

# Dateinamen & Ordnerstrukturen

---

📁 Ordnung halten 😎

Dr. Gabriele Schwiertz & Dr. Denis Arnold

2024-11-05

# Ordnung halten?

- Überblick behalten auf dem eigenen Rechner
- Für wen?
  - für mich: erleichtert mir die Arbeit
  - im Projekt: wenn ich mit anderen zusammenarbeite
  - für die Nachnutzung: wenn meine Daten auch in Zukunft benutzt werden sollen
  - für mich in der Zukunft: wenn ich in einem Jahr nochmal drauf gucken will

# Übersicht

- Übung: 3 Gruppen
- Prinzipien der Dateibenennung
- Prinzipien Ordnerstrukturen
- Versionierung
- Back-up-Strategien

# Übung: Dateinamen

- Ladet Euch den jeweiligen Ordner für Eure Gruppe aus Ilias runter
- Entzippt den Ordner und schaut Euch an, was drin ist
- Ihr habt eine Email von Eurem Professor bekommen:  
emailDringend.png
- Lest die Mail und versucht, den Auftrag auszuführen
- Schickt die fertige ppt-Datei an [gabriele.schwiertz@uni-koeln.de](mailto:gabriele.schwiertz@uni-koeln.de)
- Wenn ihr fertig seid, notiert, was an der Ordnerstruktur und den Dateinamen gut, bzw. schlecht war

# Übung: Ergebnisse

- Welche Gruppe war am schnellsten?
- Zeigt kurz, wie Ihr die Datei gefunden habt
- Was sind gute bzw. schlechte Praktiken in bezug auf Dateinamen und Ordnerstrukturen?



