

**Corona-Rechtsprechung  
des  
Bundesverfassungsgerichts  
(BVerfG-Corona-Source)**

COMPILATION REPORT

Version 2021-09-19

License MIT-0

DOI: 10.5281/zenodo.5532938

<b>Titel</b>	Source Code der »Corona-Rechtsprechung des Bundesverfassungsgerichts«
<b>Abkürzung</b>	BVerfG-Corona-Source
<b>Autor</b>	Seán Fobbe
<b>Version</b>	2021-09-19
<b>Download</b>	<a href="https://doi.org/10.5281/zenodo.5532938">https://doi.org/10.5281/zenodo.5532938</a>
<b>Lizenz</b>	MIT No Attribution (MIT-0)

### Zitiervorschlag

*Seán Fobbe* (2021). Source Code der »Corona-Rechtsprechung des Bundesverfassungsgerichts« (BVerfG-Corona-Source). Version 2021-09-19. Zenodo. DOI: 10.5281/zenodo.5532938.

### Digital Object Identifier (DOI): Concept DOI und Version DOI

Soweit nicht anders angegeben ist die DOI immer eine »Version DOI« und bezieht sich nur auf eine bestimmte Version der Software. Sie verlinkt daher nur Version 2021-09-19. Für das Gesamtkonzept der Software steht eine »Concept DOI« zur Verfügung, die auf der Zenodo-Seite jeder Version unter »Cite all versions?« zu finden ist. Sie lautet 10.5281/zenodo.4459415. Die »Concept DOI« verlinkt immer die aktuellste Version.

### Lizenz: MIT No Attribution (MIT-0)

Copyright — 2021— Seán Fobbe

Permission is hereby granted, free of charge, to any person obtaining a copy of this software and associated documentation files (the »Software«), to deal in the Software without restriction, including without limitation the rights to use, copy, modify, merge, publish, distribute, sublicense, and/or sell copies of the Software, and to permit persons to whom the Software is furnished to do so.

THE SOFTWARE IS PROVIDED »AS IS«, WITHOUT WARRANTY OF ANY KIND, EXPRESS OR IMPLIED, INCLUDING BUT NOT LIMITED TO THE WARRANTIES OF MERCHANTABILITY, FITNESS FOR A PARTICULAR PURPOSE AND NONINFRINGEMENT. IN NO EVENT SHALL THE AUTHORS OR COPYRIGHT HOLDERS BE LIABLE FOR ANY CLAIM, DAMAGES OR OTHER LIABILITY, WHETHER IN AN ACTION OF CONTRACT, TORT OR OTHERWISE, ARISING FROM, OUT OF OR IN CONNECTION WITH THE SOFTWARE OR THE USE OR OTHER DEALINGS IN THE SOFTWARE.

### Disclaimer

Dieser Datensatz ist eine private wissenschaftliche Initiative und steht in keiner Verbindung zu Behörden, Gerichten oder anderen amtlichen Stellen der Bundesrepublik Deutschland.

# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	<b>5</b>
1.1	Überblick . . . . .	5
1.2	Funktionsweise . . . . .	5
1.3	Systemanforderungen . . . . .	5
1.4	Kompilierung . . . . .	6
<b>2</b>	<b>Parameter</b>	<b>7</b>
2.1	Name des Datensatzes . . . . .	7
2.2	Datumsstempel . . . . .	7
2.3	DOI der konkreten Datensatz-Version (CE-BVerfG) . . . . .	7
2.4	DOI der konkreten Datensatz-Version (BVerfG-Corona) . . . . .	7
2.5	Verzeichnis für Analyse-Ergebnisse . . . . .	7
2.6	Optionen: Quanteda . . . . .	7
2.7	Optionen: Knitr . . . . .	8
2.7.1	Ausgabe-Format . . . . .	8
2.7.2	DPI für Raster-Grafiken . . . . .	8
2.7.3	Ausrichtung von Grafiken im Compilation Report . . . . .	8
2.8	Frequenztabellen: Ignorierte Variablen . . . . .	8
<b>3</b>	<b>Vorbereitung</b>	<b>9</b>
3.1	Datum und Uhrzeit (Beginn) . . . . .	9
3.2	Ordner für Analyse-Ergebnisse erstellen . . . . .	9
3.3	Packages . . . . .	9
3.4	Zusätzliche Funktionen einlesen . . . . .	10
3.5	Quanteda-Optionen setzen . . . . .	10
3.6	Knitr Optionen setzen . . . . .	10
3.7	Vollzitate statistischer Software . . . . .	10
3.8	Parallelisierung aktivieren . . . . .	11
3.8.1	Anzahl logischer Kerne bestimmen . . . . .	11
3.8.2	Quanteda . . . . .	11
3.8.3	Data.table . . . . .	11
<b>4</b>	<b>Stamm-Datensatz einlesen (CE-BVerfG)</b>	<b>12</b>
4.1	Download der CSV-Datei . . . . .	12
4.2	CSV-Datei einlesen . . . . .	12
4.3	ZIP-Archiv löschen . . . . .	13
4.4	Korpus-Objekt erstellen . . . . .	13
<b>5</b>	<b>Keywords in Context (KWIC)</b>	<b>14</b>
5.1	Tokenisierung . . . . .	14
5.2	KWIC-Analyse durchführen . . . . .	14
5.3	KWIC-Tabelle speichern . . . . .	14
<b>6</b>	<b>Lexical Dispersion Plot</b>	<b>15</b>
6.1	Rechteckiges Format . . . . .	15
6.2	A4-Format . . . . .	17
<b>7</b>	<b>TXT-Datensatz erstellen</b>	<b>19</b>

