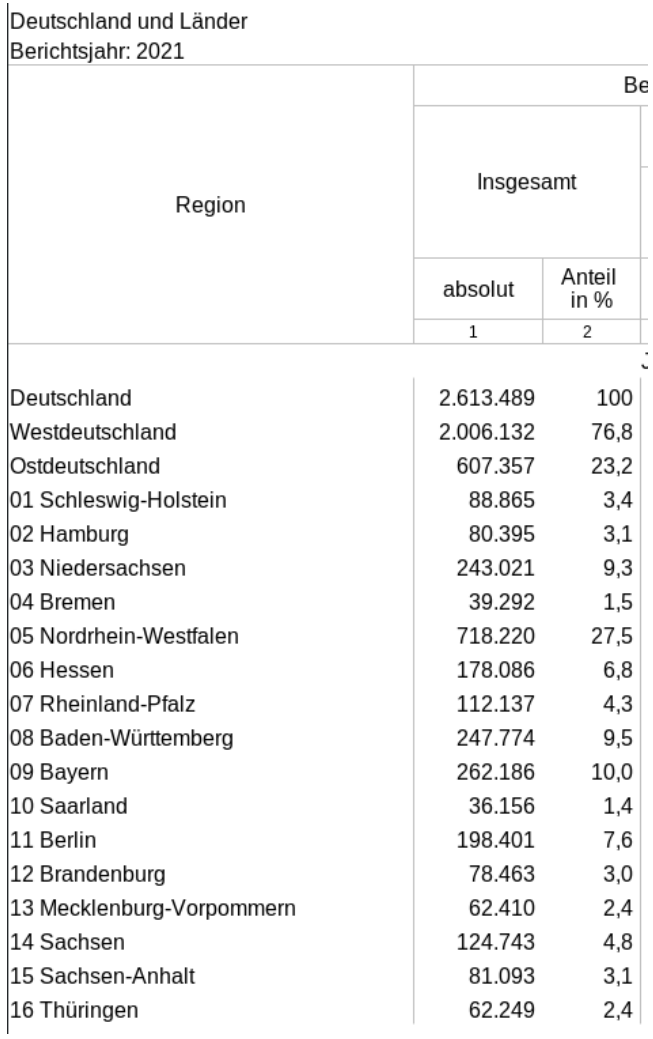

Deutschland und Länder
Berichtsjahr: 2021

Region	Insgesamt		Be
	absolut	Anteil in %	
	1	2	
Deutschland	2.613.489	100	
Westdeutschland	2.006.132	76,8	
Ostdeutschland	607.357	23,2	
01 Schleswig-Holstein	88.865	3,4	
02 Hamburg	80.395	3,1	
03 Niedersachsen	243.021	9,3	
04 Bremen	39.292	1,5	
05 Nordrhein-Westfalen	718.220	27,5	
06 Hessen	178.086	6,8	
07 Rheinland-Pfalz	112.137	4,3	
08 Baden-Württemberg	247.774	9,5	
09 Bayern	262.186	10,0	
10 Saarland	36.156	1,4	
11 Berlin	198.401	7,6	
12 Brandenburg	78.463	3,0	
13 Mecklenburg-Vorpommern	62.410	2,4	
14 Sachsen	124.743	4,8	
15 Sachsen-Anhalt	81.093	3,1	
16 Thüringen	62.249	2,4	

Beide Datenreihen sind identisch

INTERNE KONSISTENZ ÜBERPRÜFEN

Berechne: Anzahl an Arbeitslosen für jedes Bundesland als Summe der Arbeitslosen einer Gemeinde.

```
# Nur Gemeindedaten nutzen, dann auf Bundeslandebende die Summe aus den Gemeindedaten berechnen
alo_meta <- data_alo %>%
  filter(nchar(Regionalschluessel) == 8) %>%
  mutate(landkreis = str_extract(Regionalschluessel, "^.{5}"),
         bundesland = str_extract(Regionalschluessel, "^.{2}"))

alo_bundesland <- alo_meta %>%
  group_by(bundesland) %>%
  summarise(total_alo = sum(alo))

alo_landkreis <- alo_meta %>%
  group_by(landkreis) %>%
  summarise(total_alo = sum(alo)) %>%
  rename(Regionalschluessel = landkreis)
```

```
data_alo
```

```
## # A tibble: 11,180 × 3
##    Regionalschluessel Gemeinde                 alo
##    <chr>              <chr>                  <dbl>
##  1 01                 Schleswig-Holstein     88865.
##  2 01001              Flensburg, Stadt        4369.
##  3 01001000           Flensburg, Stadt        4369.
##  4 01002              Kiel, Landeshauptstadt 11097.
##  5 01002000           Kiel, Landeshauptstadt 11097.
##  6 01003              Lübeck, Hansestadt      9347.
##  7 01003000           Lübeck, Hansestadt      9347.
##  8 01004              Neumünster, Stadt       3771.
##  9 01004000           Neumünster, Stadt       3771.
## 10 01051              Dithmarschen            4143.
## # i 11,170 more rows
```

```r
data_alo %>%
  filter(nchar(Regionalschluessel) == 8)
```

```
## # A tibble: 10,741 × 3
##    Regionalschluessel Gemeinde                    alo
##    <chr>              <chr>                     <dbl>
##  1 01001000           Flensburg, Stadt         4369.
##  2 01002000           Kiel, Landeshauptstadt  11097.
##  3 01003000           Lübeck, Hansestadt       9347.
##  4 01004000           Neumünster, Stadt        3771.
##  5 01051001           Albersdorf                122.
##  6 01051002           Arkebek                     5.17
##  7 01051003           Averlak                     8.08
##  8 01051004           Bargenstedt                11.2
##  9 01051005           Barkenholm                  1.58
## 10 01051006           Barlt                      17.7
## # i 10,731 more rows
```

```r
data_alo %>%
  filter(nchar(Regionalschluessel) == 8) %>%
  mutate(landkreis = str_extract(Regionalschluessel,
```

```
## # A tibble: 10,741 × 4
##    Regionalschluessel Gemeinde                    alo landkreis
##    <chr>              <chr>                     <dbl> <chr>
##  1 01001000           Flensburg, Stadt         4369.  01001
##  2 01002000           Kiel, Landeshauptstadt  11097.  01002
##  3 01003000           Lübeck, Hansestadt       9347.  01003
##  4 01004000           Neumünster, Stadt        3771.  01004
##  5 01051001           Albersdorf                122.  01051
##  6 01051002           Arkebek                     5.17 01051
##  7 01051003           Averlak                     8.08 01051
##  8 01051004           Bargenstedt                11.2  01051
##  9 01051005           Barkenholm                  1.58 01051
## 10 01051006           Barlt                      17.7  01051
## # i 10,731 more rows
```

```r
data_alo %>%
  filter(nchar(Regionalschluessel) == 8) %>%
  mutate(landkreis = str_extract(Regionalschluessel,
  mutate(bundesland = str_extract(Regionalschluessel
```

```
## # A tibble: 10,741 × 5
##    Regionalschluessel Gemeinde                    alo landkreis bundesland
##    <chr>              <chr>                     <dbl> <chr>     <chr>
##  1 01001000           Flensburg, Stadt         4369.  01001     01
##  2 01002000           Kiel, Landeshauptstadt  11097.  01002     01
##  3 01003000           Lübeck, Hansestadt       9347.  01003     01
##  4 01004000           Neumünster, Stadt        3771.  01004     01
##  5 01051001           Albersdorf                122.  01051     01
##  6 01051002           Arkebek                     5.17 01051     01
##  7 01051003           Averlak                     8.08 01051     01
##  8 01051004           Bargenstedt                11.2  01051     01
##  9 01051005           Barkenholm                  1.58 01051     01
## 10 01051006           Barlt                      17.7  01051     01
## # i 10,731 more rows
```

```
data_alo %>%
  filter(nchar(Regionalschluessel) == 8) %>%
  mutate(landkreis = str_extract(Regionalschluessel,
  mutate(bundesland = str_extract(Regionalschluessel
alo_meta
```

```
alo_meta
```

```
## # A tibble: 10,741 × 5
##    Regionalschluessel Gemeinde                    alo landkreis bundesland
##    <chr>              <chr>                     <dbl> <chr>     <chr>
##  1 01001000           Flensburg, Stadt         4369.  01001     01
##  2 01002000           Kiel, Landeshauptstadt  11097.  01002     01
##  3 01003000           Lübeck, Hansestadt       9347.  01003     01
##  4 01004000           Neumünster, Stadt        3771.  01004     01
##  5 01051001           Albersdorf                122.  01051     01
##  6 01051002           Arkebek                     5.17 01051     01
##  7 01051003           Averlak                     8.08 01051     01
##  8 01051004           Bargenstedt                11.2  01051     01
##  9 01051005           Barkenholm                  1.58 01051     01
## 10 01051006           Barlt                      17.7  01051     01
## # i 10,731 more rows
```

```
alo_meta %>%
  group_by(bundesland)
```

```
## # A tibble: 10,741 × 5
## # Groups:   bundesland [16]
##    Regionalschluessel Gemeinde                    alo landkreis bundesland
##    <chr>              <chr>                     <dbl> <chr>     <chr>
##  1 01001000           Flensburg, Stadt         4369.  01001     01
##  2 01002000           Kiel, Landeshauptstadt  11097.  01002     01
##  3 01003000           Lübeck, Hansestadt       9347.  01003     01
##  4 01004000           Neumünster, Stadt        3771.  01004     01
##  5 01051001           Albersdorf                122.  01051     01
##  6 01051002           Arkebek                     5.17 01051     01
##  7 01051003           Averlak                     8.08 01051     01
##  8 01051004           Bargenstedt                11.2  01051     01
##  9 01051005           Barkenholm                  1.58 01051     01
## 10 01051006           Barlt                      17.7  01051     01
## # i 10,731 more rows
```

```r
alo_meta %>%
  group_by(bundesland) %>%
  summarise(total_alo = sum(alo))
```

```
## # A tibble: 16 × 2
##    bundesland total_alo
##    <chr>          <dbl>
##  1 01             88865.
##  2 02             80395.
##  3 03            243021.
##  4 04             39292.
##  5 05            718220.
##  6 06            178086.
##  7 07            112137.
##  8 08            247774.
##  9 09            262186.
## 10 10             36156.
## 11 11            198401.
## 12 12             78463.
## 13 13             62410.
## 14 14            124743.
## 15 15             81093.
## 16 16             62249.
```

```
alo_meta %>%
  group_by(bundesland) %>%
  summarise(total_alo = sum(alo)) ->
alo_bundesland
```

```
alo_meta
```

```
## # A tibble: 10,741 × 5
##    Regionalschluessel Gemeinde                    alo landkreis bundesland
##    <chr>              <chr>                     <dbl> <chr>     <chr>
##  1 01001000           Flensburg, Stadt         4369.  01001     01
##  2 01002000           Kiel, Landeshauptstadt  11097.  01002     01
##  3 01003000           Lübeck, Hansestadt       9347.  01003     01
##  4 01004000           Neumünster, Stadt        3771.  01004     01
##  5 01051001           Albersdorf                122.  01051     01
##  6 01051002           Arkebek                     5.17 01051     01
##  7 01051003           Averlak                     8.08 01051     01
##  8 01051004           Bargenstedt                11.2  01051     01
##  9 01051005           Barkenholm                  1.58 01051     01
## 10 01051006           Barlt                      17.7  01051     01
## # i 10,731 more rows
```

```r
alo_meta %>%
  group_by(landkreis)
```

```
## # A tibble: 10,741 × 5
## # Groups:   landkreis [400]
##    Regionalschluessel Gemeinde                    alo landkreis bundesland
##    <chr>              <chr>                     <dbl> <chr>     <chr>
##  1 01001000           Flensburg, Stadt         4369.  01001     01
##  2 01002000           Kiel, Landeshauptstadt  11097.  01002     01
##  3 01003000           Lübeck, Hansestadt       9347.  01003     01
##  4 01004000           Neumünster, Stadt        3771.  01004     01
##  5 01051001           Albersdorf                122.  01051     01
##  6 01051002           Arkebek                     5.17 01051     01
##  7 01051003           Averlak                     8.08 01051     01
##  8 01051004           Bargenstedt                11.2  01051     01
##  9 01051005           Barkenholm                  1.58 01051     01
## 10 01051006           Barlt                      17.7  01051     01
## # i 10,731 more rows
```

```r
alo_meta %>%
  group_by(landkreis) %>%
  summarise(total_alo = sum(alo))
```

```
## # A tibble: 400 × 2
##    landkreis total_alo
##    <chr>         <dbl>
##  1 01001         4369.
##  2 01002        11097.
##  3 01003         9347.
##  4 01004         3771.
##  5 01051         4143.
##  6 01053         5603.
##  7 01054         4699
##  8 01055         5371
##  9 01056         9371.
## 10 01057         2854.
## # i 390 more rows
```

```r
alo_meta %>%
  group_by(landkreis) %>%
  summarise(total_alo = sum(alo)) %>%
  rename(Regionalschluessel = landkreis)
```

```
## # A tibble: 400 × 2
##    Regionalschluessel total_alo
##    <chr>                   <dbl>
##  1 01001                   4369.
##  2 01002                  11097.
##  3 01003                   9347.
##  4 01004                   3771.
##  5 01051                   4143.
##  6 01053                   5603.
##  7 01054                   4699
##  8 01055                   5371
##  9 01056                   9371.
## 10 01057                   2854.
## # i 390 more rows
```

```
alo_meta %>%
  group_by(landkreis) %>%
  summarise(total_alo = sum(alo)) %>%
  rename(Regionalschluessel = landkreis) ->
alo_landkreis
```

INTERNE KONSISTENZ ÜBERPRÜFEN

Wir wollen nun die zwei Tabellen miteinander verbinden (besserer Überblick)