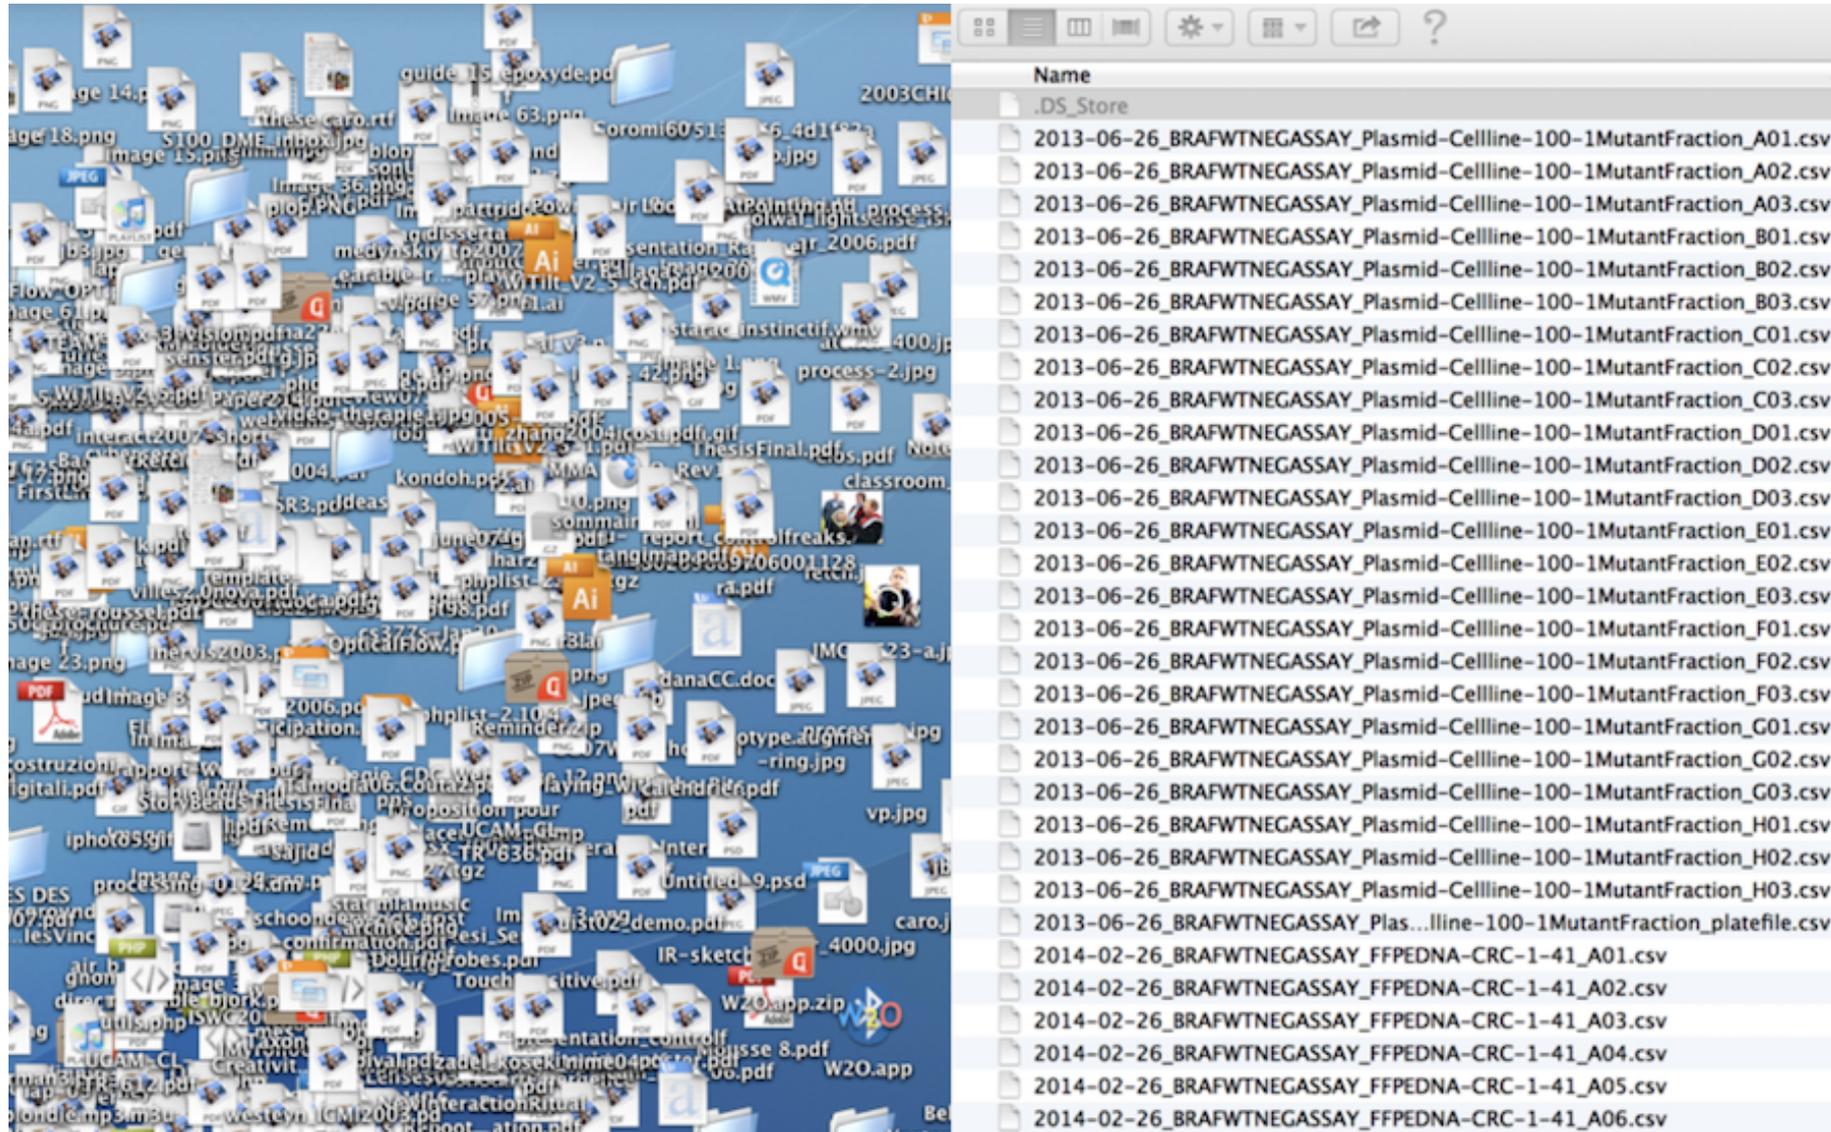
# Dateinamen



# Warum man über Dateinamen nachdenken sollte

- selbst in relativ simplen Projekten (Hausarbeit) gibt es viele Dateien
- sehr viele Dateien
- Dateien verändern sich
- Dateien stehen zueinander in Beziehung

# Es kann kompliziert werden..





# Strategien gegen das Dateienchaos

Dateinamen und Ordnerstrukturen können helfen!

Dateiname und Speicherort (Ordner, wo sich die Datei befindet) sollten direkt Auskunft geben über:

- Was die Datei ist
- Warum es sie gibt
- Wie ihre Beziehung zu anderen Dateien ist
- Je mehr Dinge selbsterklärend sind, desto besser!

# Gute und schlechte Namen



myabstract.docx

Joe's tolle Datei .txt

figure 2.png

fig1.png

JWD2(%

\$Nicht^löschenoderdukkannsteinpacken!!!!.xlsx



2022-10-01\_abstract\_for\_DAE.docx

JoeVerbessertSich.txt

fig01\_scatterplot\_butterfly\_density.png

fig02\_boxplot\_butterfly\_density.png

1986-04-22\_rawdata\_challenger.csv

# 3 Prinzipien für Dateinamen

1. Maschinenlesbar
2. Menschenlesbar
3. Klappt gut mit der Default-Sortierung

# Maschinenlesbar

- kann gut mit regulären Ausdrücken/globbing/filtern bearbeitet werden
  - keine Leerzeichen in Datei oder Ordnernamen
  - keine Interpunktionszeichen (!,?“.)
  - keine Sonderzeichen (ß, \*, |, ä, \$, の, ぱ, â, ø, 🕒)
- leicht in Skripte einzubauen
  - wohlbedachte Nutzung von Trennzeichen (\_ oder -)
- Case-Sensitivity beachten: a vs. A?