7.1	Namen der Corona-Entscheidungen definieren . . . . .	19
7.2	Anzahl der TXT-Dateien . . . . .	19
7.3	TXT-Datensatz herunterladen . . . . .	19
7.4	ZIP-Archiv entpacken . . . . .	19
7.5	Corona-Entscheidungen verpacken . . . . .	20
7.6	TXT-Dateien löschen . . . . .	20
7.7	ZIP-Archiv löschen . . . . .	20
<b>8</b>	<b>PDF-Datensatz erstellen</b>	<b>21</b>
8.1	Namen der Corona-Entscheidungen definieren . . . . .	21
8.2	Anzahl der PDF-Dateien . . . . .	21
8.3	PDF-Datensatz herunterladen . . . . .	21
8.4	ZIP-Archiv entpacken . . . . .	21
8.5	Corona-Entscheidungen verpacken . . . . .	22
8.6	PDF-Dateien löschen . . . . .	22
8.7	ZIP-Archiv löschen . . . . .	22
<b>9</b>	<b>Frequenztabellen erstellen</b>	<b>23</b>
9.1	CE-BVerfG auf Corona-Entscheidungen reduzieren . . . . .	23
9.2	Funktion anzeigen: f.fast.freqtable . . . . .	23
9.3	Ignorierte Variablen . . . . .	24
9.4	Liste zu prüfender Variablen . . . . .	24
9.5	Frequenztabellen erstellen . . . . .	25
<b>10</b>	<b>Diagramm Kopieren</b>	<b>32</b>
<b>11</b>	<b>Erstellen der ZIP-Archive</b>	<b>33</b>
11.1	Verpacken der Analyse-Dateien . . . . .	33
11.2	Verpacken der Source-Dateien . . . . .	33
<b>12</b>	<b>Kryptographische Hashes</b>	<b>34</b>
12.1	Liste der ZIP-Archive erstellen . . . . .	34
12.2	Funktion anzeigen . . . . .	34
12.3	Hashes berechnen . . . . .	35
12.4	In Data Table umwandeln . . . . .	35
12.5	Index hinzufügen . . . . .	35
12.6	In Datei schreiben . . . . .	36
12.7	Leerzeichen hinzufügen um Zeilenumbruch zu ermöglichen . . . . .	36
12.8	In Bericht anzeigen . . . . .	36
<b>13</b>	<b>Abschluss</b>	<b>38</b>
13.1	Datumsstempel . . . . .	38
13.2	Datum und Uhrzeit (Anfang) . . . . .	38
13.3	Datum und Uhrzeit (Ende) . . . . .	38
13.4	Laufzeit des gesamten Skriptes . . . . .	38
13.5	Warnungen . . . . .	38
<b>14</b>	<b>Parameter für strenge Replikationen</b>	<b>39</b>
	<b>Literaturverzeichnis</b>	<b>40</b>

# 1 Einleitung

## 1.1 Überblick

Dieses R-Skript lädt den Corpus der Entscheidungen des Bundesverfassungsgerichts (CE-BVerfG) herunter, untersucht ihn auf mit SARS-CoV-2 assoziiertem Vokabular und speichert relevante Entscheidungen. Es ist die Grundlage für den Datensatz **Corona-Rechtsprechung des Bundesverfassungsgerichts (BVerfG-Corona)**.

Alle mit diesem Skript erstellten Datensätze werden dauerhaft kostenlos und urheberrechtsfrei auf Zenodo, dem wissenschaftlichen Archiv des CERN, veröffentlicht. Alle Versionen sind mit einem persistenten Digital Object Identifier (DOI) versehen. Die neueste Version des Datensatzes ist immer über den Link der Concept DOI erreichbar: <https://doi.org/10.5281/zenodo.4459405>

## 1.2 Funktionsweise

Primäre Endprodukte des Skripts sind folgende ZIP-Archive:

1. Alle Corona-relevanten Entscheidungen im PDF-Format
2. Alle Corona-relevanten Entscheidungen im TXT-Format
3. Alle Analyse-Ergebnisse (Tabellen als CSV, Grafiken als PDF und PNG)
4. Der Source Code und alle weiteren Quelldaten

Zusätzlich werden für alle ZIP-Archive kryptographische Signaturen (SHA2-256 und SHA3-512) berechnet und in einer CSV-Datei hinterlegt. Es kann optional ein PDF-Bericht erstellt werden (siehe unter “Kompilierung”).

## 1.3 Systemanforderungen

Das Skript in seiner veröffentlichten Form kann nur unter Linux ausgeführt werden, da es Linux-spezifische Optimierungen (z.B. Fork Cluster) und Shell-Kommandos (z.B. OpenSSL) nutzt. Das Skript wurde unter Fedora Linux entwickelt und getestet. Die zur Kompilierung benutzte Version entnehmen Sie bitte dem **sessionInfo()**-Ausdruck am Ende dieses Berichts.

In der Standard-Einstellung wird das Skript vollautomatisch die maximale Anzahl an Rechenkernen/Threads auf dem System zu nutzen. Wenn die Anzahl Threads (Variable “fullCores”) auf 1 gesetzt wird, ist die Parallelisierung deaktiviert.

Auf der Festplatte sollten 4 GB Speicherplatz vorhanden sein.

Um die PDF-Berichte kompilieren zu können benötigen Sie das R package **rmarkdown**, eine vollständige Installation von  $\text{\LaTeX}$  und alle in der Präambel-TEX-Datei angegebenen  $\text{\LaTeX}$  Packages.

## 1.4 Kompilierung

Mit der Funktion `render()` von `rmarkdown` kann der **vollständige Datensatz** kompiliert und das Skript mitsamt seinen Rechenergebnisse in ein gut lesbares PDF-Format überführt werden.

Alle Kommentare sind im roxygen2-Stil gehalten. Das Skript kann daher auch **ohne** `render()` regulär als R-Skript ausgeführt werden. Es wird in diesem Fall kein PDF-Bericht erstellt und Diagramme werden nicht abgespeichert.