- Datensatz `check_alo_bundeland`: Auf Bundesland aggregierte Zahlen der Arbeitslosigkeit aus den Gemeinden
- Datessatz `alo_bundesland`: Die schon von der Arbeitsagentur aggregierte Zahlen in unserem Datensatz

```
left_join(check_alo_bundesland, alo_bundesland, by =
```

```
## # A tibble: 16 × 4
##    bundesland Gemeinde                   alo total_alo
##    <chr>      <chr>                    <dbl>     <dbl>
##  1 01         Schleswig-Holstein      88865.    88865.
##  2 02         Hamburg                 80395.    80395.
##  3 03         Niedersachsen          243021.   243021.
##  4 04         Bremen                  39292.    39292.
##  5 05         Nordrhein-Westfalen    718220.   718220.
##  6 06         Hessen                 178086.   178086.
##  7 07         Rheinland-Pfalz        112137.   112137.
##  8 08         Baden-Württemberg      247774.   247774.
##  9 09         Bayern                 262186.   262186.
## 10 10         Saarland                36156.    36156.
## 11 11         Berlin                 198401.   198401.
## 12 12         Brandenburg             78463.    78463.
## 13 13         Mecklenburg-Vorpommern  62410.    62410.
## 14 14         Sachsen                124743.   124743.
## 15 15         Sachsen-Anhalt          81093.    81093.
## 16 16         Thüringen               62249.    62249.
```

```
left_join(check_alo_bundesland, alo_bundesland, by =
  check_consitency
```

```
left_join(check_alo_bundesland, alo_bundesland, by =
  check_consitency

check_consitency
```

```
## # A tibble: 16 × 4
##    bundesland Gemeinde                   alo total_alo
##    <chr>      <chr>                    <dbl>     <dbl>
##  1 01         Schleswig-Holstein      88865.    88865.
##  2 02         Hamburg                 80395.    80395.
##  3 03         Niedersachsen          243021.   243021.
##  4 04         Bremen                  39292.    39292.
##  5 05         Nordrhein-Westfalen    718220.   718220.
##  6 06         Hessen                 178086.   178086.
##  7 07         Rheinland-Pfalz        112137.   112137.
##  8 08         Baden-Württemberg      247774.   247774.
##  9 09         Bayern                 262186.   262186.
## 10 10         Saarland                36156.    36156.
## 11 11         Berlin                 198401.   198401.
## 12 12         Brandenburg             78463.    78463.
## 13 13         Mecklenburg-Vorpommern  62410.    62410.
## 14 14         Sachsen                124743.   124743.
## 15 15         Sachsen-Anhalt          81093.    81093.
## 16 16         Thüringen               62249.    62249.
```

```r
left_join(check_alo_bundesland, alo_bundesland, by =
  check_consitency

check_consitency %>%
  mutate(diff = alo - total_alo)
```

```
## # A tibble: 16 × 5
##    bundesland Gemeinde                  alo total_alo  diff
##    <chr>      <chr>                   <dbl>     <dbl> <dbl>
##  1 01         Schleswig-Holstein      88865.    88865.     0
##  2 02         Hamburg                 80395.    80395.     0
##  3 03         Niedersachsen          243021.   243021.     0
##  4 04         Bremen                  39292.    39292.     0
##  5 05         Nordrhein-Westfalen    718220.   718220.     0
##  6 06         Hessen                 178086.   178086.     0
##  7 07         Rheinland-Pfalz        112137.   112137.     0
##  8 08         Baden-Württemberg      247774.   247774.     0
##  9 09         Bayern                 262186.   262186.     0
## 10 10         Saarland                36156.    36156.     0
## 11 11         Berlin                 198401.   198401.     0
## 12 12         Brandenburg             78463.    78463.     0
## 13 13         Mecklenburg-Vorpommern  62410.    62410.     0
## 14 14         Sachsen                124743.   124743.     0
## 15 15         Sachsen-Anhalt          81093.    81093.     0
## 16 16         Thüringen               62249.    62249.     0
```

```
left_join(check_alo_bundesland, alo_bundesland, by =
  check_consitency

check_consitency %>%
  mutate(diff = alo - total_alo)
```

```
## # A tibble: 16 × 5
##    bundesland Gemeinde                  alo total_alo  diff
##    <chr>      <chr>                   <dbl>     <dbl> <dbl>
##  1 01         Schleswig-Holstein      88865.    88865.     0
##  2 02         Hamburg                 80395.    80395.     0
##  3 03         Niedersachsen          243021.   243021.     0
##  4 04         Bremen                  39292.    39292.     0
##  5 05         Nordrhein-Westfalen    718220.   718220.     0
##  6 06         Hessen                 178086.   178086.     0
##  7 07         Rheinland-Pfalz        112137.   112137.     0
##  8 08         Baden-Württemberg      247774.   247774.     0
##  9 09         Bayern                 262186.   262186.     0
## 10 10         Saarland                36156.    36156.     0
## 11 11         Berlin                 198401.   198401.     0
## 12 12         Brandenburg             78463.    78463.     0
## 13 13         Mecklenburg-Vorpommern  62410.    62410.     0
## 14 14         Sachsen                124743.   124743.     0
## 15 15         Sachsen-Anhalt          81093.    81093.     0
## 16 16         Thüringen               62249.    62249.     0
```

Es bestehen keine Unstimmigkeiten.

Pro-Kopf Verschuldung

Pro-Kopf Verschuldung auf Gemeindeebene

- ✚ Auf Gemeindeebene aus dem Jahr 2021
- ✚ Querschnittsdaten
- ✚ Vom Statistischen Bundesamt direkt als Excel-Tabelle heruntergeladen (✔️)

> Welche Tabellenblätter sollten wir nutzen?

```
excel_sheets("../case-study/data/Schulden_2021.xlsx")
```

```
##  [1] "Titel"              "Impressum"          "Inhalt"
##  [4] "Abkürzungen"        "Erläuterungen"      "SH"
##  [7] "NI"                 "NW"                 "HE"
## [10] "RP"                 "BW"                 "BY"
## [13] "SL"                 "BB"                 "MV"
## [16] "SN"                 "ST"                 "TH"
## [19] "Statistische Ämter"
```

Mehrere Tabellenblätter einlesen

- Nicht alle Informationen in **einem Tabellenblatt** enthalten
  - Viele separate Tabellenblätter
  - Hier kommt die `for`-Schleife zum Einsatz

Mehrere Tabellenblätter einlesen

- Nicht alle Informationen in **einem Tabellenblatt** enthalten
  - Viele separate Tabellenblätter
  - Hier kommt die `for`-Schleife zum Einsatz

> Zuerst schauen wir jedoch welche Informationen wir benötigen anhand eines Beispiels:

Mehrere Tabellenblätter einlesen

```
sh <- read_xlsx("../case-study/data/Schulden_2021.xlsx", sheet = "SH")
head(sh,20)
```

```
## # A tibble: 20 × 21
##    `Zurück zum Inhalt...1` ...2  ...3  ...4  ...5  ...6  ...7  ...8  ...9  ...10
##    <chr>                   <chr> <chr> <chr> <chr> <chr> <chr> <chr> <chr> <chr>
##  1  <NA>                   <NA>  <NA>   <NA> <NA>  <NA>   <NA> <NA>  <NA>  <NA>
##  2  <NA>                   <NA>  <NA>   <NA> <NA>  <NA>   <NA> <NA>  <NA>  <NA>
##  3 "Tabelle 1:    Schulde… <NA>  <NA>   <NA> <NA>  <NA>   <NA> <NA>  <NA>  <NA>
##  4 "nach Höhe der Beteili… <NA>  <NA>   <NA> <NA>  <NA>   <NA> <NA>  <NA>  <NA>
##  5 "Regional-\r\nschlüsse… Geme… Verw… "Ein… Schu… Verä… "Sch… Schu… <NA>  <NA>
##  6  <NA>                   <NA>  <NA>   <NA> <NA>  <NA>   <NA> zusa… Verä… Schu…
##  7  <NA>                   <NA>  <NA>   <NA> <NA>  <NA>   <NA> <NA>  <NA>  <NA>
##  8  <NA>                   <NA>  <NA>   <NA> <NA>  <NA>   <NA> <NA>  <NA>  <NA>
##  9  <NA>                   <NA>  <NA>   <NA> EUR   %      "EUR" <NA>  %     EUR
## 10  <NA>                   <NA>  <NA>   <NA> 1     2      "3"   4     5     6
## 11 "010010000000"          Flen… krei… "899… 4545… 0      "505… 2310… -9.5  4625…
## 12 "010020000000"          Kiel… krei… "245… 1039… 6.1    "422… 5534… 6.7   5531…
## 13 "010030000000"          Lübe… krei… "215… 1090… 1.2    "507… 4305… -5.9  4256…
## 14 "010040000000"          Neum… krei… "796… 4532… 5.2    "568… 1141… 10.6  1029…
## 15 "01051"                 Krei… Krei… "{13… 4296… -14.8  "322… 1954… -20.7 1952…
```

Mehrere Tabellenblätter einlesen

Wir benötigen:

- "Regionalschlüssel"
- "Gemeindename"
- "Einwohner"
- "Schuldes des öffentlichen Bereichs insgesamt"
- "Schulden je Einwohner"

Variablenbezeichnungen beginnen in Zeile 5, d.h. wir ignorieren die ersten 4 Zeilen beim Einlesen.

Was ist hier eine Beobachtung?

Mehrere Tabellenblätter einlesen

Der Übersicht halber wollen wir noch eine Spalte hinzufügen, welche den Namen des Tabellenblattes enthält, welches wir gerade eingelesen haben.

```
# Einlesen des Tabellenblattes "SH" ohne die ersten 5 Zeilen und nur die Spalten 1-7
schulden_individuell <- read_xlsx("../case-study/data/Schulden_2021.xlsx", sheet = "SH", skip = 5)[1:7]
# Umbenennen der ersten 7 Spalten
colnames(schulden_individuell) <- c("Regionalschluessel", "Gemeinde",
                                    "Verwaltungsform", "Einwohner", "Schulden_gesamt", "Veraenderung_Vorjahr"

# Zusätzliche Spalte hinzufügen mit dem Namen des Tabellenblattes
schulden_individuell$Bundesland <- "SH"
```

```r
# Einlesen des Tabellenblattes "SH" ohne die ersten
read_xlsx("../case-study/data/Schulden_2021.xlsx", s
```

```
## # A tibble: 1,310 × 7
##    `Regional-\r\nschlüssel` `Gemeinde/Gemeindeverband`   Verwaltungsform
##    <chr>                    <chr>                        <chr>
##  1 <NA>                     <NA>                         <NA>
##  2 <NA>                     <NA>                         <NA>
##  3 <NA>                     <NA>                         <NA>
##  4 <NA>                     <NA>                         <NA>
##  5 <NA>                     <NA>                         <NA>
##  6 010010000000             Flensburg, Stadt             kreisfreie Stadt
##  7 010020000000             Kiel, Landeshauptstadt       kreisfreie Stadt
##  8 010030000000             Lübeck, Hansestadt           kreisfreie Stadt
##  9 010040000000             Neumünster, Stadt            kreisfreie Stadt
## 10 01051                    Kreisverwaltung Dithmarschen Kreisverwaltung
## # i 1,300 more rows
## # i 4 more variables: `Einwohner/in\r\nam\r\n30.06.2021` <chr>,
## #   `Schulden des öffentlichen Bereichs insgesamt` <chr>,
## #   `Veränderung zum Vorjahr` <chr>, `Schulden je \r\nEinwohner/in` <chr>
```

```
# Einlesen des Tabellenblattes "SH" ohne die ersten
read_xlsx("../case-study/data/Schulden_2021.xlsx", s
  schulden_individuell
```

```
# Einlesen des Tabellenblattes "SH" ohne die ersten
read_xlsx("../case-study/data/Schulden_2021.xlsx", s
  schulden_individuell

# Umbenennen der ersten 7 Spalten
colnames(schulden_individuell) <- c("Regionalschlues
                                    "Verwaltungsform
```

```
# Einlesen des Tabellenblattes "SH" ohne die ersten
read_xlsx("../case-study/data/Schulden_2021.xlsx", s
  schulden_individuell

# Umbenennen der ersten 7 Spalten
colnames(schulden_individuell) <- c("Regionalschlues
                                    "Verwaltungsform

# Zusätzliche Spalte hinzufügen mit dem Namen des Ta
schulden_individuell$Bundesland <- "SH"
```

```r
# Einlesen des Tabellenblattes "SH" ohne die ersten
read_xlsx("../case-study/data/Schulden_2021.xlsx", s
  schulden_individuell

# Umbenennen der ersten 7 Spalten
colnames(schulden_individuell) <- c("Regionalschlues
                                    "Verwaltungsform

# Zusätzliche Spalte hinzufügen mit dem Namen des Ta
schulden_individuell$Bundesland <- "SH"

schulden_individuell
```

```
## # A tibble: 1,310 × 8
##    Regionalschluessel Gemeinde          Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>             <chr>           <chr>     <chr>
##  1 <NA>               <NA>              <NA>            <NA>      <NA>
##  2 <NA>               <NA>              <NA>            <NA>      <NA>
##  3 <NA>               <NA>              <NA>            <NA>      <NA>
##  4 <NA>               <NA>              <NA>            <NA>      EUR
##  5 <NA>               <NA>              <NA>            <NA>      1
##  6 010010000000       Flensburg, Stadt  kreisfreie Sta… 89949     454539445.970
##  7 010020000000       Kiel, Landeshau…  kreisfreie Sta… 245841    1039095143.43
##  8 010030000000       Lübeck, Hansest…  kreisfreie Sta… 215051    1090890891.45
##  9 010040000000       Neumünster, Sta…  kreisfreie Sta… 79683     453215674.299
## 10 01051              Kreisverwaltung…  Kreisverwaltung {133 401} 42967438.6200
## # i 1,300 more rows
## # i 3 more variables: Veraenderung_Vorjahr <chr>, Schulden_pro_kopf <chr>,
## #   Bundesland <chr>
```

Mehrere Tabellenblätter einlesen

Nun können wir genauso bei allen anderen Tabellenblättern vorgehen:

Mehrere Tabellenblätter einlesen

Nun können wir genauso bei allen anderen Tabellenblättern vorgehen:

```
# Daten mit for-Schleife einlesen (Struktur gleich wie im vorherigen Chunk)
sheet_names <- excel_sheets("../case-study/data/Schulden_2021.xlsx")
# Einlesen der Tabellenblätter 7-18 (alle Bundesländer)
sheet_read <- sheet_names[7:18]
for (i in 1:length(sheet_read)){
  tmp <- read_xlsx("../case-study/data/Schulden_2021.xlsx", sheet = sheet_read[i], skip = 5)[1:7]
   tmp$Bundesland <- sheet_read[i]
  colnames(tmp) <- c("Regionalschluessel", "Gemeinde", "Verwaltungsform",
                     "Einwohner", "Schulden_gesamt", "Veraenderung_Vorjahr", "Schulden_pro_kopf", "Bundesland
  # Daten aller weiteren Tabellenblätter unter den aktuellen Datensatz anheften
  schulden_individuell <- bind_rows(schulden_individuell, tmp)
}
```

Mehrere Tabellenblätter einlesen

Nun können wir genauso bei allen anderen Tabellenblättern vorgehen:

```
# Daten mit for-Schleife einlesen (Struktur gleich wie im vorherigen Chunk)
sheet_names <- excel_sheets("../case-study/data/Schulden_2021.xlsx")
# Einlesen der Tabellenblätter 7-18 (alle Bundesländer)
sheet_read <- sheet_names[7:18]
for (i in 1:length(sheet_read)){
  tmp <- read_xlsx("../case-study/data/Schulden_2021.xlsx", sheet = sheet_read[i], skip = 5)[1:7]
   tmp$Bundesland <- sheet_read[i]
  colnames(tmp) <- c("Regionalschluessel", "Gemeinde", "Verwaltungsform",
                     "Einwohner", "Schulden_gesamt", "Veraenderung_Vorjahr", "Schulden_pro_kopf", "Bundesland
  # Daten aller weiteren Tabellenblätter unter den aktuellen Datensatz anheften
  schulden_individuell <- bind_rows(schulden_individuell, tmp)
}
```

