

Übungszettel Plots und Grafiken - Exercise sheet plots and graphics

M.Psy.205, Dozent: Dr. Peter Zezula

Johannes Brachem (johannes.brachem@stud.uni-goettingen.de)

Deutsche Version

Links

[Übungszettel als PDF-Datei zum Drucken](#)

Hinweise zur Bearbeitung

1. Bitte beantworten Sie die Fragen in einer .Rmd Datei. Sie können Sie über Datei > Neue Datei > R Markdown... eine neue R Markdown Datei erstellen. Den Text unter dem *Setup Chunk* (ab Zeile 11) können Sie löschen. [Unter diesem Link](#) können Sie auch unsere Vorlage-Datei herunterladen (Rechtsklick > Speichern unter...).
2. Informationen, die Sie für die Bearbeitung benötigen, finden Sie auf der [Website der Veranstaltung](#)
3. Zögern Sie nicht, im Internet nach Lösungen zu suchen. Das effektive Suchen nach Lösungen für R-Probleme im Internet ist tatsächlich eine sehr nützliche Fähigkeit, auch Profis arbeiten auf diese Weise. Die beste Anlaufstelle dafür ist der [R-Bereich der Programmiererplattform Stackoverflow](#)
4. Auf der Website von R Studio finden Sie sehr [hilfreiche Übersichtszettel](#) zu vielen verschiedenen R-bezogenen Themen. Ein guter Anfang ist der [Base R Cheat Sheet](#)

Ressourcen

Da es sich um eine praktische Übung handelt, können wir Ihnen nicht alle nützlichen Befehle einzeln vorstellen. Stattdessen finden Sie hier Verweise auf sinnvolle Ressourcen, in denen Sie für die Bearbeitung unserer Aufgaben nachschlagen können.

Ressource	Beschreibung
Field, Kapitel 4 ggplot2 Cheat Sheet Peters ggplot2-Referenz	Buchkapitel, das Schritt für Schritt in die Arbeit mit ggplot2 einführt. Große Empfehlung! Übersicht über die meisten gängigen ggplot2-Befehle Peter pflegt eine große Sammlung von Beispielen für Plots mit dem dazugehörigen Code: Eine Ressource zum Nachschlagen

Tipp der Woche

Mit der Tastenkombination `ctrl + shift + m` (Windows) oder `cmd + shift + m` (Mac) können Sie per Knopfdruck das Pipe-Symbol `%>%` einfügen.

Daten einlesen

1. Setzen Sie ein sinnvolles Arbeitsverzeichnis für den Übungszettel (in der Regel der Ordner, in dem Ihre `.Rmd` liegt). Fügen Sie eine passende Code-Zeile an den Anfang ihres `.Rmd`-Dokuments ein.
2. Laden Sie den Datensatz `mpg.csv` herunter und speichern ihn in Ihrem Arbeitsverzeichnis (idealerweise haben Sie noch den Ordner vom letzten Übungszettel - speichern Sie den Datensatz im Unterordner `/data`).
3. Öffnen Sie `mpg.csv` mit einem einfachen Texteditor und schauen Sie, mit welchem Zeichen die einzelnen Spalten getrennt sind.
4. Laden Sie die Pakete des `tidyverse`. Fügen Sie eine passende Code-Zeile an den Anfang ihres `.Rmd`-Dokuments.
5. Nutzen Sie den Befehl `read_delim()`, um `mpg.csv` unter dem Namen `mpg_data` einzulesen. `read_delim()` ist eine verallgemeinerte Form von `read_csv()`, in der sie mit dem Argument `delim = "<Trennzeichen>"` manuell angeben können, durch welches Zeichen die Spalten in Ihrem Datensatz getrennt sind.

Grundlegendes zu Grafiken

Zum Erstellen von Grafiken nutzen wir das Paket `ggplot2`. Da das Paket zum `tidyverse` gehört, brauchen Sie es nicht extra laden, wenn Sie bereits das `tidyverse` geladen haben (Siehe Aufgabe 1.4).

Objekt erstellen

Grafiken mit `ggplot2` werden eigentlich immer nach dem gleichen Muster erstellt. Zunächst nutzen Sie den Befehl `ggplot()`, um ein Grafik-Objekt zu erzeugen:

```
example_plot <- ggplot(data, aes(x = variable_1, y = variable_2))
```

Sie sehen: Das erste Argument in der Klammer ist der Datensatz, den Sie verwenden möchten. Anschließend legen Sie in dem Argument `aes()` fest, welche Variable auf der x-Achse und welche auf der y-Achse dargestellt werden soll.