Um den vollständigen Datensatz zu kompilieren und einen PDF-Bericht zu erstellen, kopieren Sie bitte alle im Source-Archiv bereitgestellten Dateien in einen leeren Ordner und führen mit R diesen Befehl aus:

```
rmarkdown::render(input = "BVerfG-Corona_Source_CorpusCreation.R",
                  output_file = paste0("BVerfG-Corona_2021-09-19_
CompilationReport.pdf"),
                  envir = new.env())
```

## 2 Parameter

### 2.1 Name des Datensatzes

```
datasetname <- "BVerfG-Corona"
```

### 2.2 Datumsstempel

Dieser Datumsstempel wird in alle Dateinamen eingefügt. Er richtet sich nach der Version des Stamm-Datensatzes.

```
datestamp <- "2021-09-19"
```

### 2.3 DOI der konkreten Datensatz-Version (CE-BVerfG)

Aus diesem Datensatz werden die Entscheidungen bezogen.

```
doi.version.cebverfg <- "10.5281/zenodo.5514083" # checked
```

### 2.4 DOI der konkreten Datensatz-Version (BVerfG-Corona)

In diesen Datensatz werden die Corona-relevanten Entscheidungen überführt.

```
doi.version <- "10.5281/zenodo.5532937" # checked
```

### 2.5 Verzeichnis für Analyse-Ergebnisse

Hinweis: Muss mit einem Schrägstrich enden!

```
outputdir <- paste0(getwd(),  
                    "/ANALYSE/")
```

### 2.6 Optionen: Quanteda

```
tokens_locale <- "de_DE"
```

## 2.7 Optionen: Knitr

### 2.7.1 Ausgabe-Format

```
dev <- c("pdf",  
        "png")
```

### 2.7.2 DPI für Raster-Grafiken

```
dpi <- 300
```

### 2.7.3 Ausrichtung von Grafiken im Compilation Report

```
fig.align <- "center"
```

## 2.8 Frequenztabellen: Ignorierte Variablen

Diese Variablen werden bei der Erstellung der Frequenztabellen nicht berücksichtigt.

```
varremove <- c("text",  
              "eingangsnummer",  
              "datum",  
              "doc_id",  
              "seite",  
              "name",  
              "ecli",  
              "aktenzeichen",  
              "aktenzeichen_alle",  
              "zeichen",  
              "tokens",  
              "typen",  
              "saetze",  
              "version",  
              "pressemittteilung",  
              "zitiervorschlag",  
              "kurzbeschreibung")
```



## 3 Vorbereitung

### 3.1 Datum und Uhrzeit (Beginn)

```
begin.script <- Sys.time()
print(begin.script)
```

```
## [1] "2021-09-28 00:29:47 CEST"
```

### 3.2 Ordner für Analyse-Ergebnisse erstellen

```
dir.create(outputdir)
```

### 3.3 Packages

```
library(doParallel) # Parallelisierung
```

```
## Loading required package: foreach
```

```
## Loading required package: iterators
```

```
## Loading required package: parallel
```

```
library(ggplot2) # Fortgeschrittene Datenvisualisierung
library(rmarkdown) # Wissenschaftliches Reporting
library(knitr) # Wissenschaftliches Reporting
library(kableExtra) # Verbesserte Kable Tabellen
library(data.table) # Fortgeschrittene Datenverarbeitung
```

```
## data.table 1.14.0 using 8 threads (see ?getDTthreads). Latest news: r-
  datatable.com
```

```
library(quanteda) # Fortgeschrittenes Natural Language Processing
```

```
## Package version: 3.1.0
## Unicode version: 13.0
## ICU version: 67.1
```

```
## Parallel computing: 16 of 16 threads used.
```

```
## See https://quanteda.io for tutorials and examples.
```

```
library(quanteda.textplots) # Quanteda: Diagramme
```

### 3.4 Zusätzliche Funktionen einlesen

**Hinweis:** Die hieraus verwendeten Funktionen werden jeweils vor der ersten Benutzung in vollem Umfang angezeigt um den Lesefluss zu verbessern.

```
source("General_Source_Functions.R")
```

### 3.5 Quanteda-Optionen setzen

```
quanteda_options(tokens_locale = tokens_locale)
```

### 3.6 Knitr Optionen setzen

```
knitr::opts_chunk$set(fig.path = outputdir,
                      dev = dev,
                      dpi = dpi,
                      fig.align = fig.align)
```

### 3.7 Vollzitate statistischer Software

```
knitr::write_bib(c(.packages()),
                 "packages.bib")
```

```
## tweaking foreach
```

## 3.8 Parallelisierung aktivieren

Parallelisierung wird zur Datenanalyse mittels **quanteda** und **data.table** verwendet. Die Anzahl Threads wird automatisch auf das verfügbare Maximum des Systems gesetzt, kann aber auch nach Belieben auf das eigene System angepasst werden. Die Parallelisierung kann deaktiviert werden, indem die Variable **fullCores** auf 1 gesetzt wird.

Die hier verwendete Funktion **makeForkCluster()** ist viel schneller als die Alternativen, funktioniert aber nur auf Unix-basierten Systemen (Linux, MacOS).

### 3.8.1 Anzahl logischer Kerne bestimmen

```
fullCores <- detectCores()
print(fullCores)
```

```
## [1] 16
```

### 3.8.2 Quanteda

```
quanteda_options(threads = fullCores)
```

### 3.8.3 Data.table

```
setDTthreads(threads = fullCores)
```

## 4 Stamm-Datensatz einlesen (CE-BVerfG)

Der Stamm-Datensatz ist der »Corpus der Entscheidungen des Bundesverfassungsgerichts« (CE-BVerfG). Dieser enthält alle vom Bundesverfassungsgericht seit 1998 veröffentlichten Entscheidungen. Dessen **aktuellste** Version ist immer über diesen Digital Object Identifier (DOI) abrufbar: <https://doi.org/10.5281/zenodo.3902658>

### 4.1 Download der CSV-Datei

Der Datensatz im CSV-Format wird automatisch über einen verschlüsselten und langzeit-stabilen Link aus dem wissenschaftlichen Archiv des CERN heruntergeladen. Dieses Vorgehen garantiert die Verwendung einer authentischen Version des Datensatzes.

```
zip.csv <- paste0("CE-BVerfG_",
                 datestamp,
                 "_DE_CSV_Datensatz.zip")

print(zip.csv)
```

```
## [1] "CE-BVerfG_2021-09-19_DE_CSV_Datensatz.zip"
```

```
link.csv <- paste0("https://zenodo.org/record/",
                  gsub("10\\.5281/zenodo\\.([0-9]+)",
                      "\\1",
                      doi.version.cebverfg),
                  "/files/",
                  zip.csv,
                  "?download=1")

print(link.csv)
```

```
## [1] "https://zenodo.org/record/5514083/files/CE-BVerfG_2021-09-19_DE_CSV_
    Datensatz.zip?download=1"
```

```
if(file.exists(zip.csv) == FALSE){

  download.file(link.csv,
               zip.csv)

}
```

### 4.2 CSV-Datei einlesen

```
dt.bverfg <- fread(cmd = paste("unzip -cq",
                               zip.csv))
```

### 4.3 ZIP-Archiv löschen

```
unlink(zip.csv)
```

### 4.4 Korpus-Objekt erstellen

```
corpus.bverfg <- corpus(dt.bverfg)
```

## 5 Keywords in Context (KWIC)

Bei einer KWIC-Analyse (keywords in context) wird nach einer bestimmten Zeichengefolge gesucht und sowohl diese, als auch die angrenzenden Wörter werden angezeigt. Konkret wird an dieser Stelle eine alternative Suche nach den Mustern “Corona”, “COVID” oder “SARS-CoV” durchgeführt. Groß- und Kleinschreibung wird ignoriert um eventuelle Tippfehler zu vernachlässigen. Das Sichtfenster wird auf 15 Tokens vor und nach dem Treffer gesetzt.