Mehrere Tabellenblätter einlesen

Nun können wir genauso bei allen anderen Tabellenblättern vorgehen:

```
# Daten mit for-Schleife einlesen (Struktur gleich wie im vorherigen Chunk)
sheet_names <- excel_sheets("../case-study/data/Schulden_2021.xlsx")
# Einlesen der Tabellenblätter 7-18 (alle Bundesländer)
sheet_read <- sheet_names[7:18]
for (i in 1:length(sheet_read)){
  tmp <- read_xlsx("../case-study/data/Schulden_2021.xlsx", sheet = sheet_read[i], skip = 5)[1:7]
   tmp$Bundesland <- sheet_read[i]
  colnames(tmp) <- c("Regionalschluessel", "Gemeinde", "Verwaltungsform",
                     "Einwohner", "Schulden_gesamt", "Veraenderung_Vorjahr", "Schulden_pro_kopf", "Bundesland
  # Daten aller weiteren Tabellenblätter unter den aktuellen Datensatz anheften
  schulden_individuell <- bind_rows(schulden_individuell, tmp)
}
```

Eine zusätzliche Spalte generieren, welche die Information pro Bundesland enthält

```
# Daten mit for-Schleife einlesen (Struktur gleich w
```

```
# Daten mit for-Schleife einlesen (Struktur gleich w
excel_sheets("../case-study/data/Schulden_2021.xlsx"
```

```
##  [1] "Titel"              "Impressum"          "Inhalt"
##  [4] "Abkürzungen"        "Erläuterungen"      "SH"
##  [7] "NI"                 "NW"                 "HE"
## [10] "RP"                 "BW"                 "BY"
## [13] "SL"                 "BB"                 "MV"
## [16] "SN"                 "ST"                 "TH"
## [19] "Statistische Ämter"
```

```
# Daten mit for-Schleife einlesen (Struktur gleich w
excel_sheets("../case-study/data/Schulden_2021.xlsx"
  sheet_names
```

```
# Daten mit for-Schleife einlesen (Struktur gleich w
excel_sheets("../case-study/data/Schulden_2021.xlsx"
  sheet_names

# Einlesen der Tabellenblätter 7-18 (alle Bundesländ
```

```r
# Daten mit for-Schleife einlesen (Struktur gleich w
excel_sheets("../case-study/data/Schulden_2021.xlsx"
  sheet_names

# Einlesen der Tabellenblätter 7-18 (alle Bundesländ
sheet_names[7:18]
```

```
##  [1] "NI" "NW" "HE" "RP" "BW" "BY" "SL" "BB" "MV" "SN" "ST" "TH"
```

```
# Daten mit for-Schleife einlesen (Struktur gleich w
excel_sheets("../case-study/data/Schulden_2021.xlsx"
  sheet_names

# Einlesen der Tabellenblätter 7-18 (alle Bundesländ
sheet_names[7:18] ->
  sheet_read
```

```
# Daten mit for-Schleife einlesen (Struktur gleich w
excel_sheets("../case-study/data/Schulden_2021.xlsx"
  sheet_names

# Einlesen der Tabellenblätter 7-18 (alle Bundesländ
sheet_names[7:18] ->
  sheet_read

length(sheet_read)
```

```
## [1] 12
```

```
# Daten mit for-Schleife einlesen (Struktur gleich w
excel_sheets("../case-study/data/Schulden_2021.xlsx"
  sheet_names

# Einlesen der Tabellenblätter 7-18 (alle Bundesländ
sheet_names[7:18] ->
  sheet_read

length(sheet_read)
```

```
for (i in 1:length(sheet_read)){
  tmp <- read_xlsx("../case-study/data/Schulden_2021
  tmp$Bundesland <- sheet_read[i]
  colnames(tmp) <- c("Regionalschluessel", "Gemeinde
                     "Einwohner", "Schulden_gesamt",
# Daten aller weiteren Tabellenblätter unter den akt
  schulden_individuell <- bind_rows(schulden_individ
}
```

```
## [1] 12
```

```r
# Daten mit for-Schleife einlesen (Struktur gleich w
excel_sheets("../case-study/data/Schulden_2021.xlsx"
  sheet_names

# Einlesen der Tabellenblätter 7-18 (alle Bundesländ
sheet_names[7:18] ->
  sheet_read

length(sheet_read)

for (i in 1:length(sheet_read)){
  tmp <- read_xlsx("../case-study/data/Schulden_2021
  tmp$Bundesland <- sheet_read[i]
  colnames(tmp) <- c("Regionalschluessel", "Gemeinde
                     "Einwohner", "Schulden_gesamt",
# Daten aller weiteren Tabellenblätter unter den akt
  schulden_individuell <- bind_rows(schulden_individ
}

schulden_individuell
```

```
## [1] 12
```

```
## # A tibble: 25,234 × 8
##    Regionalschluessel Gemeinde         Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>            <chr>           <chr>     <chr>
##  1 <NA>               <NA>             <NA>            <NA>      <NA>
##  2 <NA>               <NA>             <NA>            <NA>      <NA>
##  3 <NA>               <NA>             <NA>            <NA>      <NA>
##  4 <NA>               <NA>             <NA>            <NA>      EUR
##  5 <NA>               <NA>             <NA>            <NA>      1
##  6 010010000000       Flensburg, Stadt kreisfreie Sta… 89949     454539445.970
##  7 010020000000       Kiel, Landeshau… kreisfreie Sta… 245841    1039095143.43
##  8 010030000000       Lübeck, Hansest… kreisfreie Sta… 215051    1090890891.45
##  9 010040000000       Neumünster, Sta… kreisfreie Sta… 79683     453215674.299
## 10 01051              Kreisverwaltung… Kreisverwaltung {133 401} 42967438.6200
## # i 25,224 more rows
## # i 3 more variables: Veraenderung_Vorjahr <chr>, Schulden_pro_kopf <chr>,
## #   Bundesland <chr>
```

Variablen umformen

```
head(schulden_individuell,15)
```

```
## # A tibble: 15 × 8
##    Regionalschluessel Gemeinde         Verwaltungsform Einwohner Schulden_gesamt
##    <chr>              <chr>            <chr>           <chr>     <chr>
##  1 <NA>               <NA>             <NA>            <NA>      <NA>
##  2 <NA>               <NA>             <NA>            <NA>      <NA>
##  3 <NA>               <NA>             <NA>            <NA>      <NA>
##  4 <NA>               <NA>             <NA>            <NA>      EUR
##  5 <NA>               <NA>             <NA>            <NA>      1
##  6 010010000000       Flensburg, Stadt kreisfreie Sta… 89949     454539445.9700…
##  7 010020000000       Kiel, Landeshau… kreisfreie Sta… 245841    1039095143.430…
##  8 010030000000       Lübeck, Hansest… kreisfreie Sta… 215051    1090890891.450…
##  9 010040000000       Neumünster, Sta… kreisfreie Sta… 79683     453215674.2999…
## 10 01051              Kreisverwaltung… Kreisverwaltung {133 401} 42967438.62000…
## 11 010510011011       Brunsbüttel, St… amtsfreie Geme… 12324     54641169.33000…
## 12 010510044044       Heide, Stadt     amtsfreie Geme… 21515     42854871.67999…
## 13 010515163          Amtsverwaltung … Amtsverwaltung  {15 547}  850386.17
## 14 010515163003       Averlak          amtsangehörige… 554       1917334.710000…
## 15 010515163010       Brickeln         amtsangehörige… 200       1176540.52
## # i 3 more variables: Veraenderung_Vorjahr <chr>, Schulden_pro_kopf <chr>,
```

Variablen umformen

Wir sehen, es gibt immer noch einige Probleme:

- Die Werte unserer Variablen stehen nicht direkt unter dem Variablennamen
  - Dies können wir am einfachsten bereinigen indem wir alle `NA`s im Regionalschlüssel entfernen

Variablen umformen

Wir sehen, es gibt immer noch einige Probleme:

- Die Werte unserer Variablen stehen nicht direkt unter dem Variablennamen
  - Dies können wir am einfachsten bereinigen indem wir alle `NA`s im Regionalschlüssel entfernen
- Die Variablen "Einwohner", "Schulden_gesamt" und "Schulden_pro_Kopf" sind alle als `character` hinterlegt (`<chr>` unter dem Variablennamen in der vorherigen Tabelle)
  - Beispiel warum Klasse `character` (Zeile 28): Es sind geschweifte Klammern enthalten

```
schulden_individuell[28,]
```

```
## # A tibble: 1 × 8
##   Regionalschluessel   Gemeinde        Verwaltungsform Einwohner Schulden_gesamt
##   <chr>                <chr>           <chr>           <chr>     <chr>
## 1 010515163_Summe(Amt) Amt Burg-St. M… Amtsgebiet      {15 547}  {35 628 306}
## # i 3 more variables: Veraenderung_Vorjahr <chr>, Schulden_pro_kopf <chr>,
## #   Bundesland <chr>
```

Variablen umformen

Wir sehen, es gibt immer noch einige Probleme:

- Die Werte unserer Variablen stehen nicht direkt unter dem Variablennamen
  - Dies können wir am einfachsten bereinigen indem wir alle `NA`s im Regionalschlüssel entfernen
- Die Variablen "Einwohner", "Schulden_gesamt" und "Schulden_pro_Kopf" sind alle als `character` hinterlegt (`<chr>` unter dem Variablennamen in der vorherigen Tabelle)
  - Beispiel warum Klasse `character` (Zeile 28): Es sind geschweifte Klammern enthalten

```
schulden_individuell[28,]
```

```
## # A tibble: 1 × 8
##   Regionalschluessel   Gemeinde        Verwaltungsform Einwohner Schulden_gesamt
##   <chr>                <chr>           <chr>           <chr>     <chr>
## 1 010515163_Summe(Amt) Amt Burg-St. M… Amtsgebiet      {15 547}  {35 628 306}
## # i 3 more variables: Veraenderung_Vorjahr <chr>, Schulden_pro_kopf <chr>,
## #   Bundesland <chr>
```