# Filtern und Suchen mit Globbing/Regulären Ausdrücken

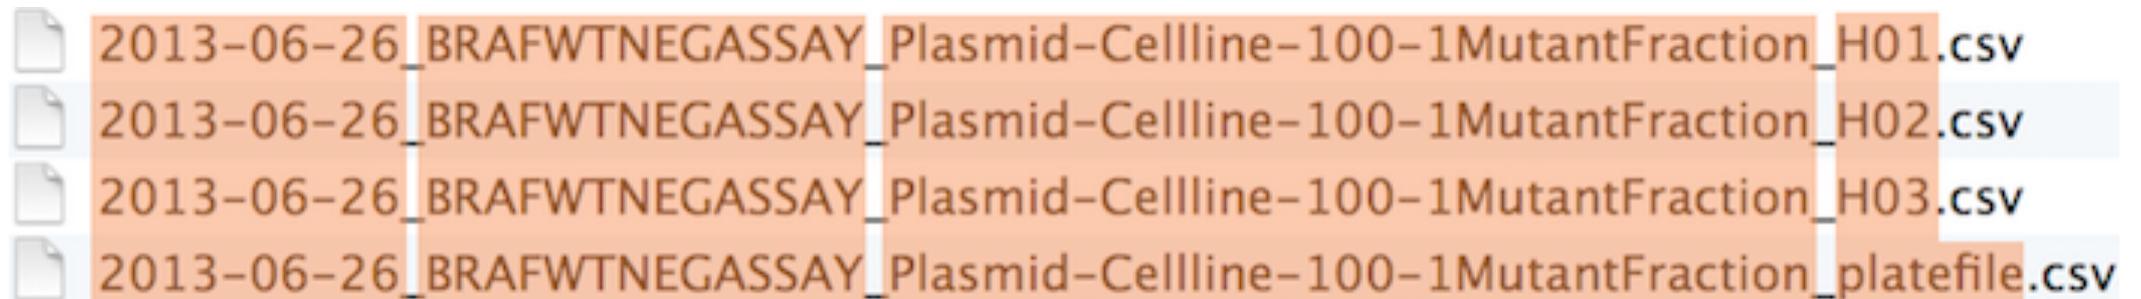
Auszüge aus Dateilisten Filtern:

- 2013-06-26\_BRAFWTNEGASSAY\_Plasmid-Cellline-100-1MutantFraction\_H01.csv
- 2013-06-26\_BRAFWTNEGASSAY\_Plasmid-Cellline-100-1MutantFraction\_H02.csv
- 2013-06-26\_BRAFWTNEGASSAY\_Plasmid-Cellline-100-1MutantFraction\_H03.csv
- 2013-06-26\_BRAFWTNEGASSAY\_Plasmid-Cellline-100-1MutantFraction\_platefile.csv
- 2014-02-26\_BRAFWTNEGASSAY\_FFPEDNA-CRC-1-41\_A01.csv
- 2014-02-26\_BRAFWTNEGASSAY\_FFPEDNA-CRC-1-41\_A02.csv
- 2014-02-26\_BRAFWTNEGASSAY\_FFPEDNA-CRC-1-41\_A03.csv
- 2014-02-26\_BRAFWTNEGASSAY\_FFPEDNA-CRC-1-41\_A04.csv

# Trennzeichen mit Bedeutung

Konsistente Nutzung von “-” und “\_” macht es möglich, Metadaten aus Dateinamen zu ziehen:

- Der Unterstrich “\_” trennt Metadaten-Einheiten, auf die man später zugreifen will
- Der Bindestrich “-” trennt Wörter o.ä. innerhalb dieser Einheiten



The image shows a list of four CSV files in a file explorer. Each file name is highlighted in orange, and the segments are separated by vertical lines. The segments are: 2013-06-26, BRAFWTNEGASSAY, Plasmid-Cellline-100-1MutantFraction, and H01.csv, H02.csv, H03.csv, and platefile.csv.

2013-06-26	BRAFWTNEGASSAY	Plasmid-Cellline-100-1MutantFraction	H01.csv
2013-06-26	BRAFWTNEGASSAY	Plasmid-Cellline-100-1MutantFraction	H02.csv
2013-06-26	BRAFWTNEGASSAY	Plasmid-Cellline-100-1MutantFraction	H03.csv
2013-06-26	BRAFWTNEGASSAY	Plasmid-Cellline-100-1MutantFraction	platefile.csv

# Trennzeichen mit Bedeutung

Metadaten-Information aus Dateinamen mit sinnvollen Trennzeichen können leicht in Tabellen extrahiert werden (z.B. mit R, der Shell, Python,...)

```
> flist <- list.files(pattern = "Plasmid") %>% head
```

```
> stringr::str_split_fixed(flist, "[_\\.]", 5)
```

	[,1]	[,2]	[,3]	[,4]	[,5]
[1,]	"2013-06-26"	"BRAFWTNEGASSAY"	"Plasmid-Cellline-100-1MutantFraction"	"A01"	"csv"
[2,]	"2013-06-26"	"BRAFWTNEGASSAY"	"Plasmid-Cellline-100-1MutantFraction"	"A02"	"csv"
[3,]	"2013-06-26"	"BRAFWTNEGASSAY"	"Plasmid-Cellline-100-1MutantFraction"	"A03"	"csv"
[4,]	"2013-06-26"	"BRAFWTNEGASSAY"	"Plasmid-Cellline-100-1MutantFraction"	"B01"	"csv"
[5,]	"2013-06-26"	"BRAFWTNEGASSAY"	"Plasmid-Cellline-100-1MutantFraction"	"B02"	"csv"
[6,]	"2013-06-26"	"BRAFWTNEGASSAY"	"Plasmid-Cellline-100-1MutantFraction"	"B03"	"csv"

date

assay

sample set

well

# Case-Sensitivity beachten: a vs. A?

- Manche Betriebssysteme machen einen Unterschied zwischen a und A
- Manche Betriebssysteme machen keinen Unterschied zwischen a und A
- Daher: Keine Dateinamen, die sich nur in Groß- und Kleinschreibung unterscheiden verwenden!
- Konsistent benennen



test.docx vs. Test.docx vs. TEST.docx

# Konsistente Benennung

in that case...



@allison\_horst



### snake\_case

Pros: Concise when it consists of a few words.  
Cons: Redundant as hell when it gets longer.  
`push_something_to_first_queue, pop_what, get_whatever...`



### PascalCase

Pros: Seems neat.  
`GetItem, SetItem, Convert, ...`  
Cons: Barely used. (why?)



### camelCase

Pros: Widely used in the programmer community.  
Cons: Looks ugly when a few methods are n-worded.  
`push, reserve, beginBuilding, ...`



### skewer-case

Pros: Easy to type.  
`easier-than-capitals, easier-than-underscore, ...`  
Cons: Any sane language freaks out when you try it.