### 5.1 Tokenisierung

```
tokens <- tokens(corpus.bverfg,
  what = "word",
  remove_punct = FALSE,
  remove_symbols = FALSE,
  remove_numbers = FALSE,
  remove_url = FALSE,
  remove_separators = TRUE,
  split_hyphens = FALSE,
  include_docvars = TRUE,
  padding = FALSE)
```

### 5.2 KWIC-Analyse durchführen

```
kwic <- kwic(tokens,
  pattern = "(Corona) | (COVID) | (SARS-CoV)",
  window = 15,
  valuetype = "regex",
  case_insensitive = TRUE)
```

### 5.3 KWIC-Tabelle speichern

```
file.kwic.sansdate <- paste(datasetname,
  "02_KeywordsInContext.csv",
  sep = "_")

file.kwic.date <- paste(datasetname,
  datestamp,
  "ANALYSE_02_KeywordsInContext.csv",
  sep = "_")

fwrite(data.frame(kwic),
  paste0(outputdir,
  file.kwic.sansdate))

fwrite(data.frame(kwic),
  file.kwic.date)
```


## 6 Lexical Dispersion Plot

Lexical Dispersion Plots zeigen mit einem vertikalen Strich an, an welcher Stelle in einem Dokument sich ein Token befindet. Alle Dokumente sind auf eine Länge von 1.0 normalisiert, d.h. ein Wert von 0.5 heißt immer, dass sich das Token in der Mitte des jeweiligen Dokumentes befindet. Viele und/oder dicke Striche deuten auf eine große Häufigkeit des Tokens hin.

### 6.1 Rechteckiges Format

```
textplot_xray(kwic,
              scale = "relative")+
  labs(
    title = paste(datasetname,
                  "| Version",
                  datestamp,
                  "| Lexical Dispersion Plot"),
    caption = paste("DOI:",
                   doi.version,
                   "| Fobbe"))+
  theme(
    text = element_text(size = 14),
    plot.title = element_text(size = 14,
                              face = "bold"),
    legend.position = "none",
    plot.margin = margin(10, 20, 10, 10)
  )
```

BVerfG-Corona | Version 2021-09-19 | Lexical Dispersion Plot




DOI: 10.5281/zenodo.5532937 | Fobbe



## 6.2 A4-Format

```
textplot_xray(kwic,
              scale = "relative")+
  labs(
    title = paste(datasetname,
                  "| Version",
                  datestamp,
                  "| Lexical Dispersion Plot"),
    caption = paste("DOI:",
                   doi.version,
                   "| Fobbe"))+
  theme(
    text = element_text(size = 14),
    plot.title = element_text(size = 14,
                              face = "bold"),
    legend.position = "none",
    plot.margin = margin(10, 20, 10, 10)
  )
```

### BVerfG-Corona | Version 2021-09-19 | Lexical Dispersion Plot



## 7 TXT-Datensatz erstellen

### 7.1 Namen der Corona-Entscheidungen definieren

```
keep.txt <- unique(kwic$docname)
```

### 7.2 Anzahl der TXT-Dateien

```
length(keep.txt)
```

```
## [1] 95
```

### 7.3 TXT-Datensatz herunterladen

```
zip.txt <- paste0("CE-BVerfG_",
                 datestamp,
                 "_DE_TXT_Datensatz.zip")

link.txt <- paste0("https://zenodo.org/record/",
                  gsub("10\\.5281/zenodo\\.([0-9]+)",
                       "\\1",
                       doi.version.cebverfg),
                  "/files/",
                  zip.txt,
                  "?download=1")

if(file.exists(zip.txt) == FALSE){

  download.file(link.txt,
               zip.txt)

}
```

### 7.4 ZIP-Archiv entpacken

```
unzip(zip.txt)
```

## 7.5 Corona-Entscheidungen verpacken

```
zip(paste(datasetname,  
          datestamp,  
          "DE_TXT_Datensatz.zip",  
          sep = "_"),  
    keep.txt)
```

## 7.6 TXT-Dateien löschen

```
files.txt <- list.files(pattern = ".txt")  
unlink(files.txt)
```

## 7.7 ZIP-Archiv löschen

```
unlink(zip.txt)
```

## 8 PDF-Datensatz erstellen

### 8.1 Namen der Corona-Entscheidungen definieren

```
keep.pdf <- gsub(".txt",  
                ".pdf",  
                keep.txt)
```

### 8.2 Anzahl der PDF-Dateien

```
length(keep.pdf)
```

```
## [1] 95
```

### 8.3 PDF-Datensatz herunterladen

```
zip.pdf <- paste0("CE-BVerfG_",  
                 datestamp,  
                 "_DE_PDF_Datensatz.zip")  
  
link.pdf <- paste0("https://zenodo.org/record/",  
                  gsub("10\\.5281/zenodo\\.([0-9]+)",  
                      "\\1",  
                      doi.version.cebverfg),  
                  "/files/",  
                  zip.pdf,  
                  "?download=1")  
  
if(file.exists(zip.pdf) == FALSE){  
  download.file(link.pdf,  
               zip.pdf)  
}
```

### 8.4 ZIP-Archiv entpacken

```
unzip(zip.pdf)
```

## 8.5 Corona-Entscheidungen verpacken

```
zip(paste(datasetname,  
          datestamp,  
          "DE_PDF_Datensatz.zip",  
          sep = "_"),  
    keep.pdf)
```