- Definition einer Variablen `landkreis`: Ersten 5 Zeichen im Regionalschlüssel

```
# Die Daten wurden noch nicht schön eingelesen, in d
# waren die Variablennamen über mehrere Reihen gezog
schulden_individuell
```

```
## # A tibble: 13,272 × 8
##    Regionalschluessel Gemeinde          Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>             <chr>           <chr>     <chr>
##  1 <NA>               <NA>              <NA>            <NA>      <NA>
##  2 <NA>               <NA>              <NA>            <NA>      <NA>
##  3 <NA>               <NA>              <NA>            <NA>      <NA>
##  4 <NA>               <NA>              <NA>            <NA>      EUR
##  5 <NA>               <NA>              <NA>            <NA>      1
##  6 010010000000       Flensburg, Stadt  kreisfreie Sta… 89949     454539445.970
##  7 010020000000       Kiel, Landeshau…  kreisfreie Sta… 245841    1039095143.43
##  8 010030000000       Lübeck, Hansest…  kreisfreie Sta… 215051    1090890891.45
##  9 010040000000       Neumünster, Sta…  kreisfreie Sta… 79683     453215674.299
## 10 01051              Kreisverwaltung…  Kreisverwaltung {133 401} 42967438.6200
## # i 13,262 more rows
## # i 3 more variables: Veraenderung_Vorjahr <chr>, Schulden_pro_kopf <chr>,
## #   Bundesland <chr>
```

```
# Die Daten wurden noch nicht schön eingelesen, in d
# waren die Variablennamen über mehrere Reihen gezog
schulden_individuell %>%
  filter(!is.na(Regionalschluessel))
```

```
## # A tibble: 13,155 × 8
##    Regionalschluessel Gemeinde          Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>             <chr>           <chr>     <chr>
##  1 010010000000       Flensburg, Stadt  kreisfreie Sta… 89949     454539445.970
##  2 010020000000       Kiel, Landeshau…  kreisfreie Sta… 245841    1039095143.43
##  3 010030000000       Lübeck, Hansest…  kreisfreie Sta… 215051    1090890891.45
##  4 010040000000       Neumünster, Sta…  kreisfreie Sta… 79683     453215674.299
##  5 01051              Kreisverwaltung…  Kreisverwaltung {133 401} 42967438.6200
##  6 010510011011       Brunsbüttel, St…  amtsfreie Geme… 12324     54641169.3300
##  7 010510044044       Heide, Stadt      amtsfreie Geme… 21515     42854871.6799
##  8 010515163          Amtsverwaltung …  Amtsverwaltung  {15 547}  850386.17
##  9 010515163003       Averlak           amtsangehörige… 554       1917334.71000
## 10 010515163010       Brickeln          amtsangehörige… 200       1176540.52
## # i 13,145 more rows
## # i 3 more variables: Veraenderung_Vorjahr <chr>, Schulden_pro_kopf <chr>,
## #   Bundesland <chr>
```

```r
# Die Daten wurden noch nicht schön eingelesen, in d
# waren die Variablennamen über mehrere Reihen gezog
schulden_individuell %>%
  filter(!is.na(Regionalschluessel)) %>%
  mutate(Schulden_gesamt = as.numeric(Schulden_gesam
```

```
## # A tibble: 13,155 × 8
##    Regionalschluessel Gemeinde          Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>             <chr>           <chr>               <db
##  1 010010000000       Flensburg, Stadt  kreisfreie Sta… 89949          4545394
##  2 010020000000       Kiel, Landeshau…  kreisfreie Sta… 245841        10390951
##  3 010030000000       Lübeck, Hansest…  kreisfreie Sta… 215051        10908908
##  4 010040000000       Neumünster, Sta…  kreisfreie Sta… 79683          4532156
##  5 01051              Kreisverwaltung…  Kreisverwaltung {133 401}       429674
##  6 010510011011       Brunsbüttel, St…  amtsfreie Geme… 12324           546411
##  7 010510044044       Heide, Stadt      amtsfreie Geme… 21515           428548
##  8 010515163          Amtsverwaltung …  Amtsverwaltung  {15 547}          8503
##  9 010515163003       Averlak           amtsangehörige… 554              19173
## 10 010515163010       Brickeln          amtsangehörige… 200              11765
## # i 13,145 more rows
## # i 3 more variables: Veraenderung_Vorjahr <chr>, Schulden_pro_kopf <chr>,
## #   Bundesland <chr>
```

```r
# Die Daten wurden noch nicht schön eingelesen, in d
# waren die Variablennamen über mehrere Reihen gezog
schulden_individuell %>%
  filter(!is.na(Regionalschluessel)) %>%
  mutate(Schulden_gesamt = as.numeric(Schulden_gesam
  mutate(Einwohner = as.numeric(Einwohner))
```

```
## # A tibble: 13,155 × 8
##    Regionalschluessel Gemeinde          Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>             <chr>               <dbl>           <db
##  1 010010000000       Flensburg, Stadt  kreisfreie Sta…     89949      4545394
##  2 010020000000       Kiel, Landeshau…  kreisfreie Sta…    245841     10390951
##  3 010030000000       Lübeck, Hansest…  kreisfreie Sta…    215051     10908908
##  4 010040000000       Neumünster, Sta…  kreisfreie Sta…     79683      4532156
##  5 01051              Kreisverwaltung…  Kreisverwaltung       NA       429674
##  6 010510011011       Brunsbüttel, St…  amtsfreie Geme…     12324       546411
##  7 010510044044       Heide, Stadt      amtsfreie Geme…     21515       428548
##  8 010515163          Amtsverwaltung …  Amtsverwaltung        NA         8503
##  9 010515163003       Averlak           amtsangehörige…       554        19173
## 10 010515163010       Brickeln          amtsangehörige…       200        11765
## # i 13,145 more rows
## # i 3 more variables: Veraenderung_Vorjahr <chr>, Schulden_pro_kopf <chr>,
## #   Bundesland <chr>
```

```r
# Die Daten wurden noch nicht schön eingelesen, in d
# waren die Variablennamen über mehrere Reihen gezog
schulden_individuell %>%
  filter(!is.na(Regionalschluessel)) %>%
  mutate(Schulden_gesamt = as.numeric(Schulden_gesam
  mutate(Einwohner = as.numeric(Einwohner)) %>%
  mutate(Schulden_pro_kopf = as.numeric(Schulden_pro
```

```
## # A tibble: 13,155 × 8
##    Regionalschluessel Gemeinde          Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>             <chr>               <dbl>           <db
##  1 010010000000       Flensburg, Stadt  kreisfreie Sta…     89949      4545394
##  2 010020000000       Kiel, Landeshau…  kreisfreie Sta…    245841     10390951
##  3 010030000000       Lübeck, Hansest…  kreisfreie Sta…    215051     10908908
##  4 010040000000       Neumünster, Sta…  kreisfreie Sta…     79683      4532156
##  5 01051              Kreisverwaltung…  Kreisverwaltung       NA       429674
##  6 010510011011       Brunsbüttel, St…  amtsfreie Geme…     12324       546411
##  7 010510044044       Heide, Stadt      amtsfreie Geme…     21515       428548
##  8 010515163          Amtsverwaltung …  Amtsverwaltung        NA         8503
##  9 010515163003       Averlak           amtsangehörige…       554        19173
## 10 010515163010       Brickeln          amtsangehörige…       200        11765
## # i 13,145 more rows
## # i 3 more variables: Veraenderung_Vorjahr <chr>, Schulden_pro_kopf <dbl>,
## #   Bundesland <chr>
```

```r
# Die Daten wurden noch nicht schön eingelesen, in d
# waren die Variablennamen über mehrere Reihen gezog
schulden_individuell %>%
  filter(!is.na(Regionalschluessel)) %>%
  mutate(Schulden_gesamt = as.numeric(Schulden_gesam
  mutate(Einwohner = as.numeric(Einwohner)) %>%
  mutate(Schulden_pro_kopf = as.numeric(Schulden_pro
  mutate(landkreis = str_extract(Regionalschluessel,
```

```
## # A tibble: 13,155 × 9
##    Regionalschluessel Gemeinde          Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>             <chr>               <dbl>           <db
##  1 010010000000       Flensburg, Stadt  kreisfreie Sta…     89949      4545394
##  2 010020000000       Kiel, Landeshau…  kreisfreie Sta…    245841     10390951
##  3 010030000000       Lübeck, Hansest…  kreisfreie Sta…    215051     10908908
##  4 010040000000       Neumünster, Sta…  kreisfreie Sta…     79683      4532156
##  5 01051              Kreisverwaltung…  Kreisverwaltung       NA       429674
##  6 010510011011       Brunsbüttel, St…  amtsfreie Geme…     12324       546411
##  7 010510044044       Heide, Stadt      amtsfreie Geme…     21515       428548
##  8 010515163          Amtsverwaltung …  Amtsverwaltung        NA         8503
##  9 010515163003       Averlak           amtsangehörige…       554        19173
## 10 010515163010       Brickeln          amtsangehörige…       200        11765
## # i 13,145 more rows
## # i 4 more variables: Veraenderung_Vorjahr <chr>, Schulden_pro_kopf <dbl>,
## #   Bundesland <chr>, landkreis <chr>
```

```r
# Die Daten wurden noch nicht schön eingelesen, in d
# waren die Variablennamen über mehrere Reihen gezog
schulden_individuell %>%
  filter(!is.na(Regionalschluessel)) %>%
  mutate(Schulden_gesamt = as.numeric(Schulden_gesam
  mutate(Einwohner = as.numeric(Einwohner)) %>%
  mutate(Schulden_pro_kopf = as.numeric(Schulden_pro
  mutate(landkreis = str_extract(Regionalschluessel,
  select(-Veraenderung_Vorjahr)
```

```
## # A tibble: 13,155 × 8
##    Regionalschluessel Gemeinde          Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>             <chr>               <dbl>           <db
##  1 010010000000       Flensburg, Stadt  kreisfreie Sta…     89949      4545394
##  2 010020000000       Kiel, Landeshau…  kreisfreie Sta…    245841     10390951
##  3 010030000000       Lübeck, Hansest…  kreisfreie Sta…    215051     10908908
##  4 010040000000       Neumünster, Sta…  kreisfreie Sta…     79683      4532156
##  5 01051              Kreisverwaltung…  Kreisverwaltung       NA       429674
##  6 010510011011       Brunsbüttel, St…  amtsfreie Geme…     12324       546411
##  7 010510044044       Heide, Stadt      amtsfreie Geme…     21515       428548
##  8 010515163          Amtsverwaltung …  Amtsverwaltung        NA        85038
##  9 010515163003       Averlak           amtsangehörige…       554       191733
## 10 010515163010       Brickeln          amtsangehörige…       200       117654
## # i 13,145 more rows
## # i 3 more variables: Schulden_pro_kopf <dbl>, Bundesland <chr>,
## #   landkreis <chr>
```

```
# Die Daten wurden noch nicht schön eingelesen, in d
# waren die Variablennamen über mehrere Reihen gezog
schulden_individuell %>%
  filter(!is.na(Regionalschluessel)) %>%
  mutate(Schulden_gesamt = as.numeric(Schulden_gesam
  mutate(Einwohner = as.numeric(Einwohner)) %>%
  mutate(Schulden_pro_kopf = as.numeric(Schulden_pro
  mutate(landkreis = str_extract(Regionalschluessel,
  select(-Veraenderung_Vorjahr) %>%
#manche Landkreise haben keine Infos zu den Einwohne
  filter( !is.na( Einwohner ))
```

```
## # A tibble: 10,785 × 8
##    Regionalschluessel Gemeinde         Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>            <chr>               <dbl>           <db
##  1 010010000000       Flensburg, Stadt kreisfreie Sta…     89949      4545394
##  2 010020000000       Kiel, Landeshau… kreisfreie Sta…    245841     10390951
##  3 010030000000       Lübeck, Hansest… kreisfreie Sta…    215051     10908908
##  4 010040000000       Neumünster, Sta… kreisfreie Sta…     79683      4532156
##  5 010510011011       Brunsbüttel, St… amtsfreie Geme…     12324       546411
##  6 010510044044       Heide, Stadt     amtsfreie Geme…     21515       428548
##  7 010515163003       Averlak          amtsangehörige…       554       191733
##  8 010515163010       Brickeln         amtsangehörige…       200       117654
##  9 010515163012       Buchholz         amtsangehörige…       997       197665
## 10 010515163016       Burg (Dithmarsc… amtsangehörige…      4166      1035990
## # i 10,775 more rows
## # i 3 more variables: Schulden_pro_kopf <dbl>, Bundesland <chr>,
## #   landkreis <chr>
```

```
# Die Daten wurden noch nicht schön eingelesen, in d
# waren die Variablennamen über mehrere Reihen gezog
schulden_individuell %>%
  filter(!is.na(Regionalschluessel)) %>%
  mutate(Schulden_gesamt = as.numeric(Schulden_gesam
  mutate(Einwohner = as.numeric(Einwohner)) %>%
  mutate(Schulden_pro_kopf = as.numeric(Schulden_pro
  mutate(landkreis = str_extract(Regionalschluessel,
  select(-Veraenderung_Vorjahr) %>%
#manche Landkreise haben keine Infos zu den Einwohne
  filter( !is.na( Einwohner )) ->
schulden_bereinigt
```

```
# Die Daten wurden noch nicht schön eingelesen, in d
# waren die Variablennamen über mehrere Reihen gezog
schulden_individuell %>%
  filter(!is.na(Regionalschluessel)) %>%
  mutate(Schulden_gesamt = as.numeric(Schulden_gesam
  mutate(Einwohner = as.numeric(Einwohner)) %>%
  mutate(Schulden_pro_kopf = as.numeric(Schulden_pro
  mutate(landkreis = str_extract(Regionalschluessel,
  select(-Veraenderung_Vorjahr) %>%
#manche Landkreise haben keine Infos zu den Einwohne
  filter( !is.na( Einwohner )) ->
schulden_bereinigt
```