### SCREAMING\_SNAKE\_CASE

Pros: Can demonstrate your anger with text.  
Cons: Makes your eyes deaf.  
`LOOK_AT_THIS, LOOK_AT_THAT, LOOK_HERE_YOU_MORON, ...`

### nocase

Pros: Looks professional.  
Cons: Misleading af.  
`supersexyhippotalamus, bool penisbig, ...`



### fUcKtHeCaSe

Pros: Can live outside of the law.  
Cons: Can be out of a job.

# Nicht zu lang

- Windows MAXPATH 260
- Der Pfad inklusive Dateiname darf nicht zu lang werden
- Das kann bei langen Datei- und Ordnernamen und tiefer Einbettung passieren
- Gleichgewicht zwischen zu vollen Ordnern und einer zu tiefen Einbettung in die Ordnerstruktur



```
"C:  
\Users\schiwertz\Documents\DataLiteracy\Beispielpfad\Communications\2018\Workshop  
\Entomology\ButterfliesMothsAndRelatedInsects\Analysis_preliminary  
\Scripts_for_Preparation\Python_2_7_1_1\Data_Cleaning_and_Wrangling  
\FirstPartButterfliesOnly\myplots\"
```

# Zusammenfassung: Maschinenlesbarkeit

- 👉 Macht das spätere Durchsuchen einfacher
- 👉 Macht das spätere Filtern einfacher
- 👉 Macht das Extrahieren von Informationen einfacher

Wenig Erfahrungen mit globbing und Regulären Ausdrücken? Dann lieber:

- 💀 keine Leerzeichen
- 💀 keine Interpunktionszeichen
- 💀 keine Sonderzeichen

- ✓ sinnvolle Trennzeichen
- ✓ Nur englische Buchstaben, Zahlen, Bindestriche und Unterstriche erlaubt!

# 3 Prinzipien für Dateinamen

1. Maschinenlesbar
2. Menschenlesbar
3. Klappt gut mit der Default-Sortierung

# Menschenlesbarkeit

- Name enthält Information über den Inhalt
- Vgl. das Konzept *slug* in semantischen URLs

<https://de.wikipedia.org/?curid=112763>

oder

<https://de.wikipedia.org/wiki/Sonnenblume>

Sonnenblume = slug

# Ein Beispiel

Welche Dateien hättest Du gerne in der Nacht vor der Abgabe?



```
01_marshall-data.md
01_marshall-data.r
02_pre-dea-filtering.md
02_pre-dea-filtering.r
03_dea-with-limma-voom.md
03_dea-with-limma-voom.r
04_explore-dea-results.md
04_explore-dea-results.r
90_limma-model-term-name-fiasco.md
90_limma-model-term-name-fiasco.r
Makefile
figure
helper01_load-counts.r
helper02_load-exp-des.r
helper03_load-focus-statinf.r
helper04_extract-and-tidy.r
tmp.txt
```



```
01.md
01.r
02.md
02.r
03.md
03.r
04.md
04.r
90.md
90.r
Makefile
figure
helper01.r
helper02.r
helper03.r
helper04.r
tmp.txt
```



# Embrace the slug!

01\_`marshal-data`.r

02\_`pre-dea-filtering`.r

03\_`dea-with-limma-voom`.r

04\_`explore-dea-results`.r

90\_`limma-model-term-name-fiasco`.r

helper01\_`load-counts`.r

helper02\_`load-exp-des`.r

helper03\_`load-focus-statinf`.r

helper04\_`extract-and-tidy`.r

# Beziehungen zwischen Dateien herstellen

R-Skripte:

01\_daten-bereinigen.r

02\_vorfiltern.r

03\_ergebnisse-explorieren.r

04\_statistik.r

Die Plots, die dabei entstehen:

01\_daten-bereinigen\_sprachen\_scatterplot.png

02\_vorfiltern\_sprachen\_barplot.png

02\_vorfiltern\_sprachen\_barplot-facets.png

04\_statistik\_sprachen-vs-anzahl\_boxplot.png

# Zusammenfassung: Menschenlesbarkeit

Es ist leicht herauszufinden, was in der Datei drin ist, einfach durch einen sinnvollen Dateinamen!



# 3 Prinzipien für Dateinamen

1. Maschinenlesbar
2. Menschenlesbar
3. Klappt gut mit der Default-Sortierung



# Klappt gut mit der Default-Sortierung

- Zahlen voranstellen
- Datumsangabe gemäß ISO 8601
- Zahlen Nullen voranstellen

# Zahlen voranstellen

Chronologische, bzw. logische Sortierung durch vorangestellte Zahlen

Z.B. R-Skripte von vorher:

01\_daten-bereinigen.r

02\_vorfiltern.r

03\_ergebnisse-explorieren.r

04\_statistik.r

# Datumsangabe: YYYY-MM-DD

Mithilfe von Datumsangaben werden Dateien automatisch chronologisch sortiert.



1-April-2012.png

1-Jan-2009.png

1-Jan-2012.png

12-Jan-2012.png

2-Jan-2012.png

31-Dec-2009.png



2009-01-01.png

2009-12-31.png

2012-01-01.png

2012-01-03.png

2012-01-12.png

2009-04-01.png

# Datumsangabe: YYYY-MM-DD

## PUBLIC SERVICE ANNOUNCEMENT:

OUR DIFFERENT WAYS OF WRITING DATES AS NUMBERS CAN LEAD TO ONLINE CONFUSION. THAT'S WHY IN 1988 ISO SET A GLOBAL STANDARD NUMERIC DATE FORMAT.