## 8.6 PDF-Dateien löschen

```
files.pdf <- list.files(pattern = ".pdf")  
unlink(files.pdf)
```

## 8.7 ZIP-Archiv löschen

```
unlink(zip.pdf)
```

## 9 Frequenztabellen erstellen

### 9.1 CE-BVerfG auf Corona-Entscheidungen reduzieren

```
dt.corona <- dt.bverfg[doc_id %in% keep.txt]
```

### 9.2 Funktion anzeigen: f.fast.freqtable

```
print(f.fast.freqtable)
```

```
function(x, varlist = names(x), sumrow = TRUE, output.list = TRUE, output.kable = FALSE, output.csv = FALSE, outputdir = "./", prefix = „“, align = "r"){
```

```
## Begin List
freqtable.list <- vector("list", length(varlist))

## Calculate Frequency Table
for (i in seq_along(varlist)){

  varname <- varlist[i]

  freqtable <- x[, .N, keyby=c(paste0(varname))]

  freqtable[, c("exactpercent",
               "roundedpercent",
               "cumulpercent") := {
    exactpercent <- N/sum(N)*100
    roundedpercent <- round(exactpercent, 2)
    cumulpercent <- round(cumsum(exactpercent), 2)
    list(exactpercent,
         roundedpercent,
         cumulpercent)}]

  ## Calculate Summary Row
  if (sumrow == TRUE){
    colsums <- cbind("Total",
                    freqtable[, lapply(.SD, function(x){round(sum(x))}),
                    .SDcols = c("N",
                                "exactpercent",
                                "roundedpercent")
                    ], round(max(freqtable$cumulpercent)))

    colnames(colsums)[c(1,5)] <- c(varname, "cumulpercent")
    freqtable <- rbind(freqtable, colsums)
  }

  ## Add Frequency Table to List
  freqtable.list[[i]] <- freqtable

  ## Write CSV
```

```

if (output.csv == TRUE){
  fwrite(freqtable,
         paste0(outputdir,
                prefix,
                varname,
                ".csv"),
         na = "NA")
}

## Output Kable
if (output.kable == TRUE){
  cat("\n-----\n")
  cat(paste0("Frequency Table for Variable:  ", varname, "\n"))
  cat("-----\n")
  cat(paste0("\n ",
            x[, .N, keyby=c(paste0(varname))][, .N],
            " unique value(s) detected.\n\n"))

  print(kable(freqtable,
             format = "latex",
             align = align,
             booktabs = TRUE,
             longtable = TRUE) %>% kable_styling(latex_options = "repeat_
header"))
}
}

## Return List of Frequency Tables
if (output.list == TRUE){
  return(freqtable.list)
}
}
}

```

### 9.3 Ignorierte Variablen

```
print(varremove)
```

```

## [1] "text"           "eingangsnummer"  "datum"
## [4] "doc_id"         "seite"           "name"
## [7] "ecli"           "aktenzeichen"    "aktenzeichen_alle"
## [10] "zeichen"        "tokens"          "typen"
## [13] "saetze"         "version"         "pressemittteilung"
## [16] "zitiervorschlag" "kurzbeschreibung"

```

### 9.4 Liste zu prüfender Variablen



```

varlist <- names(dt.corona)

varlist <- setdiff(varlist,
                   varremove)

print(varlist)

```

```

## [1] "gericht"           "entscheidung_typ" "spruchkoerper_typ"
## [4] "spruchkoerper_az" "registerzeichen"  "verfahrensart"
## [7] "eingangsjahr_az" "eingangsjahr_iso" "entscheidungsjahr"
## [10] "kollision"        "band"             "praesi"
## [13] "v_praesi"         "richter"          "doi_concept"
## [16] "doi_version"      "lizenz"

```

## 9.5 Frequenztabellen erstellen

```

prefix <- paste0(datasetname,
                  "_00_Frequenztafel_var-")

```

```

f.fast.freqtable(dt.corona,
                 varlist = varlist,
                 sumrow = TRUE,
                 output.list = FALSE,
                 output.kable = TRUE,
                 output.csv = TRUE,
                 outputdir = outputdir,
                 prefix = prefix,
                 align = c("p{5cm}",
                           rep("r", 4)))

```

---

Frequency Table for Variable: gericht

---

1 unique value(s) detected.

gericht	N	exactpercent	roundedpercent	cumulpercent
BVerfG	95	100	100	100
Total	95	100	100	100

---

---

Frequency Table for Variable: entscheidung\_typ

---

---

1 unique value(s) detected.

entscheidung_typ	N	exactpercent	roundedpercent	cumulpercent
B	95	100	100	100
Total	95	100	100	100

---

---

Frequency Table for Variable: spruchkoerper\_typ

---

---

2 unique value(s) detected.

spruchkoerper_typ	N	exactpercent	roundedpercent	cumulpercent
K	83	87.36842	87.37	87.37
S	12	12.63158	12.63	100.00
Total	95	100.00000	100.00	100.00

---

---

Frequency Table for Variable: spruchkoerper\_az

---

---

2 unique value(s) detected.

spruchkoerper_az	N	exactpercent	roundedpercent	cumulpercent
1	72	75.78947	75.79	75.79
2	23	24.21053	24.21	100.00
Total	95	100.00000	100.00	100.00

---

---

Frequency Table for Variable: registerzeichen

---

---

4 unique value(s) detected.

registerzeichen	N	exactpercent	roundedpercent	cumulpercent
BvC	4	4.210526	4.21	4.21
BvE	2	2.105263	2.11	6.32
BvQ	29	30.526316	30.53	36.84
BvR	60	63.157895	63.16	100.00
Total	95	100.000000	100.00	100.00

Frequency Table for Variable: verfahrensart

4 unique value(s) detected.

verfahrensart	N	exactpercent	roundedpercent	cumulpercent
Einstweilige Anordnungen	29	30.526316	30.53	30.53
Organstreitverfahren	2	2.105263	2.11	32.63
Verfassungsbeschwerden; Kommunalverfassungsbe- schwerden	60	63.157895	63.16	95.79
Wahlprüfungsverfahren	4	4.210526	4.21	100.00
Total	95	100.000000	100.00	100.00

Frequency Table for Variable: eingangsjahr\_az

4 unique value(s) detected.