Konsistenzcheck zum Schulden-Datensatz

Interne Validität Schulden pro Kopf

- `Schulden_pro_Kopf_new` von Hand berechnen
- **Beachte:**
  - Geschweiften Klammern entfernen bei `Schulden_gesamt` (mit `str_remove_all`), als auch die Leerzeichen innerhalb der Zahlen (z.B. 15 653), was wir mit `gsub("[[:space:]]")` erreichen.
  - Tun wir das nicht, so würden wir wieder `NA`s im Datensatz erhalten
  - Durch die ifelse Bedingung wird der Befehl `str_remove_all` nur angewendet, wenn tatsächlich geschweifte Klammern vorhanden sind

```
# Erstellen der Vergleichstabelle
schulden_consistency <- schulden_individuell %>%
  filter( !is.na(Einwohner) & !is.na(Regionalschluessel) ) %>%
  mutate(Schulden_gesamt = ifelse(is.na(as.numeric(Schulden_gesamt))==TRUE,
                                  as.numeric(gsub("[[:space:]]", "", str_remove_all(Schulden_gesamt, "[{}]"))),
                                  as.numeric(Schulden_gesamt)),
         Schulden_pro_kopf = ifelse(is.na(as.numeric(Schulden_pro_kopf))==TRUE,
                                    as.numeric(gsub("[[:space:]]", "", str_remove_all(Schulden_pro_kopf, "[{}]"))),
                                    as.numeric(Schulden_pro_kopf)),
         Einwohner_num = ifelse(is.na(as.numeric(Einwohner))==TRUE,
                                as.numeric(gsub("[[:space:]]", "", str_remove_all(Einwohner, "[{}]"))),
                                as.numeric(Einwohner)),
         Schulden_pro_kopf_new = round(Schulden_gesamt / Einwohner_num,2)) %>%
  relocate(Regionalschluessel, Einwohner, Einwohner_num, Schulden_pro_kopf, Schulden_pro_kopf_new ) %>%
  mutate(landkreis = str_extract(Regionalschluessel, "^.{5}"),
         differenz = Schulden_pro_kopf - Schulden_pro_kopf_new)
```

```
# Erstellen der Vergleichstabelle
schulden_individuell
```

```
## # A tibble: 13,272 × 8
##    Regionalschluessel Gemeinde          Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>             <chr>           <chr>     <chr>
##  1 <NA>               <NA>              <NA>            <NA>      <NA>
##  2 <NA>               <NA>              <NA>            <NA>      <NA>
##  3 <NA>               <NA>              <NA>            <NA>      <NA>
##  4 <NA>               <NA>              <NA>            <NA>      EUR
##  5 <NA>               <NA>              <NA>            <NA>      1
##  6 010010000000       Flensburg, Stadt  kreisfreie Sta… 89949     454539445.970
##  7 010020000000       Kiel, Landeshau…  kreisfreie Sta… 245841    1039095143.43
##  8 010030000000       Lübeck, Hansest…  kreisfreie Sta… 215051    1090890891.45
##  9 010040000000       Neumünster, Sta…  kreisfreie Sta… 79683     453215674.299
## 10 01051              Kreisverwaltung…  Kreisverwaltung {133 401} 42967438.6200
## # i 13,262 more rows
## # i 3 more variables: Veraenderung_Vorjahr <chr>, Schulden_pro_kopf <chr>,
## #   Bundesland <chr>
```

```r
# Erstellen der Vergleichstabelle
schulden_individuell %>%
  filter( !is.na(Einwohner) & !is.na(Regionalschlues
```

```
## # A tibble: 13,114 × 8
##    Regionalschluessel Gemeinde          Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>             <chr>           <chr>     <chr>
##  1 010010000000       Flensburg, Stadt  kreisfreie Sta… 89949     454539445.970
##  2 010020000000       Kiel, Landeshau…  kreisfreie Sta… 245841    1039095143.43
##  3 010030000000       Lübeck, Hansest…  kreisfreie Sta… 215051    1090890891.45
##  4 010040000000       Neumünster, Sta…  kreisfreie Sta… 79683     453215674.299
##  5 01051              Kreisverwaltung…  Kreisverwaltung {133 401} 42967438.6200
##  6 010510011011       Brunsbüttel, St…  amtsfreie Geme… 12324     54641169.3300
##  7 010510044044       Heide, Stadt      amtsfreie Geme… 21515     42854871.6799
##  8 010515163          Amtsverwaltung …  Amtsverwaltung  {15 547}  850386.17
##  9 010515163003       Averlak           amtsangehörige… 554       1917334.71000
## 10 010515163010       Brickeln          amtsangehörige… 200       1176540.52
## # i 13,104 more rows
## # i 3 more variables: Veraenderung_Vorjahr <chr>, Schulden_pro_kopf <chr>,
## #   Bundesland <chr>
```

```r
# Erstellen der Vergleichstabelle
schulden_individuell %>%
  filter( !is.na(Einwohner) & !is.na(Regionalschlues
  mutate(Schulden_gesamt = ifelse(is.na(as.numeric(S
                                  as.numeric(gsub("[
                                  as.numeric(Schulde
```

```
## # A tibble: 13,114 × 8
##    Regionalschluessel Gemeinde          Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>             <chr>           <chr>               <db
##  1 010010000000       Flensburg, Stadt  kreisfreie Sta… 89949          4545394
##  2 010020000000       Kiel, Landeshau…  kreisfreie Sta… 245841        10390951
##  3 010030000000       Lübeck, Hansest…  kreisfreie Sta… 215051        10908908
##  4 010040000000       Neumünster, Sta…  kreisfreie Sta… 79683          4532156
##  5 01051              Kreisverwaltung…  Kreisverwaltung {133 401}       429674
##  6 010510011011       Brunsbüttel, St…  amtsfreie Geme… 12324           546411
##  7 010510044044       Heide, Stadt      amtsfreie Geme… 21515           428548
##  8 010515163          Amtsverwaltung …  Amtsverwaltung  {15 547}          8503
##  9 010515163003       Averlak           amtsangehörige… 554              19173
## 10 010515163010       Brickeln          amtsangehörige… 200              11765
## # i 13,104 more rows
## # i 3 more variables: Veraenderung_Vorjahr <chr>, Schulden_pro_kopf <chr>,
## #   Bundesland <chr>
```

```r
# Erstellen der Vergleichstabelle
schulden_individuell %>%
  filter( !is.na(Einwohner) & !is.na(Regionalschlues
  mutate(Schulden_gesamt = ifelse(is.na(as.numeric(S
                                  as.numeric(gsub("[
                                  as.numeric(Schulde
  mutate(Schulden_pro_kopf = ifelse(is.na(as.numeric
                                    as.numeric(gsub(
                                    as.numeric(Schul
```

```
## # A tibble: 13,114 × 8
##    Regionalschluessel Gemeinde         Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>            <chr>           <chr>                <db
##  1 010010000000       Flensburg, Stadt kreisfreie Sta… 89949          4545394
##  2 010020000000       Kiel, Landeshau… kreisfreie Sta… 245841        10390951
##  3 010030000000       Lübeck, Hansest… kreisfreie Sta… 215051        10908908
##  4 010040000000       Neumünster, Sta… kreisfreie Sta… 79683          4532156
##  5 01051              Kreisverwaltung… Kreisverwaltung {133 401}       429674
##  6 010510011011       Brunsbüttel, St… amtsfreie Geme… 12324           546411
##  7 010510044044       Heide, Stadt     amtsfreie Geme… 21515           428548
##  8 010515163          Amtsverwaltung … Amtsverwaltung  {15 547}          8503
##  9 010515163003       Averlak          amtsangehörige… 554              19173
## 10 010515163010       Brickeln         amtsangehörige… 200              11765
## # i 13,104 more rows
## # i 3 more variables: Veraenderung_Vorjahr <chr>, Schulden_pro_kopf <dbl>,
## #   Bundesland <chr>
```

```
# Erstellen der Vergleichstabelle
schulden_individuell %>%
  filter( !is.na(Einwohner) & !is.na(Regionalschlues
  mutate(Schulden_gesamt = ifelse(is.na(as.numeric(S
                                  as.numeric(gsub("[
                                  as.numeric(Schulde
  mutate(Schulden_pro_kopf = ifelse(is.na(as.numeric
                                    as.numeric(gsub(
                                    as.numeric(Schul
  mutate(Einwohner_num = ifelse(is.na(as.numeric(Ein
                                as.numeric(gsub("[[:
                                as.numeric(Einwohner
```

```
## # A tibble: 13,114 × 9
##    Regionalschluessel Gemeinde         Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>            <chr>           <chr>               <db
##  1 010010000000       Flensburg, Stadt kreisfreie Sta… 89949          4545394
##  2 010020000000       Kiel, Landeshau… kreisfreie Sta… 245841        10390951
##  3 010030000000       Lübeck, Hansest… kreisfreie Sta… 215051        10908908
##  4 010040000000       Neumünster, Sta… kreisfreie Sta… 79683          4532156
##  5 01051              Kreisverwaltung… Kreisverwaltung {133 401}       429674
##  6 010510011011       Brunsbüttel, St… amtsfreie Geme… 12324           546411
##  7 010510044044       Heide, Stadt     amtsfreie Geme… 21515           428548
##  8 010515163          Amtsverwaltung … Amtsverwaltung  {15 547}         85038
##  9 010515163003       Averlak          amtsangehörige… 554             19173
## 10 010515163010       Brickeln         amtsangehörige… 200             11765
## # i 13,104 more rows
## # i 4 more variables: Veraenderung_Vorjahr <chr>, Schulden_pro_kopf <dbl>,
## #   Bundesland <chr>, Einwohner_num <dbl>
```

```r
# Erstellen der Vergleichstabelle
schulden_individuell %>%
  filter( !is.na(Einwohner) & !is.na(Regionalschlues
  mutate(Schulden_gesamt = ifelse(is.na(as.numeric(S
                                  as.numeric(gsub("[
                                  as.numeric(Schulde
  mutate(Schulden_pro_kopf = ifelse(is.na(as.numeric
                                    as.numeric(gsub(
                                    as.numeric(Schul
  mutate(Einwohner_num = ifelse(is.na(as.numeric(Ein
                                as.numeric(gsub("[[:
                                as.numeric(Einwohner
  mutate(Schulden_pro_kopf_new = round(Schulden_gesa
```

```
## # A tibble: 13,114 × 10
##    Regionalschluessel Gemeinde          Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>             <chr>           <chr>               <db
##  1 010010000000       Flensburg, Stadt  kreisfreie Sta… 89949          4545394
##  2 010020000000       Kiel, Landeshau…  kreisfreie Sta… 245841        10390951
##  3 010030000000       Lübeck, Hansest…  kreisfreie Sta… 215051        10908908
##  4 010040000000       Neumünster, Sta…  kreisfreie Sta… 79683          4532156
##  5 01051              Kreisverwaltung…  Kreisverwaltung {133 401}       429674
##  6 010510011011       Brunsbüttel, St…  amtsfreie Geme… 12324           546411
##  7 010510044044       Heide, Stadt      amtsfreie Geme… 21515           428548
##  8 010515163          Amtsverwaltung …  Amtsverwaltung  {15 547}          8503
##  9 010515163003       Averlak           amtsangehörige… 554              19173
## 10 010515163010       Brickeln          amtsangehörige… 200              11765
## # i 13,104 more rows
## # i 5 more variables: Veraenderung_Vorjahr <chr>, Schulden_pro_kopf <dbl>,
## #   Bundesland <chr>, Einwohner_num <dbl>, Schulden_pro_kopf_new <dbl>
```

```r
# Erstellen der Vergleichstabelle
schulden_individuell %>%
  filter( !is.na(Einwohner) & !is.na(Regionalschlues
  mutate(Schulden_gesamt = ifelse(is.na(as.numeric(S
                                  as.numeric(gsub("[
                                  as.numeric(Schulde
  mutate(Schulden_pro_kopf = ifelse(is.na(as.numeric
                                    as.numeric(gsub(
                                    as.numeric(Schul
  mutate(Einwohner_num = ifelse(is.na(as.numeric(Ein
                                as.numeric(gsub("[[:
                                as.numeric(Einwohner
  mutate(Schulden_pro_kopf_new = round(Schulden_gesa
  relocate(Regionalschluessel, Einwohner, Einwohner_
```

```
## # A tibble: 13,114 × 10
##    Regionalschluessel Einwohner Einwohner_num Schulden_pro_kopf
##    <chr>              <chr>             <dbl>             <dbl>
##  1 010010000000       89949             89949             5053.
##  2 010020000000       245841           245841             4227.
##  3 010030000000       215051           215051             5073.
##  4 010040000000       79683             79683             5688.
##  5 01051              {133 401}        133401              322.
##  6 010510011011       12324             12324             4434.
##  7 010510044044       21515             21515             1992.
##  8 010515163          {15 547}          15547               54.7
##  9 010515163003       554                 554             3461.
## 10 010515163010       200                 200             5883.
## # i 13,104 more rows
## # i 6 more variables: Schulden_pro_kopf_new <dbl>, Gemeinde <chr>,
## #   Verwaltungsform <chr>, Schulden_gesamt <dbl>, Veraenderung_Vorjahr <chr>,
## #   Bundesland <chr>
```

```r
# Erstellen der Vergleichstabelle
schulden_individuell %>%
  filter( !is.na(Einwohner) & !is.na(Regionalschlues
  mutate(Schulden_gesamt = ifelse(is.na(as.numeric(S
                                  as.numeric(gsub("[
                                  as.numeric(Schulde
  mutate(Schulden_pro_kopf = ifelse(is.na(as.numeric
                                    as.numeric(gsub(
                                    as.numeric(Schul
  mutate(Einwohner_num = ifelse(is.na(as.numeric(Ein
                                as.numeric(gsub("[[:
                                as.numeric(Einwohner
  mutate(Schulden_pro_kopf_new = round(Schulden_gesa
  relocate(Regionalschluessel, Einwohner, Einwohner_
  mutate(landkreis = str_extract(Regionalschluessel,
         differenz = Schulden_pro_kopf - Schulden_pr
```

```
## # A tibble: 13,114 × 12
##    Regionalschluessel Einwohner Einwohner_num Schulden_pro_kopf
##    <chr>              <chr>             <dbl>             <dbl>
##  1 010010000000       89949             89949             5053.
##  2 010020000000       245841           245841             4227.
##  3 010030000000       215051           215051             5073.
##  4 010040000000       79683             79683             5688.
##  5 01051              {133 401}        133401              322.
##  6 010510011011       12324             12324             4434.
##  7 010510044044       21515             21515             1992.
##  8 010515163          {15 547}          15547               54.7
##  9 010515163003       554                 554             3461.
## 10 010515163010       200                 200             5883.
## # i 13,104 more rows
## # i 8 more variables: Schulden_pro_kopf_new <dbl>, Gemeinde <chr>,
## #   Verwaltungsform <chr>, Schulden_gesamt <dbl>, Veraenderung_Vorjahr <chr>,
## #   Bundesland <chr>, landkreis <chr>, differenz <dbl>
```

```
# Erstellen der Vergleichstabelle
schulden_individuell %>%
  filter( !is.na(Einwohner) & !is.na(Regionalschlues
  mutate(Schulden_gesamt = ifelse(is.na(as.numeric(S
                                  as.numeric(gsub("[
                                  as.numeric(Schulde
  mutate(Schulden_pro_kopf = ifelse(is.na(as.numeric
                                    as.numeric(gsub(
                                    as.numeric(Schul
  mutate(Einwohner_num = ifelse(is.na(as.numeric(Ein
                                as.numeric(gsub("[[:
                                as.numeric(Einwohner
  mutate(Schulden_pro_kopf_new = round(Schulden_gesa
  relocate(Regionalschluessel, Einwohner, Einwohner_
  mutate(landkreis = str_extract(Regionalschluessel,
         differenz = Schulden_pro_kopf - Schulden_pr
schulden_consistency
```

Interne Validität Schulden pro Kopf

```
range(schulden_consistency$differenz, na.rm=TRUE)
```

```
## [1] -0.49  0.50
```

Interne Validität Schulden pro Kopf

```
range(schulden_consistency$differenz, na.rm=TRUE)
```

```
## [1] -0.49  0.50
```

Die Differenzen liegen zwischen +/- 50 Cent

Interne Validität Schulden pro Kopf

Es gibt keine nicht verfügbaren Werte, was gut ist bzgl. der internen Validität.

```
filter(schulden_consistency, is.na(differenz))
```

```
## # A tibble: 0 × 12
## # i 12 variables: Regionalschluessel <chr>, Einwohner <chr>,
## #   Einwohner_num <dbl>, Schulden_pro_kopf <dbl>, Schulden_pro_kopf_new <dbl>,
## #   Gemeinde <chr>, Verwaltungsform <chr>, Schulden_gesamt <dbl>,
## #   Veraenderung_Vorjahr <chr>, Bundesland <chr>, landkreis <chr>,
## #   differenz <dbl>
```

Bruttoinlandsprodukt

Informationen bzgl. des Bruttoinlandsprodukts

Nach dem Download bei den Statistischen Ämtern des Bundes und der Länder und einer ersten Betrachtung interessieren uns folgende Tabellenblätter:

- Betrachten der Daten
  - Tabellenblatt "1.1" ist für unsere Analyse ausschlaggebend (für das BIP)
  - Tabellenblatt "3.1" ist für die Anzahl an Erwerbstätigen ausschlaggebend
  - Tabellenblatt "5" ist für die Anzahl an Einwohnern ausschlaggebend
- Die ersten vier Zeilen benötigen wir nicht
- Die letzte Zeile enthält eine kurze Beschreibung die wir nicht benötigen
  - **Lösung:** Behalte alle Zeilen, welche bei der `Lfd. Nr.` numerisch sind
- Die folgenden Variablen benötigen wir nicht für unsere Analyse und können entfernt werden: `Lfd. Nr.`, `EU-Code`, `NUTS 1`, `NUTS 2`, `NUTS 3`, `Land`, `Gebietseinheit`