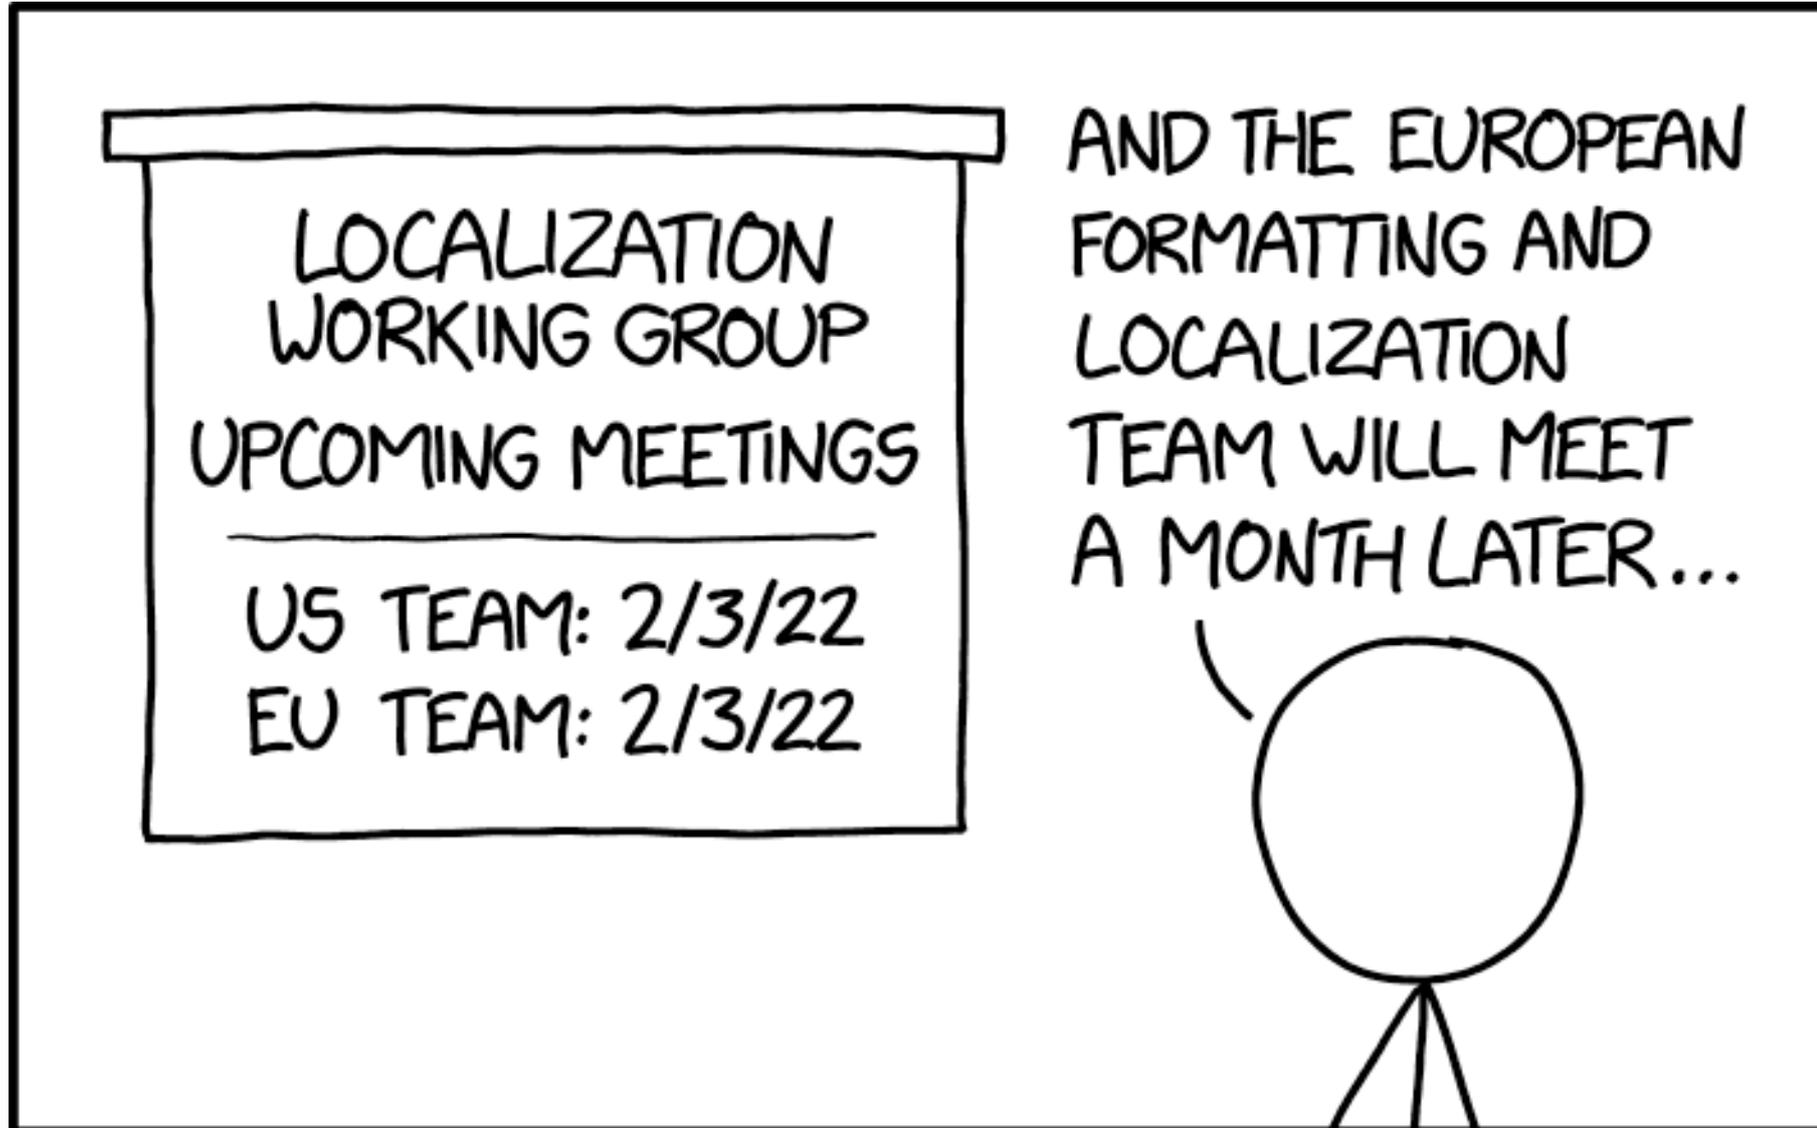
THIS IS *THE* CORRECT WAY TO WRITE NUMERIC DATES:

2013-02-27

THE FOLLOWING FORMATS ARE THEREFORE DISCOURAGED:

02/27/2013 02/27/13 27/02/2013 27/02/13  
20130227 2013.02.27 27.02.13 27-02-13  
27.2.13 2013. II. 27.  $27\frac{1}{2}$ -13 2013.158904109  
MMXIII-II-XXVII MMXIII  $\frac{LVII}{CCCLXV}$  1330300800  
 $((3+3)\times(111+1)-1)\times3/3-1/3^3$  ~~2013~~   
10/11011/1101 02/27/20/13  $\begin{matrix} 2 & 3 & 1 & 4 \\ 0 & 1 & 2 & 3 & 7 \\ 5 & 6 & 7 & 8 \end{matrix}$

# Datumsangabe: YYYY-MM-DD



# Datumsangabe: YYYY-MM-DD

Comprehensive Map of all countries using the Format MM-DD-YYYY



# Zahlen Nullen voranstellen

Ohne Nullen sieht es so aus:

10\_plots-fuer-konferenz\_final.png

1\_data-cleaning.R

2\_data-exploration.R

21\_boxplot.png

3\_data-wrangling.R

Das kann niemand wollen 😞

```
01_marshall-data.r
02_pre-dea-filtering.r
03_dea-with-limma-voom.r
04_explore-dea-results.r
90_limma-model-term-name-fiasco.r
helper01_load-counts.r
helper02_load-exp-des.r
helper03_load-focus-statinf.r
helper04_extract-and-tidy.r
```



# Zusammenfassung: Klappt gut mit der Default-Sortierung

- Zahlen voranstellen
- Datumsangabe gemäß ISO 8601
- Zahlen Nullen voranstellen

# 3 Prinzipien für Dateinamen

1. Maschinenlesbar
2. Menschenlesbar
3. Klappt gut mit der Default-Sortierung



# Ordnernamen

# Ziele

- Integrität der Daten
- Portabilität
- einfach, später selbst Schritte nochmal nachvollziehen zu können
- einfach, Mitarbeiter:innen mit an Board zu holen

# Ordnerstrukturen und Pfade

- Bei der Benennung: s.o. Dateinamen
- Trennung von Daten, Analyse, Output
- Klarmachen von Beziehungen zwischen den Arbeitsschritten
- nie händisch Rohdaten bearbeiten, später nicht mehr nachvollziehbar
- ein Ordner für die Rohdaten (“raw-data”, read-only)
- weitere Ordner für weitere Bearbeitungsphasen (“data”)
- gute Dokumentation (readme)

# Ordnerpfade

-  Projekt
  -  01\_mein-plan.docx
  -  02\_datensammlung.csv
  -  03\_analyse.R

## Pfad, Dateiname, Extension

Die Pfade zu den Dateien sehen so aus:

 Windows:

- Projekt\01\_meinplan.docx
- Projekt\02\_datensammlung.csv
- Projekt\03\_analyse.R

 Apple &  Linux:

- Projekt/01\_meinplan.docx
- Projekt/02\_datensammlung.csv
- Projekt/03\_analyse.R



# ReadMe: Meine Gebrauchsanweisung

- Idealerweise gibt es ReadMe-Dateien für ein Projekt/Ordner
- Einfache Text- oder Markdowndatei, in der steht, was in dem Ordner drin ist und wofür es benutzt wird
- Auch Dateinamen-Konventionen sollten hier erklärt sein
- Hinweise zur Versionierung
- In einem publizierten Datensatz hilft die ReadMe-Datei dem User sich zurechtzufinden



# Ordnerstruktur für ein größeres Projekt:

- Gemeinsam entscheiden, was wo liegt
- Aufschreiben
- Administratives vs. inhaltliches (Reisekostenordner, Analyseordner, Publikation)



# Ordnerstruktur für ein größeres Projekt:

- Auf Ordnungsprinzipien auch in Unterordnern einigen
  - Nach Zweck: Warum werden Daten erhoben (Solar-Studie, Arbeitspaket 7b,...)
  - Nach Kommunikation: Wo werden die Daten diskutiert (Konferenz XY, Workshop Z...)
  - Nach Chronologie: Wie werden die Daten zeitlich ein geordnet (Messzeit, Versuchsreihe, ...)
  - Nach Verarbeitungsgrad: Wie stark wurden die Daten bearbeitet? (Rohdaten, Prozessierung, Ergebnis)
  - Nach Ursprung: Wo kommen die Daten her? (Person, Gebiet, Gerät,...)
  - ...