ingangsjahr_az	N	exactpercent	roundedpercent	cumulpercent
15	1	1.052632	1.05	1.05
18	1	1.052632	1.05	2.11
20	68	71.578947	71.58	73.68
21	25	26.315790	26.32	100.00
Total	95	100.000000	100.00	100.00

---

Frequency Table for Variable: eingangsjahr\_iso

---

4 unique value(s) detected.

eingangsjahr_iso	N	exactpercent	roundedpercent	cumulpercent
2015	1	1.052632	1.05	1.05
2018	1	1.052632	1.05	2.11
2020	68	71.578947	71.58	73.68
2021	25	26.315790	26.32	100.00
Total	95	100.000000	100.00	100.00

---

Frequency Table for Variable: entscheidungsjahr

---

2 unique value(s) detected.

entscheidungsjahr	N	exactpercent	roundedpercent	cumulpercent
2020	63	66.31579	66.32	66.32
2021	32	33.68421	33.68	100.00
Total	95	100.00000	100.00	100.00

---

Frequency Table for Variable: kollision

---

1 unique value(s) detected.

kollision	N	exactpercent	roundedpercent	cumulpercent
NA	95	100	100	100
Total	95	100	100	100

---

Frequency Table for Variable: band

---

1 unique value(s) detected.

band	N	exactpercent	roundedpercent	cumulpercent
NA	95	100	100	100
Total	95	100	100	100

Frequency Table for Variable: praesi

2 unique value(s) detected.

praesi	N	exactpercent	roundedpercent	cumulpercent
Harbarth	55	57.89474	57.89	57.89
Voßkuhle	40	42.10526	42.11	100.00
Total	95	100.00000	100.00	100.00

Frequency Table for Variable: v\_praesi

2 unique value(s) detected.

v_praesi	N	exactpercent	roundedpercent	cumulpercent
Harbarth	40	42.10526	42.11	42.11
König	55	57.89474	57.89	100.00
Total	95	100.00000	100.00	100.00

Frequency Table for Variable: richter

14 unique value(s) detected.

richter	N	exactpercent	roundedpercent	cumulpercent
Baer Ott Radtk	11	11.578947	11.58	11.58
Harbarth Baer Ott	5	5.263158	5.26	16.84
Harbarth Britz Ott	2	2.105263	2.11	18.95
Harbarth Britz Radtk	24	25.263158	25.26	44.21
Harbarth Paulus Baer Britz Ott Crist Radtk Brettel	3	3.157895	3.16	47.37

(continued)

richter	N	exactpercent	roundedpercent	cumulpercent
Huber Kessal-Wulf König	5	5.263158	5.26	52.63
Huber Kessal-Wulf Wallrabenstein	4	4.210526	4.21	56.84
König Huber Hermanns Müller Kessal-Wulf Maidowski Langenfeld	1	1.052632	1.05	57.89
König Huber Hermanns Müller Kessal-Wulf Maidowski Langenfeld Wallrabenstein	1	8.421053	8.42	66.32
König Maidowski Wallrabenstein	1	1.052632	1.05	67.37
König Müller Maidowski	4	4.210526	4.21	71.58
Masing Paulus Christ	15	15.789474	15.79	87.37
Paulus Christ Härtel	11	11.578947	11.58	98.95
Paulus Christ Radtke	1	1.052632	1.05	100.00
Total	95	100.000000	100.00	100.00

Frequency Table for Variable: doi\_concept

1 unique value(s) detected.

doi_concept	N	exactpercent	roundedpercent	cumulpercent
10.5281/zenodo.3902658	95	100	100	100
Total	95	100	100	100

Frequency Table for Variable: doi\_version

1 unique value(s) detected.

doi_version	N	exactpercent	roundedpercent	cumulpercent
10.5281/zenodo.5514083	95	100	100	100
Total	95	100	100	100

---

Frequency Table for Variable: lizenz

---

1 unique value(s) detected.

lizenz	N	exactpercent	roundedpercent	cumulpercent
Creative Commons Zero 1.0 Universal	95	100	100	100
Total	95	100	100	100

## 10 Diagramm Kopieren

```
rechteckig <- list.files(outputdir, pattern = "Rechteckig.*\\.pdf",
                        full.names = TRUE)

rechteckig.path <- gsub("//",
                      "/",
                      rechteckig)

rechteckig.file <- gsub(".+//(.+)",
                      "\\1",
                      rechteckig)

rechteckig.file <- gsub("01",
                      paste0(datestamp,
                              "_ANALYSE_01"),
                      rechteckig.file)

rechteckig.file <- gsub("-1\\.pdf",
                      "\\1\\.pdf",
                      rechteckig.file)

file.copy(rechteckig.path,
          rechteckig.file)
```

```
## [1] TRUE
```



## 11 Erstellen der ZIP-Archive

### 11.1 Verpacken der Analyse-Dateien

```
zip(paste0(datasetname,  
           "_",  
           datestamp,  
           "_DE_",  
           basename(outputdir),  
           ".zip"),  
    basename(outputdir))
```

### 11.2 Verpacken der Source-Dateien

```
files.source <- c(list.files(pattern = "Source"),  
                 "buttons")  
  
files.source <- grep("spin",  
                   files.source,  
                   value = TRUE,  
                   ignore.case = TRUE,  
                   invert = TRUE)  
  
zip(paste(datasetname,  
          datestamp,  
          "Source_Files.zip",  
          sep = "_"),  
    files.source)
```

## 12 Kryptographische Hashes

Dieses Modul berechnet für jedes ZIP-Archiv zwei Arten von Hashes: SHA2-256 und SHA3-512. Mit diesen kann die Authentizität der Dateien geprüft werden und es wird dokumentiert, dass sie aus diesem Source Code hervorgegangen sind. Die SHA-2 und SHA-3 Algorithmen sind äußerst resistent gegenüber *collision* und *pre-imaging* Angriffen, sie gelten derzeit als kryptographisch sicher. Ein SHA3-Hash mit 512 bit Länge ist nach Stand von Wissenschaft und Technik auch gegenüber quantenkryptoanalytischen Verfahren unter Einsatz des *Grover-Algorithmus* hinreichend resistent.