Informationen bzgl. des Bruttoinlandsprodukts

```
# Blatt 1.1 einlesen und die ersten 4 Zeilen skippen
bip <- read_xlsx("../case-study/data/BIP_2022.xlsx", sheet="1.1", skip = 4)
erwerb <- read_xlsx("../case-study/data/BIP_2022.xlsx", sheet="3.1", skip = 4)
einwohner <- read_xlsx("../case-study/data/BIP_2022.xlsx", sheet = "5", skip = 4)
```

```
# Zeile löschen in der die `Lfd. Nr.` nicht nummeris
# Zusätzliche Spalten löschen
bip
```

```
## # A tibble: 448 × 37
##    `Lfd. Nr.` `EU-Code` `Regional-schlüssel` Land  `NUTS 1` `NUTS 2` `NUTS 3`
##    <chr>      <chr>     <chr>                <chr> <chr>    <chr>    <chr>
##  1 <NA>       <NA>      <NA>                 <NA>  <NA>     <NA>     <NA>
##  2 1          DE1       08                   BW    1        <NA>     <NA>
##  3 2          DE11      081                  BW    <NA>     2        <NA>
##  4 3          DE111     08111                BW    <NA>     <NA>     3
##  5 4          DE112     08115                BW    <NA>     <NA>     3
##  6 5          DE113     08116                BW    <NA>     <NA>     3
##  7 6          DE114     08117                BW    <NA>     <NA>     3
##  8 7          DE115     08118                BW    <NA>     <NA>     3
##  9 8          DE116     08119                BW    <NA>     <NA>     3
## 10 9          DE117     08121                BW    <NA>     <NA>     3
## # i 438 more rows
## # i 30 more variables: Gebietseinheit <chr>, `1992` <chr>, `1994` <chr>,
## #   `1995` <chr>, `1996` <chr>, `1997` <chr>, `1998` <chr>, `1999` <chr>,
## #   `2000` <dbl>, `2001` <dbl>, `2002` <dbl>, `2003` <dbl>, `2004` <dbl>,
## #   `2005` <dbl>, `2006` <dbl>, `2007` <dbl>, `2008` <dbl>, `2009` <dbl>,
## #   `2010` <dbl>, `2011` <dbl>, `2012` <dbl>, `2013` <dbl>, `2014` <dbl>,
## #   `2015` <dbl>, `2016` <dbl>, `2017` <dbl>, `2018` <dbl>, `2019` <dbl>, …
```

```r
# Zeile löschen in der die `Lfd. Nr.` nicht nummeris
# Zusätzliche Spalten löschen
bip %>%
  filter(is.na(as.numeric(`Lfd. Nr.`))==FALSE)
```

```
## # A tibble: 445 × 37
##    `Lfd. Nr.` `EU-Code` `Regional-schlüssel` Land  `NUTS 1` `NUTS 2` `NUTS 3`
##    <chr>      <chr>     <chr>                <chr> <chr>    <chr>    <chr>
##  1 1          DE1       08                   BW    1        <NA>     <NA>
##  2 2          DE11      081                  BW    <NA>     2        <NA>
##  3 3          DE111     08111                BW    <NA>     <NA>     3
##  4 4          DE112     08115                BW    <NA>     <NA>     3
##  5 5          DE113     08116                BW    <NA>     <NA>     3
##  6 6          DE114     08117                BW    <NA>     <NA>     3
##  7 7          DE115     08118                BW    <NA>     <NA>     3
##  8 8          DE116     08119                BW    <NA>     <NA>     3
##  9 9          DE117     08121                BW    <NA>     <NA>     3
## 10 10         DE118     08125                BW    <NA>     <NA>     3
## # i 435 more rows
## # i 30 more variables: Gebietseinheit <chr>, `1992` <chr>, `1994` <chr>,
## #   `1995` <chr>, `1996` <chr>, `1997` <chr>, `1998` <chr>, `1999` <chr>,
## #   `2000` <dbl>, `2001` <dbl>, `2002` <dbl>, `2003` <dbl>, `2004` <dbl>,
## #   `2005` <dbl>, `2006` <dbl>, `2007` <dbl>, `2008` <dbl>, `2009` <dbl>,
## #   `2010` <dbl>, `2011` <dbl>, `2012` <dbl>, `2013` <dbl>, `2014` <dbl>,
## #   `2015` <dbl>, `2016` <dbl>, `2017` <dbl>, `2018` <dbl>, `2019` <dbl>, …
```

```r
# Zeile löschen in der die `Lfd. Nr.` nicht nummeris
# Zusätzliche Spalten löschen
bip %>%
  filter(is.na(as.numeric(`Lfd. Nr.`))==FALSE) %>%
  select(-c(`Lfd. Nr.`, `EU-Code`, `NUTS 1`, `NUTS 2
```

```
## # A tibble: 445 × 30
##    `Regional-schlüssel` `1992`  `1994` `1995` `1996` `1997` `1998` `1999` `200
##    <chr>                <chr>   <chr>  <chr>  <chr>  <chr>  <chr>  <chr>   <db
##  1 08                   255866… 26264… 27174… 27677… 28219… 29109… 30072… 3.09
##  2 081                  110977… 11160… 11528… 11678… 12086… 12384… 12779… 1.30
##  3 08111                32946.… 31736… 32281… 32802… 34339… 33553… 35048… 3.53
##  4 08115                12090.… 11833… 11937… 12097… 13919… 13679… 14424… 1.39
##  5 08116                12275.… 12482… 12748… 13169… 13284… 13952… 14192… 1.44
##  6 08117                5062.0… 5180.… 5447.… 5643.… 5667.… 5838.… 5920.… 6.00
##  7 08118                11714.… 12163… 12756… 12895… 13143… 13516… 13866… 1.47
##  8 08119                8500.4… 8723.… 9320.… 8780.… 8928.… 9175.… 9707.… 1.04
##  9 08121                4219.2… 4387.… 4522.… 4510.… 4581.… 5645.… 5282.… 5.27
## 10 08125                6073.5… 6126.… 6577.… 6811.… 7019.… 7645.… 7928.… 8.45
## # i 435 more rows
## # i 21 more variables: `2001` <dbl>, `2002` <dbl>, `2003` <dbl>, `2004` <dbl>,
## #   `2005` <dbl>, `2006` <dbl>, `2007` <dbl>, `2008` <dbl>, `2009` <dbl>,
## #   `2010` <dbl>, `2011` <dbl>, `2012` <dbl>, `2013` <dbl>, `2014` <dbl>,
## #   `2015` <dbl>, `2016` <dbl>, `2017` <dbl>, `2018` <dbl>, `2019` <dbl>,
## #   `2020` <dbl>, `2021` <dbl>
```

```r
# Zeile löschen in der die `Lfd. Nr.` nicht nummeris
# Zusätzliche Spalten löschen
bip %>%
  filter(is.na(as.numeric(`Lfd. Nr.`))==FALSE) %>%
  select(-c(`Lfd. Nr.`, `EU-Code`, `NUTS 1`, `NUTS 2
  rename(Regionalschluessel = `Regional-schlüssel`)
```

```
## # A tibble: 445 × 30
##    Regionalschluessel `1992`    `1994` `1995` `1996` `1997` `1998` `1999` `200
##    <chr>              <chr>     <chr>  <chr>  <chr>  <chr>  <chr>  <chr>   <db
##  1 08                 255866.4… 26264… 27174… 27677… 28219… 29109… 30072… 3.09
##  2 081                110977.0… 11160… 11528… 11678… 12086… 12384… 12779… 1.30
##  3 08111              32946.88… 31736… 32281… 32802… 34339… 33553… 35048… 3.53
##  4 08115              12090.93  11833… 11937… 12097… 13919… 13679… 14424… 1.39
##  5 08116              12275.605 12482… 12748… 13169… 13284… 13952… 14192… 1.44
##  6 08117              5062.037… 5180.… 5447.… 5643.… 5667.… 5838.… 5920.… 6.00
##  7 08118              11714.16  12163… 12756… 12895… 13143… 13516… 13866… 1.47
##  8 08119              8500.405… 8723.… 9320.… 8780.… 8928.… 9175.… 9707.… 1.04
##  9 08121              4219.259  4387.… 4522.… 4510.… 4581.… 5645.… 5282.… 5.27
## 10 08125              6073.524… 6126.… 6577.… 6811.… 7019.… 7645.… 7928.… 8.45
## # i 435 more rows
## # i 21 more variables: `2001` <dbl>, `2002` <dbl>, `2003` <dbl>, `2004` <dbl>,
## #   `2005` <dbl>, `2006` <dbl>, `2007` <dbl>, `2008` <dbl>, `2009` <dbl>,
## #   `2010` <dbl>, `2011` <dbl>, `2012` <dbl>, `2013` <dbl>, `2014` <dbl>,
## #   `2015` <dbl>, `2016` <dbl>, `2017` <dbl>, `2018` <dbl>, `2019` <dbl>,
## #   `2020` <dbl>, `2021` <dbl>
```

```
# Zeile löschen in der die `Lfd. Nr.` nicht nummeris
# Zusätzliche Spalten löschen
bip %>%
  filter(is.na(as.numeric(`Lfd. Nr.`))==FALSE) %>%
  select(-c(`Lfd. Nr.`, `EU-Code`, `NUTS 1`, `NUTS 2
  rename(Regionalschluessel = `Regional-schlüssel`)
bip_wide
```

Informationen bzgl. des Bruttoinlandsprodukts

> Was ist hier eine Beobachtung?

Informationen bzgl. des Bruttoinlandsprodukts

> Was ist hier eine Beobachtung?

Entsprechend können wir bei den Erwerbstätigen und den Einwohnern vorgehen:

```
# Zeile löschen in der die `Lfd. Nr.` nicht nummerisch ist
# Zusätzliche Spalten löschen
erwerb_wide <- erwerb %>%
  filter(is.na(as.numeric(`Lfd. Nr.`))==FALSE) %>%
  select(-c(`Lfd. Nr.`, `EU-Code`, `NUTS 1`, `NUTS 2`, `NUTS 3`, Land, Gebietseinheit)) %>%
  rename(Regionalschluessel = `Regional-schlüssel`)

einwohner_wide <- einwohner %>%
  filter(is.na(as.numeric(`Lfd. Nr.`))==FALSE) %>%
  select(-c(`Lfd. Nr.`, `EU-Code`, `NUTS 1`, `NUTS 2`, `NUTS 3`, Land, Gebietseinheit)) %>%
  rename(Regionalschluessel = `Regional-schlüssel`)
```

Informationen bzgl. des Bruttoinlandsprodukts

Datensatz,

- ist ein Panel: Mehrere Jahre für mehrere Landkreise in Deutschland vorhanden
- ist im `wide` Format -> d.h. die Daten sind nicht `tidy`

```
head(bip_wide, 3)
```

```
## # A tibble: 3 × 30
##   Regionalschluessel `1992`     `1994` `1995` `1996` `1997` `1998` `1999` `2000`
##   <chr>              <chr>      <chr>  <chr>  <chr>  <chr>  <chr>  <chr>   <dbl>
## 1 08                 255866.41… 26264… 27174… 27677… 28219… 29109… 30072… 3.09e5
## 2 081                110977.071 11160… 11528… 11678… 12086… 12384… 12779… 1.30e5
## 3 08111              32946.883… 31736… 32281… 32802… 34339… 33553… 35048… 3.53e4
## # i 21 more variables: `2001` <dbl>, `2002` <dbl>, `2003` <dbl>, `2004` <dbl>,
## #   `2005` <dbl>, `2006` <dbl>, `2007` <dbl>, `2008` <dbl>, `2009` <dbl>,
## #   `2010` <dbl>, `2011` <dbl>, `2012` <dbl>, `2013` <dbl>, `2014` <dbl>,
## #   `2015` <dbl>, `2016` <dbl>, `2017` <dbl>, `2018` <dbl>, `2019` <dbl>,
## #   `2020` <dbl>, `2021` <dbl>
```

Informationen bzgl. des Bruttoinlandsprodukts

Datensatz,

- ist ein Panel: Mehrere Jahre für mehrere Landkreise in Deutschland vorhanden
- ist im `wide` Format -> d.h. die Daten sind nicht `tidy`

```
head(bip_wide, 3)
```

```
## # A tibble: 3 × 30
##   Regionalschluessel `1992`     `1994` `1995` `1996` `1997` `1998` `1999` `2000`
##   <chr>              <chr>      <chr>  <chr>  <chr>  <chr>  <chr>  <chr>   <dbl>
## 1 08                 255866.41… 26264… 27174… 27677… 28219… 29109… 30072… 3.09e5
## 2 081                110977.071 11160… 11528… 11678… 12086… 12384… 12779… 1.30e5
## 3 08111              32946.883… 31736… 32281… 32802… 34339… 33553… 35048… 3.53e4
## # i 21 more variables: `2001` <dbl>, `2002` <dbl>, `2003` <dbl>, `2004` <dbl>,
## #   `2005` <dbl>, `2006` <dbl>, `2007` <dbl>, `2008` <dbl>, `2009` <dbl>,
## #   `2010` <dbl>, `2011` <dbl>, `2012` <dbl>, `2013` <dbl>, `2014` <dbl>,
## #   `2015` <dbl>, `2016` <dbl>, `2017` <dbl>, `2018` <dbl>, `2019` <dbl>,
## #   `2020` <dbl>, `2021` <dbl>
```

> Was sind die Bedigungen für einen `tidy` Datensatz?

Daten in das `long`-Format überführen

Datensatz ins `long`-Format überführen mit `pivot_longer`:

```
bip_long <- pivot_longer(bip_wide, cols = c("1992":"2021") , names_to = "Jahr", values_to = "BIP")
```

```
Fehler: Can't combine `1992` <character> and `2000` <double>.
```

Daten in das `long`-Format überführen

BIP sollte normalerweise nummerisch sein:

- Klasse `double` sollte korrekt sein
- umformatieren der Spalten `1992` - `1999`
- mit `across()` kann der `mutate()`-Befehl über mehrere Spalten angewendet werden

```
#BIP von 1992 - 1999 umformen (als numerische Variab
```

```
#BIP von 1992 - 1999 umformen (als numerische Variab
bip_wide
```

```
## # A tibble: 445 × 30
##    Regionalschluessel `1992`    `1994` `1995` `1996` `1997` `1998` `1999` `200
##    <chr>              <chr>     <chr>  <chr>  <chr>  <chr>  <chr>  <chr>   <db
##  1 08                 255866.4… 26264… 27174… 27677… 28219… 29109… 30072… 3.09
##  2 081                110977.0… 11160… 11528… 11678… 12086… 12384… 12779… 1.30
##  3 08111              32946.88… 31736… 32281… 32802… 34339… 33553… 35048… 3.53
##  4 08115              12090.93  11833… 11937… 12097… 13919… 13679… 14424… 1.39
##  5 08116              12275.605 12482… 12748… 13169… 13284… 13952… 14192… 1.44
##  6 08117              5062.037… 5180.… 5447.… 5643.… 5667.… 5838.… 5920.… 6.00
##  7 08118              11714.16  12163… 12756… 12895… 13143… 13516… 13866… 1.47
##  8 08119              8500.405… 8723.… 9320.… 8780.… 8928.… 9175.… 9707.… 1.04
##  9 08121              4219.259  4387.… 4522.… 4510.… 4581.… 5645.… 5282.… 5.27
## 10 08125              6073.524… 6126.… 6577.… 6811.… 7019.… 7645.… 7928.… 8.45
## # i 435 more rows
## # i 21 more variables: `2001` <dbl>, `2002` <dbl>, `2003` <dbl>, `2004` <dbl>,
## #   `2005` <dbl>, `2006` <dbl>, `2007` <dbl>, `2008` <dbl>, `2009` <dbl>,
## #   `2010` <dbl>, `2011` <dbl>, `2012` <dbl>, `2013` <dbl>, `2014` <dbl>,
## #   `2015` <dbl>, `2016` <dbl>, `2017` <dbl>, `2018` <dbl>, `2019` <dbl>,
## #   `2020` <dbl>, `2021` <dbl>
```

```r
#BIP von 1992 - 1999 umformen (als numerische Variab
bip_wide %>%
  select(`1992`:`1999`)
```

```
## # A tibble: 445 × 7
##    `1992`              `1994`              `1995`       `1996` `1997` `1998` `199
##    <chr>               <chr>               <chr>        <chr>  <chr>  <chr>  <chr
##  1 255866.41899999999 262645.41600000003 271746.699…  27677…  28219…  29109…  300
##  2 110977.071         111602.66499999999 115280.807   11678…  12086…  12384…  127
##  3 32946.883999999998 31736.567999999999 32281.0040…  32802…  34339…  33553…  350
##  4 12090.93           11833.816000000001 11937.788    12097…  13919…  13679…  144
##  5 12275.605          12482.948           12748.703    13169…  13284…  13952…  141
##  6 5062.0370000000003 5180.0739999999996 5447.49399…  5643.…  5667.…  5838.…  592
##  7 11714.16           12163.822           12756.3989…  12895…  13143…  13516…  138
##  8 8500.4050000000007 8723.0990000000002 9320.15600…  8780.…  8928.…  9175.…  970
##  9 4219.259           4387.4809999999998 4522.82399…  4510.…  4581.…  5645.…  528
## 10 6073.5249999999996 6126.3310000000001 6577.05599…  6811.…  7019.…  7645.…  792
## # i 435 more rows
```

```r
#BIP von 1992 - 1999 umformen (als numerische Variab
bip_wide %>%
  select(`1992`:`1999`) %>%
  mutate(across(is.character, as.double))
```

```
## # A tibble: 445 × 7
##     `1992`  `1994`  `1995`  `1996`  `1997`  `1998`  `1999`
##      <dbl>   <dbl>   <dbl>   <dbl>   <dbl>   <dbl>   <dbl>
##  1 255866. 262645. 271747. 276777. 282190. 291100. 300727.
##  2 110977. 111603. 115281. 116787. 120867. 123842. 127799.
##  3  32947.  31737.  32281.  32803.  34340.  33553.  35048.
##  4  12091.  11834.  11938.  12097.  13919.  13679.  14424.
##  5  12276.  12483.  12749.  13169.  13285.  13952.  14192.
##  6   5062.   5180.   5447.   5643.   5668.   5839.   5920.
##  7  11714.  12164.  12756.  12895.  13144.  13516.  13867.
##  8   8500.   8723.   9320.   8781.   8928.   9176.   9708.
##  9   4219.   4387.   4523.   4511.   4581.   5646.   5282.
## 10   6074.   6126.   6577.   6812.   7020.   7646.   7929.
## # i 435 more rows
```

```
#BIP von 1992 - 1999 umformen (als numerische Variab
bip_wide %>%
  select(`1992`:`1999`) %>%
  mutate(across(is.character, as.double)) ->
bip_double
```