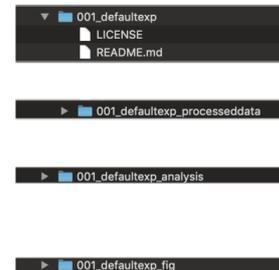
# Ordnerstruktur für ein größeres Projekt:

Es gibt templates dafür

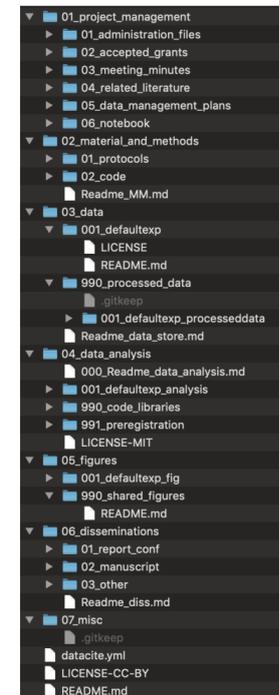
z. B. **GinTonic**

Experiment level:

add sub-folders for each experiment

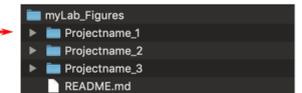


**Project level**



Laboratory level:

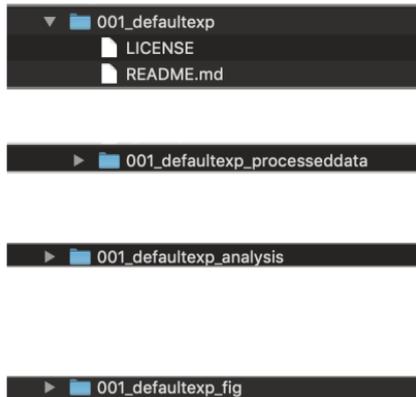
mirror sub-folders in other structures



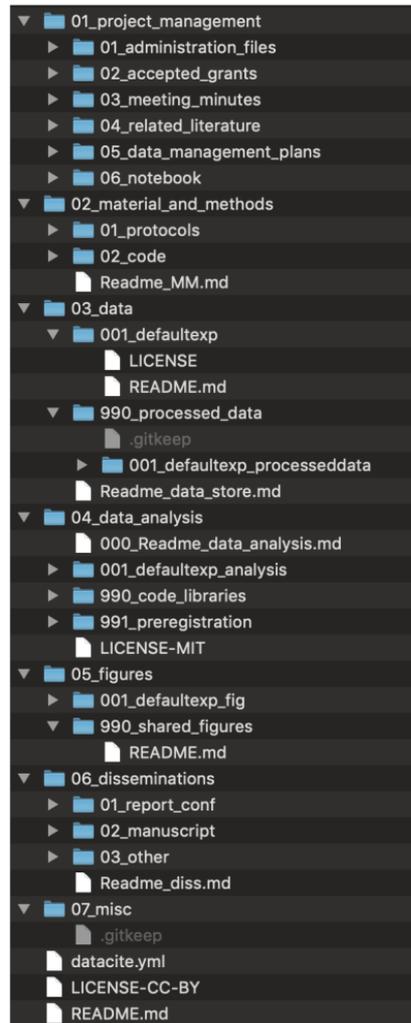
# GinTonic

## Experiment level:

add sub-folders for each experiment

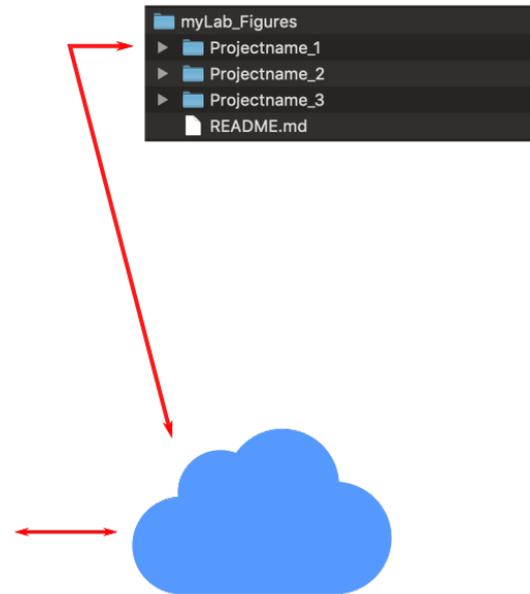


## Project level



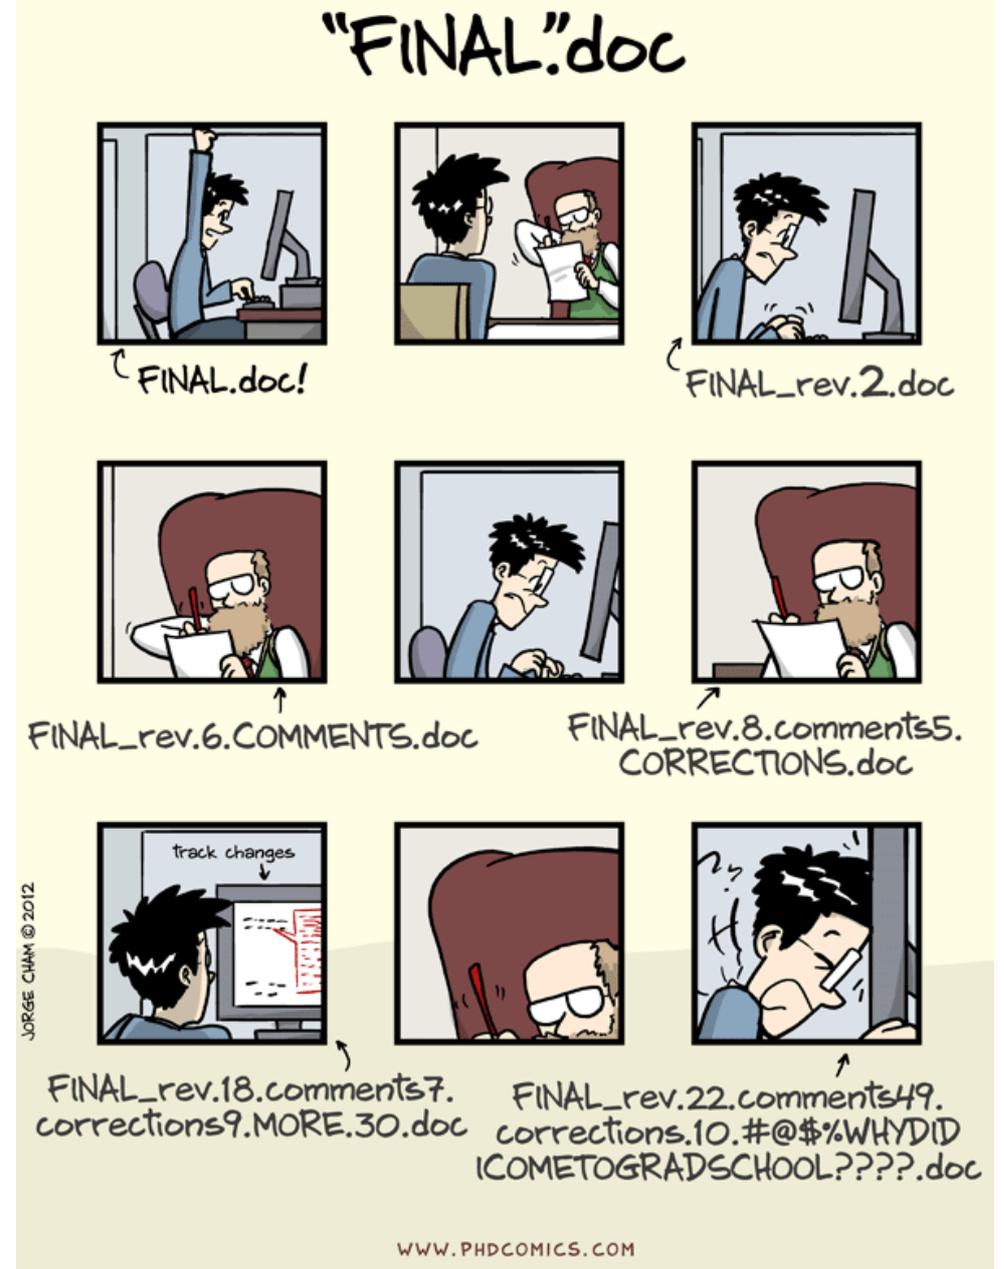
## Laboratory level:

mirror sub-folders in other structures



# Versionierung

- Im Arbeitsprozess entstehen viele Versionen einer Datei -
- Wie damit umgehen? -
- Versionierung mit Datum  
text\_2022-04-14.docx -
- Versionierung mit Nummern  
text\_03.docx - Einen Ordner anlegen für alte Versionen -
- Professionell: git!





# Backups

# Gründe für Datenverlust

-  menschliches Versagen
-  Viren & Malware
-  Softwarefehler
-  Diebstahl & Verlust (Laptop geklaut, USB-Stick verloren)
-  Katastrophen (Feuer, Überschwemmung,...)

# Backups

## 3-2-1-Regel

- Mindestens 3 Kopien der Daten
- Auf mindestens 2 verschiedenen Speichermedien
- 1 davon sollte dezentral/extern liegen (Cloud)

# Zusammenfassung

- Man kann durch geschickte und konsistente Benennung von Dateien und Ordnern Ordnung ins Chaos bringen
- Das sollte eine bewusste Entscheidung sein