### 12.1 Liste der ZIP-Archive erstellen

```
files.zip <- list.files(pattern = "\\\\.zip$",  
                        ignore.case = TRUE)
```

### 12.2 Funktion anzeigen

```
print(f.dopar.multihashes)
```

```
function(x, threads = detectCores()){
```

```
print(paste("Parallel processing using", threads, "threads."))  
  
begin <- Sys.time()  
  
cl <- makeForkCluster(threads)  
registerDoParallel(cl)  
  
multihashes <- foreach(filename = x,  
                        .errorhandling = 'pass',  
                        .combine = 'rbind') %dopar% {  
  
    sha2.256 <- system2("openssl",  
                       paste("sha256",  
                               filename),  
                       stdout = TRUE)  
  
    sha2.256 <- gsub("^.*\\|= ",  
                   "",  
                   sha2.256)  
  
    sha3.512 <- system2("openssl",  
                       paste("sha3-512",  
                               filename),  
                       stdout = TRUE)  
  
    sha3.512 <- gsub("^.*\\|= ",  
                   "",
```

```

                                sha3.512)
                                out <- data.frame(filename,
                                sha2.256,
                                sha3.512)
                                return(out)
                                }
stopCluster(cl)

end <- Sys.time()
duration <- end - begin

print(paste0("Processed ",
            length(x),
            " files. Runtime was ",
            round(duration,
            digits = 2),
            " ",
            attributes(duration)$units,
            "."))

return(multihashes)
}

```

### 12.3 Hashes berechnen

```
multihashes <- f.dopar.multihashes(files.zip)
```

```
## [1] "Parallel processing using 16 threads."
## [1] "Processed 4 files. Runtime was 0.32 secs."
```

### 12.4 In Data Table umwandeln

```
setDT(multihashes)
```

### 12.5 Index hinzufügen

```
multihashes$index <- seq_len(multihashes[,.N])
```

## 12.6 In Datei schreiben

```
fwrite(multihashes,  
      paste(datasetname,  
            datestamp,  
            "KryptographischeHashes.csv",  
            sep = "_"),  
      na = "NA")
```

## 12.7 Leerzeichen hinzufügen um Zeilenumbruch zu ermöglichen

```
multihashes$sha3.512 <- paste(substr(multihashes$sha3.512, 1, 64),  
                             substr(multihashes$sha3.512, 65, 128))
```

## 12.8 In Bericht anzeigen

```
kable(multihashes[,.(index,filename)],  
      format = "latex",  
      align = c("p{1cm}",  
               "p{13cm}"),  
      booktabs = TRUE,  
      longtable = TRUE)
```

---

index	filename
1	BVerfG-Corona_2021-09-19_DE_ANALYSE.zip
2	BVerfG-Corona_2021-09-19_DE_PDF_Datensatz.zip
3	BVerfG-Corona_2021-09-19_DE_TXT_Datensatz.zip
4	BVerfG-Corona_2021-09-19_Source_Files.zip

---

```
kable(multihashes[,.(index,sha2.256)],
      format = "latex",
      align = c("c",
                "p{13cm}"),
      booktabs = TRUE,
      longtable = TRUE)
```

---

index	sha2.256
1	226121ca85ad15ae31fbd89e7a7db9a3725fd5e9c832ec24e5239ff1e582be27
2	66420244e005f1f0bd5639702508dcbeec9e1a73a04505fdd472c1c2cad9831e
3	9478bedd036a9cca6fc23d2c024649170eb7ee834e2dd8691a06c513ace15dae
4	0ddbaf8fee08aea36311a6263121d59a94d052ae8076a86ca075c1fbbf1ed81a

---

```
kable(multihashes[,.(index,sha3.512)],
      format = "latex",
      align = c("c",
                "p{13cm}"),
      booktabs = TRUE,
      longtable = TRUE)
```

---

index	sha3.512
1	439797090ec33a752b355dbe91abfc48957ac6ca424a1e49df0a01c40b1286e4 4a54907dac089ef75c6cebc9f8289f8e94fc7fd59aaea786084656c60cccc988
2	6c88395c6d452180c2152c762d12efccb309e7af2f176a5889e8dc9d8e543e52 d15948b9ff52b7a98348774539646f4f3c8262307d380f2357da52cfd1c24971
3	c29ac69525586ebb7c5b818aecd23bf85f4c5e7d619fe0d78b011a182caec27e dc96be21a5a7cc9c43b9d181202ac6301020e73b49056f1793ca722565dc0bba
4	19d9f146361f73ef65cc9ab8e367e6c5acd9333e637f0439ee6d5531b1d01f2e e8cf117565a801d1c0c3cc81149f49e9c0cfed255d72796ad0c31e13f0f66a15

---

## 13 Abschluss

### 13.1 Datumsstempel

Hinweis: der Datumsstempel weicht vom Zeitpunkt der tatsächlichen Erstellung des Datensatzes ab, weil sich der Datumsstempel nach dem Tag des Abrufs des CE-BVerfG richtet.

```
print(datestamp)
```

```
## [1] "2021-09-19"
```

### 13.2 Datum und Uhrzeit (Anfang)

```
print(begin.script)
```

```
## [1] "2021-09-28 00:29:47 CEST"
```

### 13.3 Datum und Uhrzeit (Ende)

```
end.script <- Sys.time()  
print(end.script)
```

```
## [1] "2021-09-28 00:31:52 CEST"
```

### 13.4 Laufzeit des gesamten Skriptes

```
print(end.script - begin.script)
```

```
## Time difference of 2.08687 mins
```