Entsprechend dann bei den Einwohnern und Erwerbstätigen:

> Es wird eine Warnmeldung ausgegeben das `NA`s bei der Umwandlung erzeugt wurden. Warum?

```
# Erwerbstätige von 1992 - 1999 umformen (als numerische Variable)
erwerb_double <- erwerb_wide %>%
  select(`1992`:`1999`) %>%
  mutate(across(is.character, as.double))
```

```
## Warning: There were 7 warnings in `mutate()`.
## The first warning was:
## i In argument: `across(is.character, as.double)`.
## Caused by warning:
## ! NAs durch Umwandlung erzeugt
## i Run `dplyr::last_dplyr_warnings()` to see the 6 remaining warnings.
```

```
# Einwohner von 1992 - 1999 umformen (als numerische Variable)
einwohner_double <- einwohner_wide %>%
  select(`1992`:`1999`) %>%
  mutate(across(is.character, as.double))
```

```
## Warning: There were 7 warnings in `mutate()`.
## The first warning was:
## i In argument: `across(is.character, as.double)`.
## Caused by warning:
```

Daten in das `long`-Format überführen

Wir überprüfen, welche Spalten die Warnung hervorgerufen haben und wo `NA`s erzeugt wurden

```
bip_wide_test <- bip_wide %>%
  bind_cols(bip_double)

head(filter(bip_wide_test, is.na(`1992...31`)))
```

```
## # A tibble: 6 × 37
##   Regionalschluessel `1992...2` `1994...3` `1995...4` `1996...5` `1997...6`
##   <chr>              <chr>      <chr>      <chr>      <chr>      <chr>
## 1 13003              .          .          .          .          .
## 2 13004              .          .          .          .          .
## 3 13071              .          .          .          .          .
## 4 13072              .          .          .          .          .
## 5 13073              .          .          .          .          .
## 6 13074              .          .          .          .          .
## # i 31 more variables: `1998...7` <chr>, `1999...8` <chr>, `2000` <dbl>,
## #   `2001` <dbl>, `2002` <dbl>, `2003` <dbl>, `2004` <dbl>, `2005` <dbl>,
## #   `2006` <dbl>, `2007` <dbl>, `2008` <dbl>, `2009` <dbl>, `2010` <dbl>,
## #   `2011` <dbl>, `2012` <dbl>, `2013` <dbl>, `2014` <dbl>, `2015` <dbl>,
## #   `2016` <dbl>, `2017` <dbl>, `2018` <dbl>, `2019` <dbl>, `2020` <dbl>,
```

Eine Umwandlung zu `NA` geschieht bei den Werten bei denen – eingetragen wurde. D.h. für uns ist es ok hier ein `NA` einzutragen. Somit können wir die Umwandlung in die Klasse `double` durchführen:

```
bip_wide <- bip_wide %>%
  select(-(`1992`:`1999`)) %>%
  bind_cols(bip_double)

erwerb_wide <- erwerb_wide %>%
  select(-(`1992`:`1999`)) %>%
  bind_cols(erwerb_double)

einwohner_wide <- einwohner_wide %>%
  select(-(`1992`:`1999`)) %>%
  bind_cols(einwohner_double)
```

Daten in das `long`-Format überführen

Nun können wir den Datensatz ins `long`-Format transferieren und nach dem Jahr sortieren.

- Einwohner und Erwerbstätigen in 1000 Personen angegeben, daher Erwerbstätigen und Einwohner mit 1000 multiplizieren.
- BIP ist in 1 Mio. Euro angegeben, daher die Multiplikation mit 1 Mio.

```r
# BIP ins long-Format
pivot_longer(bip_wide, cols = c("2000":"1999") , nam
```

```
## # A tibble: 12,905 × 3
##    Regionalschluessel Jahr      bip
##    <chr>              <chr>   <dbl>
##  1 08                 2000  308823.
##  2 08                 2001  323078.
##  3 08                 2002  325510.
##  4 08                 2003  329164.
##  5 08                 2004  333276.
##  6 08                 2005  335789.
##  7 08                 2006  357283.
##  8 08                 2007  377021.
##  9 08                 2008  381903.
## 10 08                 2009  353463.
## # i 12,895 more rows
```

```r
# BIP ins long-Format
pivot_longer(bip_wide, cols = c("2000":"1999") , nam
  mutate( Jahr = as.numeric(Jahr),
          bip = bip * 1000000)
```

```
## # A tibble: 12,905 × 3
##    Regionalschluessel  Jahr          bip
##    <chr>              <dbl>        <dbl>
##  1 08                  2000 308822815000
##  2 08                  2001 323077717000
##  3 08                  2002 325510403000
##  4 08                  2003 329164078000
##  5 08                  2004 333275845000
##  6 08                  2005 335788716000
##  7 08                  2006 357283378000
##  8 08                  2007 377021382000
##  9 08                  2008 381902739000
## 10 08                  2009 353462984000
## # i 12,895 more rows
```

```r
# BIP ins long-Format
pivot_longer(bip_wide, cols = c("2000":"1999") , nam
  mutate( Jahr = as.numeric(Jahr),
          bip = bip * 1000000) %>%
  arrange( Jahr )
```

```
## # A tibble: 12,905 × 3
##    Regionalschluessel  Jahr          bip
##    <chr>              <dbl>        <dbl>
##  1 08                  1992 255866419000
##  2 081                 1992 110977071000
##  3 08111               1992  32946884000
##  4 08115               1992  12090930000
##  5 08116               1992  12275605000
##  6 08117               1992   5062037000
##  7 08118               1992  11714160000
##  8 08119               1992   8500405000
##  9 08121               1992   4219259000
## 10 08125               1992   6073525000
## # i 12,895 more rows
```

```
# BIP ins long-Format
pivot_longer(bip_wide, cols = c("2000":"1999") , nam
  mutate( Jahr = as.numeric(Jahr),
          bip = bip * 1000000) %>%
  arrange( Jahr ) ->
bip_long
```

Für die Erwerbstätigen und Einwohner entsprechend:

```
# Anzahl der Erwerbstätigen ins long-Format
erwerb_long <- pivot_longer(erwerb_wide, cols = c("2000":"1999") , names_to = "Jahr", values_to = "erw") %>%
  mutate( Jahr = as.numeric(Jahr),
          erw = erw * 1000) %>%
  arrange( Jahr )

# Anzahl der Einwohner ins long-Format
einwohner_long <- pivot_longer(einwohner_wide, cols = c("2000":"1999") , names_to = "Jahr", values_to = "einw
  mutate( Jahr = as.numeric(Jahr),
          einwohner = einwohner * 1000) %>%
  arrange( Jahr )
```

Konsistenzchecks

Hier sollten Sie selbst aktiv werden und die Daten auf Konsistenz prüfen:

> Als Konsistenzcheck könnten Sie hier die Anzahl der Einwohner aus den verschiedenen Datensätzen vergleichen.

Kartenmaterial hinzufügen

Wir benötigen hier eine Karte von Deutschland mit den einzelnen Verwaltungsgrenzen als SHAPE-File und können diese mittels des `sf`-Pakets einlesen.

Das OpenData Portal des Bundesamts für Kartographie und Geodäsie stellt die nötigen Informationen kostenlos zur Verfügung.

Die Dokumentation der Daten sollten wir uns immer zuerst anschauen, bevor wir die Datenquelle herunterladen.

Dies gilt nicht nur für die Geodaten, sondern allgemein für alle Datenreihen.

> Bitte versuchen Sie selbst die Daten herunterzuladen und anhand des Regionalschlüssels (ARS) mit dem BIP, den Arbeitslosen und den Schulden zusammenzuführen.

Datensätze zusammenführen

> Nun möchten wir die unterschiedlichen Datensätze noch zu einem zusammenfügen!

Zuerst müssen wir folgende Schritte unternehmen:

- ✚ Informationen zur Verschuldung auf Landkreisebene aggregieren
- ✚ Daten zum BIP auf das Jahr 2021 einschränken.
- ✚ Datensätze anhand des Regionalschlüssels miteinander verbinden.