- Ihr wisst, worüber man nachdenken sollte
- Ihr wisst, was Ordnerpfade sind und welche Zeichen nicht verwendet werden dürfen
- Ihr wisst, was Versionierung ist (später dazu mehr)
- Ihr wisst, was eine minimale Backup-Strategie ist

# Quellen

Die Folien basieren auf:

<https://annakrystalli.me/rrresearchACCE20/filenaming-view.html>

<https://slides.djnavarro.net/project-structure/#1>

<https://speakerdeck.com/jennybc/how-to-name-files>

[https://tu-dresden.de/forschung-transfer/services-fuer-forschende/kontaktstelle-forschungsdaten/news/ordnerstruktur-logik?set\\_language=en](https://tu-dresden.de/forschung-transfer/services-fuer-forschende/kontaktstelle-forschungsdaten/news/ordnerstruktur-logik?set_language=en)

Bildquellen:

all countries: [https://img-9gag-fun.9cache.com/photo/a2mXmGd\\_700b.jpg](https://img-9gag-fun.9cache.com/photo/a2mXmGd_700b.jpg)

future self: Photo by [Amy Shamblen](#) on [Unsplash](#), edited by Gabriele Schwiertz

# Übung: Backup

- Tauscht Euch über Eure Backup-Strategien aus
- Nutzt die Zeit, um ein Backup anzulegen

# Übung: Ordnerstruktur

- Legt einen leeren Ordner an
- Erarbeitet eine bessere neue Ordnerstruktur für Eure
- Tauscht Euch mit der/dem Nachbar\*in dazu aus
- Gebt Euch selbst regeln für die Dateibenennung
  - Schreibt sie in einer Datei auf
  - CamelCase oder snake\_case
  - Mit Datum am Ende? 2024-11-05
  - Mit Versionsnummer? v2
- HA: räumt alles in die neue Ordnerstruktur um, wenn sie Euch gefällt