### 13.5 Warnungen

```
warnings()
```

## 14 Parameter für strenge Replikationen

```
system2("openssl", "version", stdout = TRUE)
```

```
## [1] "OpenSSL 1.1.1l FIPS 24 Aug 2021"
```

```
sessionInfo()
```

```
## R version 4.0.5 (2021-03-31)
## Platform: x86_64-redhat-linux-gnu (64-bit)
## Running under: Fedora 34 (Workstation Edition)
##
## Matrix products: default
## BLAS/LAPACK: /usr/lib64/libflexiblas.so.3.0
##
## locale:
##  [1] LC_CTYPE=en_US.utf8      LC_NUMERIC=C
##  [3] LC_TIME=en_US.utf8      LC_COLLATE=en_US.utf8
##  [5] LC_MONETARY=en_US.utf8  LC_MESSAGES=en_US.utf8
##  [7] LC_PAPER=en_US.utf8    LC_NAME=C
##  [9] LC_ADDRESS=C           LC_TELEPHONE=C
## [11] LC_MEASUREMENT=en_US.utf8 LC_IDENTIFICATION=C
##
## attached base packages:
## [1] parallel stats      graphics grDevices utils      datasets methods
## [8] base
##
## other attached packages:
##  [1] quanteda.textplots_0.94 quanteda_3.1.0      data.table_1.14.0
##  [4] kableExtra_1.3.4      knitr_1.34          rmarkdown_2.10
##  [7] ggplot2_3.3.5         doParallel_1.0.16   iterators_1.0.13
## [10] foreach_1.5.1
##
## loaded via a namespace (and not attached):
##  [1] tidyselect_1.1.1  xfun_0.25          purrr_0.3.4        lattice_0.20-44
##  [5] colorspace_2.0-2 vctrs_0.3.8       generics_0.1.0     htmltools_0.5.2
##  [9] viridisLite_0.4.0 yaml_2.2.1         utf8_1.2.2         rlang_0.4.11
## [13] pillar_1.6.2     glue_1.4.2         withr_2.4.2        lifecycle_1.0.0
## [17] stringr_1.4.0    munsell_0.5.0     gtable_0.3.0       rvest_1.0.1
## [21] codetools_0.2-18 evaluate_0.14      labeling_0.4.2     fastmap_1.1.0
## [25] fansi_0.5.0     highr_0.9         Rcpp_1.0.7         scales_1.1.1
## [29] magick_2.7.3     RcppParallel_5.1.4 webshot_0.5.2      farver_2.1.0
## [33] systemfonts_1.0.2 fastmatch_1.1-3    stopwords_2.2      digest_0.6.27
## [37] stringi_1.7.4    dplyr_1.0.7       grid_4.0.5         tools_4.0.5
## [41] magrittr_2.0.1   tibble_3.1.4      crayon_1.4.1       pkgconfig_2.0.3
## [45] ellipsis_0.3.2   Matrix_1.3-4      xml2_1.3.2         svglite_2.0.0
## [49] httr_1.4.2       rstudioapi_0.13   R6_2.5.1           compiler_4.0.5
```

## Literaturverzeichnis

- Allaire, JJ, Yihui Xie, Jonathan McPherson, Javier Luraschi, Kevin Ushey, Aron Atkins, Hadley Wickham, Joe Cheng, Winston Chang, and Richard Iannone. 2021. *Rmarkdown: Dynamic Documents for R*. <https://CRAN.R-project.org/package=rmarkdown>.
- Analytics, Revolution, and Steve Weston. 2020. *Iterators: Provides Iterator Construct*. <https://github.com/RevolutionAnalytics/iterators>.
- Benoit, Kenneth, Kohei Watanabe, Haiyan Wang, Paul Nulty, Adam Obeng, Stefan Müller, and Akitaka Matsuo. 2018a. “Quanteda: An R Package for the Quantitative Analysis of Textual Data.” *Journal of Open Source Software* 3 (30): 774. <https://doi.org/10.21105/joss.00774>.
- . 2018b. “Quanteda: An R Package for the Quantitative Analysis of Textual Data.” *Journal of Open Source Software* 3 (30): 774. <https://doi.org/10.21105/joss.00774>.
- Benoit, Kenneth, Kohei Watanabe, Haiyan Wang, Paul Nulty, Adam Obeng, Stefan Müller, Akitaka Matsuo, and William Lowe. 2021. *Quanteda: Quantitative Analysis of Textual Data*. <https://quanteda.io>.
- Benoit, Kenneth, Kohei Watanabe, Haiyan Wang, Adam Obeng, Stefan Müller, and Akitaka Matsuo. 2021. *Quanteda.textplots: Plots for the Quantitative Analysis of Textual Data*. <https://CRAN.R-project.org/package=quanteda.textplots>.
- Corporation, Microsoft, and Steve Weston. 2020. *DoParallel: Foreach Parallel Adaptor for the Parallel Package*. <https://CRAN.R-project.org/package=doParallel>.
- Dowle, Matt, and Arun Srinivasan. 2021. *Data.table: Extension of ‘Data.frame’*. <https://CRAN.R-project.org/package=data.table>.
- R Core Team. 2021. *R: A Language and Environment for Statistical Computing*. Vienna, Austria: R Foundation for Statistical Computing. <https://www.R-project.org/>.
- Revolution Analytics, and Steve Weston. n.d. *Foreach: Provides Foreach Looping Construct*.
- Wickham, Hadley. 2016. *Ggplot2: Elegant Graphics for Data Analysis*. Springer-Verlag New York. <https://ggplot2.tidyverse.org>.
- Wickham, Hadley, Winston Chang, Lionel Henry, Thomas Lin Pedersen, Kohske Takahashi, Claus Wilke, Kara Woo, Hiroaki Yutani, and Dewey Dunnington. 2021. *Ggplot2: Create Elegant Data Visualisations Using the Grammar of Graphics*. <https://CRAN.R-project.org/package=ggplot2>.
- Xie, Yihui. 2014. “Knitr: A Comprehensive Tool for Reproducible Research in R.” In *Implementing Reproducible Computational Research*, edited by Victoria Stodden, Friedrich Leisch, and Roger D. Peng. Chapman; Hall/CRC. <http://www.crcpress.com/product/isbn/9781466561595>.
- . 2015. *Dynamic Documents with R and Knitr*. 2nd ed. Boca Raton, Florida: Chapman; Hall/CRC. <https://yihui.org/knitr/>.
- . 2021. *Knitr: A General-Purpose Package for Dynamic Report Generation in R*. <https://yihui.org/knitr/>.
- Xie, Yihui, J. J. Allaire, and Garrett Grolemond. 2018. *R Markdown: The Definitive Guide*. Boca Raton, Florida: Chapman; Hall/CRC. <https://bookdown.org/yihui/rmarkdown>.



- Xie, Yihui, Christophe Dervieux, and Emily Riederer. 2020. *R Markdown Cookbook*. Boca Raton, Florida: Chapman; Hall/CRC. <https://bookdown.org/yihui/rmarkdown-cookbook>.
- Zhu, Hao. 2021. *KableExtra: Construct Complex Table with Kable and Pipe Syntax*. <https://CRAN.R-project.org/package=kableExtra>.