Weiterhin können wir die geografischen Daten separat abspeichern und bei Bedarf anhand des Regionalschlüssels zu unserem Datensatz hinzumergen.

```
# Schulden auf Landkreisebene
schulden_bereinigt
```

```
## # A tibble: 10,785 × 8
##    Regionalschluessel Gemeinde          Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>             <chr>                <dbl>           <db
##  1 010010000000       Flensburg, Stadt  kreisfreie Sta…     89949      4545394
##  2 010020000000       Kiel, Landeshau…  kreisfreie Sta…    245841     10390951
##  3 010030000000       Lübeck, Hansest…  kreisfreie Sta…    215051     10908908
##  4 010040000000       Neumünster, Sta…  kreisfreie Sta…     79683      4532156
##  5 010510011011       Brunsbüttel, St…  amtsfreie Geme…     12324       546411
##  6 010510044044       Heide, Stadt      amtsfreie Geme…     21515       428548
##  7 010515163003       Averlak           amtsangehörige…       554        19173
##  8 010515163010       Brickeln          amtsangehörige…       200        11765
##  9 010515163012       Buchholz          amtsangehörige…       997        19766
## 10 010515163016       Burg (Dithmarsc…  amtsangehörige…      4166       103599
## # i 10,775 more rows
## # i 3 more variables: Schulden_pro_kopf <dbl>, Bundesland <chr>,
## #   landkreis <chr>
```

```r
# Schulden auf Landkreisebene
schulden_bereinigt %>%
  group_by(landkreis)
```

```
## # A tibble: 10,785 × 8
## # Groups:   landkreis [396]
##    Regionalschluessel Gemeinde         Verwaltungsform Einwohner Schulden_gesa
##    <chr>              <chr>            <chr>               <dbl>           <db
##  1 010010000000       Flensburg, Stadt kreisfreie Sta…     89949      4545394
##  2 010020000000       Kiel, Landeshau… kreisfreie Sta…    245841     10390951
##  3 010030000000       Lübeck, Hansest… kreisfreie Sta…    215051     10908908
##  4 010040000000       Neumünster, Sta… kreisfreie Sta…     79683      4532156
##  5 010510011011       Brunsbüttel, St… amtsfreie Geme…     12324       546411
##  6 010510044044       Heide, Stadt     amtsfreie Geme…     21515       428548
##  7 010515163003       Averlak          amtsangehörige…       554        19173
##  8 010515163010       Brickeln         amtsangehörige…       200        11765
##  9 010515163012       Buchholz         amtsangehörige…       997        19766
## 10 010515163016       Burg (Dithmarsc… amtsangehörige…      4166       103599
## # i 10,775 more rows
## # i 3 more variables: Schulden_pro_kopf <dbl>, Bundesland <chr>,
## #   landkreis <chr>
```

```r
# Schulden auf Landkreisebene
schulden_bereinigt %>%
  group_by(landkreis) %>%
  summarise( Schulden_pro_kopf_lk = sum(Schulden_ges
             Einwohner = sum(Einwohner),
             Schulden_gesamt = sum(Schulden_gesamt))
```

```
## # A tibble: 396 × 4
##    landkreis Schulden_pro_kopf_lk Einwohner Schulden_gesamt
##    <chr>                    <dbl>     <dbl>           <dbl>
##  1 01001                    5053.     89949      454539446.
##  2 01002                    4227.    245841     1039095143.
##  3 01003                    5073.    215051     1090890891.
##  4 01004                    5688.     79683      453215674.
##  5 01051                    2826.    133401      376925967.
##  6 01053                    1613.    199992      322536846.
##  7 01054                    3206.    167710      537632139.
##  8 01055                    2405.    202229      486299418.
##  9 01056                    2917.    317385      925938817.
## 10 01057                    2333.    129640      302408108.
## # i 386 more rows
```

```r
# Schulden auf Landkreisebene
schulden_bereinigt %>%
  group_by(landkreis) %>%
  summarise( Schulden_pro_kopf_lk = sum(Schulden_ges
             Einwohner = sum(Einwohner),
             Schulden_gesamt = sum(Schulden_gesamt))
  rename(Regionalschluessel = landkreis)
```

```
## # A tibble: 396 × 4
##    Regionalschluessel Schulden_pro_kopf_lk Einwohner Schulden_gesamt
##    <chr>                             <dbl>     <dbl>           <dbl>
##  1 01001                              5053.     89949      454539446.
##  2 01002                              4227.    245841     1039095143.
##  3 01003                              5073.    215051     1090890891.
##  4 01004                              5688.     79683      453215674.
##  5 01051                              2826.    133401      376925967.
##  6 01053                              1613.    199992      322536846.
##  7 01054                              3206.    167710      537632139.
##  8 01055                              2405.    202229      486299418.
##  9 01056                              2917.    317385      925938817.
## 10 01057                              2333.    129640      302408108.
## # i 386 more rows
```

```
# Schulden auf Landkreisebene
schulden_bereinigt %>%
  group_by(landkreis) %>%
  summarise( Schulden_pro_kopf_lk = sum(Schulden_ges
             Einwohner = sum(Einwohner),
             Schulden_gesamt = sum(Schulden_gesamt))
  rename(Regionalschluessel = landkreis) ->
schulden_kombi
```

```r
# Anzahl an Erwerbstätigen für das Jahr 2021
erwerb_long
```

```
## # A tibble: 12,905 × 3
##    Regionalschluessel  Jahr     erw
##    <chr>              <dbl>   <dbl>
##  1 08                  1992 5230587
##  2 081                 1992 2046858
##  3 08111               1992  486895
##  4 08115               1992  188312
##  5 08116               1992  237498
##  6 08117               1992  118140
##  7 08118               1992  223059
##  8 08119               1992  176939
##  9 08121               1992   94510
## 10 08125               1992  115906
## # i 12,895 more rows
```

```r
# Anzahl an Erwerbstätigen für das Jahr 2021
erwerb_long %>%
  filter(nchar(Regionalschluessel) == 5 & Jahr == 20
```

```
## # A tibble: 399 × 3
##    Regionalschluessel  Jahr    erw
##    <chr>              <dbl>  <dbl>
##  1 08111               2021 532593
##  2 08115               2021 226864
##  3 08116               2021 280672
##  4 08117               2021 119505
##  5 08118               2021 268651
##  6 08119               2021 205809
##  7 08121               2021  98279
##  8 08125               2021 180424
##  9 08126               2021  73805
## 10 08127               2021 115040
## # i 389 more rows
```

```r
# Anzahl an Erwerbstätigen für das Jahr 2021
erwerb_long %>%
  filter(nchar(Regionalschluessel) == 5 & Jahr == 20
  select(-Jahr)
```

```
## # A tibble: 399 × 2
##    Regionalschluessel    erw
##    <chr>               <dbl>
##  1 08111              532593
##  2 08115              226864
##  3 08116              280672
##  4 08117              119505
##  5 08118              268651
##  6 08119              205809
##  7 08121               98279
##  8 08125              180424
##  9 08126               73805
## 10 08127              115040
## # i 389 more rows
```

```r
# Anzahl an Erwerbstätigen für das Jahr 2021
erwerb_long %>%
  filter(nchar(Regionalschluessel) == 5 & Jahr == 20
  select(-Jahr) ->
erwerb_kombi
```

```r
# Anzahl an Einwohner für das Jahr 2021
einwohner_long
```

```
## # A tibble: 12,905 × 3
##    Regionalschluessel  Jahr einwohner
##    <chr>              <dbl>     <dbl>
##  1 08                  1992  10050431
##  2 081                 1992   3771006
##  3 08111               1992    593628
##  4 08115               1992    343190
##  5 08116               1992    487370
##  6 08117               1992    248688
##  7 08118               1992    475248
##  8 08119               1992    389670
##  9 08121               1992    118566
## 10 08125               1992    283163
## # i 12,895 more rows
```

```r
# Anzahl an Einwohner für das Jahr 2021
einwohner_long %>%
  filter(nchar(Regionalschluessel) == 5 & Jahr == 20
```

```
## # A tibble: 399 × 3
##    Regionalschluessel  Jahr einwohner
##    <chr>              <dbl>     <dbl>
##  1 08111               2021    628290
##  2 08115               2021    393047
##  3 08116               2021    533503
##  4 08117               2021    258914
##  5 08118               2021    544825
##  6 08119               2021    427301
##  7 08121               2021    126036
##  8 08125               2021    347081
##  9 08126               2021    113042
## 10 08127               2021    198629
## # i 389 more rows
```

```r
# Anzahl an Einwohner für das Jahr 2021
einwohner_long %>%
  filter(nchar(Regionalschluessel) == 5 & Jahr == 20
  select(-Jahr)
```

```
## # A tibble: 399 × 2
##    Regionalschluessel einwohner
##    <chr>                  <dbl>
##  1 08111                628290
##  2 08115                393047
##  3 08116                533503
##  4 08117                258914
##  5 08118                544825
##  6 08119                427301
##  7 08121                126036
##  8 08125                347081
##  9 08126                113042
## 10 08127                198629
## # i 389 more rows
```

```
# Anzahl an Einwohner für das Jahr 2021
einwohner_long %>%
  filter(nchar(Regionalschluessel) == 5 & Jahr == 20
  select(-Jahr) ->
einwohner_kombi
```

```
# Anzahl der Einwohner mit dem BIP verbinden um das
left_join(bip_long, einwohner_long, by=c("Regionalsc
```

```
## # A tibble: 12,905 × 4
##    Regionalschluessel  Jahr          bip einwohner
##    <chr>              <dbl>        <dbl>     <dbl>
##  1 08                  1992 255866419000  10050431
##  2 081                 1992 110977071000   3771006
##  3 08111               1992  32946884000    593628
##  4 08115               1992  12090930000    343190
##  5 08116               1992  12275605000    487370
##  6 08117               1992   5062037000    248688
##  7 08118               1992  11714160000    475248
##  8 08119               1992   8500405000    389670
##  9 08121               1992   4219259000    118566
## 10 08125               1992   6073525000    283163
## # i 12,895 more rows
```

```r
# Anzahl der Einwohner mit dem BIP verbinden um das
left_join(bip_long, einwohner_long, by=c("Regionalsc
  mutate(bip_pro_kopf = bip / einwohner)
```

```
## # A tibble: 12,905 × 5
##    Regionalschluessel  Jahr          bip einwohner bip_pro_kopf
##    <chr>              <dbl>        <dbl>     <dbl>        <dbl>
##  1 08                  1992 255866419000  10050431       25458.
##  2 081                 1992 110977071000   3771006       29429.
##  3 08111               1992  32946884000    593628       55501.
##  4 08115               1992  12090930000    343190       35231.
##  5 08116               1992  12275605000    487370       25187.
##  6 08117               1992   5062037000    248688       20355.
##  7 08118               1992  11714160000    475248       24649.
##  8 08119               1992   8500405000    389670       21814.
##  9 08121               1992   4219259000    118566       35586.
## 10 08125               1992   6073525000    283163       21449.
## # i 12,895 more rows
```

```r
# Anzahl der Einwohner mit dem BIP verbinden um das
left_join(bip_long, einwohner_long, by=c("Regionalsc
  mutate(bip_pro_kopf = bip / einwohner) %>%
# BIP auf Landkreisebene
  filter(nchar(Regionalschluessel) == 5 & Jahr == 20
```

```
## # A tibble: 399 × 5
##    Regionalschluessel  Jahr         bip einwohner bip_pro_kopf
##    <chr>              <dbl>       <dbl>     <dbl>        <dbl>
##  1 08111               2021 54983349000    628290       87513.
##  2 08115               2021 26471627000    393047       67350.
##  3 08116               2021 23940184000    533503       44874.
##  4 08117               2021  8665366000    258914       33468.
##  5 08118               2021 24894174000    544825       45692.
##  6 08119               2021 16119439000    427301       37724.
##  7 08121               2021  7598902000    126036       60292.
##  8 08125               2021 21144932000    347081       60922.
##  9 08126               2021  6241990000    113042       55218.
## 10 08127               2021  9549854000    198629       48079.
## # i 389 more rows
```

```r
# Anzahl der Einwohner mit dem BIP verbinden um das
left_join(bip_long, einwohner_long, by=c("Regionalsc
  mutate(bip_pro_kopf = bip / einwohner) %>%
# BIP auf Landkreisebene
  filter(nchar(Regionalschluessel) == 5 & Jahr == 20
  select(-c(Jahr, einwohner))
```

```
## # A tibble: 399 × 3
##    Regionalschluessel         bip bip_pro_kopf
##    <chr>                    <dbl>        <dbl>
##  1 08111               54983349000       87513.
##  2 08115               26471627000       67350.
##  3 08116               23940184000       44874.
##  4 08117                8665366000       33468.
##  5 08118               24894174000       45692.
##  6 08119               16119439000       37724.
##  7 08121                7598902000       60292.
##  8 08125               21144932000       60922.
##  9 08126                6241990000       55218.
## 10 08127                9549854000       48079.
## # i 389 more rows
```

```
# Anzahl der Einwohner mit dem BIP verbinden um das
left_join(bip_long, einwohner_long, by=c("Regionalsc
  mutate(bip_pro_kopf = bip / einwohner) %>%
# BIP auf Landkreisebene
  filter(nchar(Regionalschluessel) == 5 & Jahr == 20
  select(-c(Jahr, einwohner)) ->
bip_kombi
```

```r
# Datensätze zusammenführen

# Basisdatensatz -> Arbeitslosenzahlen pro Landkreis
# Namen der Bundesländer zumergen
alo_landkreis
```

```
## # A tibble: 400 × 2
##    Regionalschluessel total_alo
##    <chr>                  <dbl>
##  1 01001                  4369.
##  2 01002                 11097.
##  3 01003                  9347.
##  4 01004                  3771.
##  5 01051                  4143.
##  6 01053                  5603.
##  7 01054                  4699
##  8 01055                  5371
##  9 01056                  9371.
## 10 01057                  2854.
## # i 390 more rows
```

```r
# Datensätze zusammenführen

# Basisdatensatz -> Arbeitslosenzahlen pro Landkreis
# Namen der Bundesländer zumergen
alo_landkreis %>%
  mutate(bundesland = str_extract(Regionalschluessel
```

```
## # A tibble: 400 × 3
##    Regionalschluessel total_alo bundesland
##    <chr>                  <dbl> <chr>
##  1 01001                  4369. 01
##  2 01002                 11097. 01
##  3 01003                  9347. 01
##  4 01004                  3771. 01
##  5 01051                  4143. 01
##  6 01053                  5603. 01
##  7 01054                  4699  01
##  8 01055                  5371  01
##  9 01056                  9371. 01
## 10 01057                  2854. 01
## # i 390 more rows
```

```r
# Datensätze zusammenführen

# Basisdatensatz -> Arbeitslosenzahlen pro Landkreis
# Namen der Bundesländer zumergen
alo_landkreis %>%
  mutate(bundesland = str_extract(Regionalschluessel
  left_join(., schulden_kombi, by = "Regionalschlues
```

```
## # A tibble: 400 × 6
##    Regionalschluessel total_alo bundesland Schulden_pro_kopf_lk Einwohner
##    <chr>                  <dbl> <chr>                      <dbl>     <dbl>
##  1 01001                  4369. 01                         5053.     89949
##  2 01002                 11097. 01                         4227.    245841
##  3 01003                  9347. 01                         5073.    215051
##  4 01004                  3771. 01                         5688.     79683
##  5 01051                  4143. 01                         2826.    133401
##  6 01053                  5603. 01                         1613.    199992
##  7 01054                  4699  01                         3206.    167710
##  8 01055                  5371  01                         2405.    202229
##  9 01056                  9371. 01                         2917.    317385
## 10 01057                  2854. 01                         2333.    129640
## # i 390 more rows
## # i 1 more variable: Schulden_gesamt <dbl>
```

```r
# Datensätze zusammenführen

# Basisdatensatz -> Arbeitslosenzahlen pro Landkreis
# Namen der Bundesländer zumergen
alo_landkreis %>%
  mutate(bundesland = str_extract(Regionalschluessel
  left_join(., schulden_kombi, by = "Regionalschlues
  left_join(., bip_kombi, by = "Regionalschluessel")
```

```
## # A tibble: 400 × 8
##    Regionalschluessel total_alo bundesland Schulden_pro_kopf_lk Einwohner
##    <chr>                  <dbl> <chr>                      <dbl>     <dbl>
##  1 01001                  4369. 01                         5053.     89949
##  2 01002                 11097. 01                         4227.    245841
##  3 01003                  9347. 01                         5073.    215051
##  4 01004                  3771. 01                         5688.     79683
##  5 01051                  4143. 01                         2826.    133401
##  6 01053                  5603. 01                         1613.    199992
##  7 01054                  4699  01                         3206.    167710
##  8 01055                  5371  01                         2405.    202229
##  9 01056                  9371. 01                         2917.    317385
## 10 01057                  2854. 01                         2333.    129640
## # i 390 more rows
## # i 3 more variables: Schulden_gesamt <dbl>, bip <dbl>, bip_pro_kopf <dbl>
```

```r
# Datensätze zusammenführen

# Basisdatensatz -> Arbeitslosenzahlen pro Landkreis
# Namen der Bundesländer zumergen
alo_landkreis %>%
  mutate(bundesland = str_extract(Regionalschluessel
  left_join(., schulden_kombi, by = "Regionalschlues
  left_join(., bip_kombi, by = "Regionalschluessel")
# Zahl der Erwerbstätigen zumergen
  left_join(., erwerb_kombi, by = "Regionalschluesse
```

```
## # A tibble: 400 × 9
##    Regionalschluessel total_alo bundesland Schulden_pro_kopf_lk Einwohner
##    <chr>                  <dbl> <chr>                      <dbl>     <dbl>
##  1 01001                  4369. 01                         5053.     89949
##  2 01002                 11097. 01                         4227.    245841
##  3 01003                  9347. 01                         5073.    215051
##  4 01004                  3771. 01                         5688.     79683
##  5 01051                  4143. 01                         2826.    133401
##  6 01053                  5603. 01                         1613.    199992
##  7 01054                  4699  01                         3206.    167710
##  8 01055                  5371  01                         2405.    202229
##  9 01056                  9371. 01                         2917.    317385
## 10 01057                  2854. 01                         2333.    129640
## # i 390 more rows
## # i 4 more variables: Schulden_gesamt <dbl>, bip <dbl>, bip_pro_kopf <dbl>,
## #   erw <dbl>
```

```
# Datensätze zusammenführen

# Basisdatensatz -> Arbeitslosenzahlen pro Landkreis
# Namen der Bundesländer zumergen
alo_landkreis %>%
  mutate(bundesland = str_extract(Regionalschluessel
  left_join(., schulden_kombi, by = "Regionalschlues
  left_join(., bip_kombi, by = "Regionalschluessel")
# Zahl der Erwerbstätigen zumergen
  left_join(., erwerb_kombi, by = "Regionalschluesse
gesamtdaten
```

```
# Datensätze zusammenführen

# Basisdatensatz -> Arbeitslosenzahlen pro Landkreis
# Namen der Bundesländer zumergen
alo_landkreis %>%
  mutate(bundesland = str_extract(Regionalschluessel
  left_join(., schulden_kombi, by = "Regionalschlues
  left_join(., bip_kombi, by = "Regionalschluessel")
# Zahl der Erwerbstätigen zumergen
  left_join(., erwerb_kombi, by = "Regionalschluesse
gesamtdaten

#saveRDS(gesamtdaten, "data/gesamtdaten.rds")  #save
```

```r
# Datensätze zusammenführen

# Basisdatensatz -> Arbeitslosenzahlen pro Landkreis
# Namen der Bundesländer zumergen
alo_landkreis %>%
  mutate(bundesland = str_extract(Regionalschluessel
  left_join(., schulden_kombi, by = "Regionalschlues
  left_join(., bip_kombi, by = "Regionalschluessel")
# Zahl der Erwerbstätigen zumergen
  left_join(., erwerb_kombi, by = "Regionalschluesse
gesamtdaten

#saveRDS(gesamtdaten, "data/gesamtdaten.rds")  #save
#saveRDS(schulden_bereinigt, "data/schulden_bereinig
```

```
# Datensätze zusammenführen

# Basisdatensatz -> Arbeitslosenzahlen pro Landkreis
# Namen der Bundesländer zumergen
alo_landkreis %>%
  mutate(bundesland = str_extract(Regionalschluessel
  left_join(., schulden_kombi, by = "Regionalschlues
  left_join(., bip_kombi, by = "Regionalschluessel")
# Zahl der Erwerbstätigen zumergen
  left_join(., erwerb_kombi, by = "Regionalschluesse
gesamtdaten

#saveRDS(gesamtdaten, "data/gesamtdaten.rds")  #save
#saveRDS(schulden_bereinigt, "data/schulden_bereinig
#saveRDS(bip_zeitreihe, "data/bip_zeitreihe.rds")   #
```

Übungsaufgaben

Laden Sie sich das durchschnittliche Arbeitnehmerentgelt pro Arbeitnehmer und Landkreis auf der Seite der Statistischen Ämter des Bundes und der Länder herunter und lesen Sie diesen in R ein.

- Finden Sie in dem heruntergeladenen Datensatz heraus, was der Unterschied zwischen *Arbeitnehmerentgelt* und *Bruttolöhne- und Gehälter* ist.
- Lesen Sie die für Sie relevante Tabelle *Bruttolöhne- und Gehälter* in R ein.
- Bereinigen Sie die Tabelle, d.h. der Datensatz sollte danach `tidy` sein.
- Berechnen Sie die Bruttolöhne pro Bundesland mit den Bruttolöhnen der einzelnen Landkreise als Konsistenzcheck.