Grafische Ebene hinzufügen

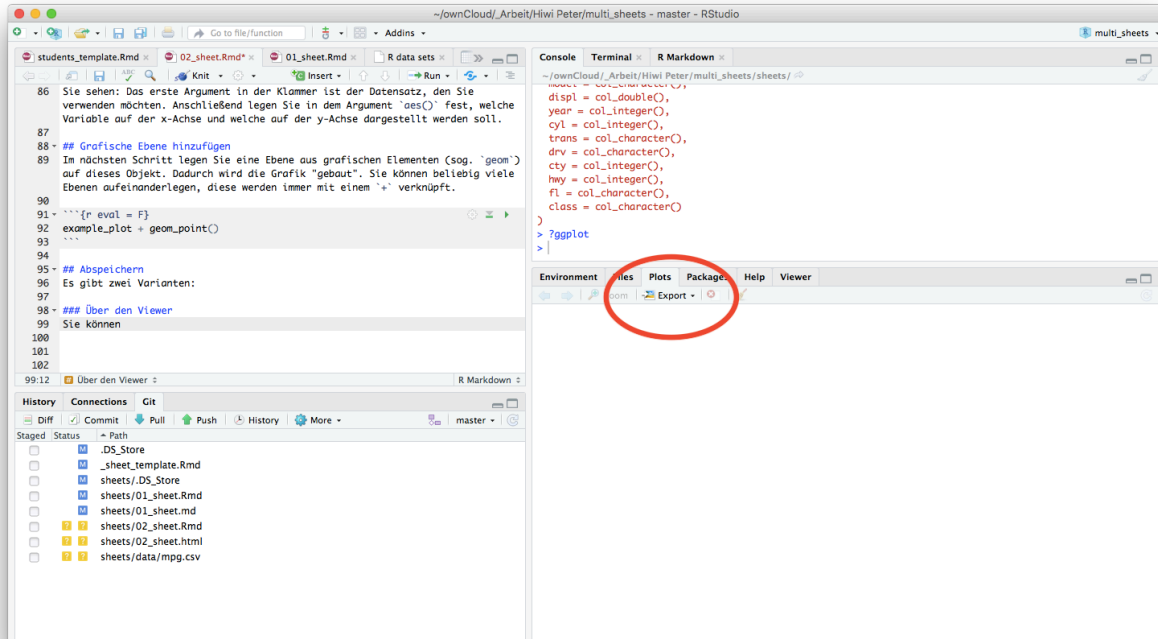
Im nächsten Schritt legen Sie eine Ebene aus grafischen Elementen (sog. `geom`) auf dieses Objekt. Dadurch wird die Grafik "gebaut". Sie können beliebig viele Ebenen aufeinanderlegen, diese werden immer mit einem `+` verknüpft.

```
example_plot + geom_point()
```

Abspeichern

Es gibt zwei Varianten:

Über den Viewer Sie können über die “Export” Schaltfläche im Viewer arbeiten:



Über die Syntax Wenn Sie einen Plot über die Syntax speichern möchten, dann müssen Sie zunächst die Ebenen, die Sie hinzugefügt haben, mit abspeichern:

```
example_plot <- example_plot + geom_point()
```

Dann verwenden Sie `ggsave()`, um den Plot zu speichern. Er wird in Ihrem Arbeitsverzeichnis abgelegt. Sie geben in dem Befehl zunächst den gewünschten Dateinamen in Anführungszeichen an (Endung nicht vergessen!), und geben als nächstes den Plot an, den Sie speichern möchten.

```
ggsave("example_plot.png", example_plot)
```

Scatterplot

1. Nutzen Sie `?mpg`, um sich eine Beschreibung des Datensatzes anzeigen zu lassen.
2. Erstellen Sie mit `ggplot()` ein Objekt namens `displ_plot`, in dem Sie als Datensatz `mpg_data` spezifizieren. Auf der x-Achse sollten Sie den Hubraum (*engine displacement*) des Modells eingeben. Auf der y-Achse sollte stehen, wie viele Meilen pro Gallone Treibstoff (*city miles per gallon*) gefahren werden können.
3. Nutzen Sie `geom_point()`, um zu diesem Objekt nun eine Ebene aus Punkten hinzuzufügen.
4. Nutzen Sie `geom_smooth()` mit den Argumenten `method = "lm"` und `se = FALSE`, um dem Plot zusätzlich eine Regressionsgerade hinzuzufügen.
5. Probieren Sie aus, was passiert, wenn man bei `geom_smooth()` die beiden Argumente aus der vorherigen Aufgabe weglässt.


Barplot

1. Erstellen Sie ein neues Plot-Objekt namens `drv_plot` mit folgenden Spezifikationen: Der Datensatz sollte wieder `mpg_data` sein, auf der x-Achse sollte die Art des Antriebs (`front`, `rear` oder `4wd`) dargestellt sein, und auf der y-Achse wieder der Treibstoffverbrauch in *Miles per Gallon*.
2. Fügen Sie nun eine *summary*-Ebene mit dem Befehl `stat_summary()` zu dem Plot hinzu. Nutzen Sie in `stat_summary()` das Argument `fun.y = mean`, um ggplot mitzuteilen, dass Sie den Mittelwert der Beobachtungen auf der y-Achse darstellen möchten. Nutzen Sie außerdem in `stat_summary()` das Argument `geom = "bar"`, um sich einen Barplot ausgeben zu lassen.
3. Fügen Sie dem Befehl `aes()` bei der Definition des Objektes `drv_plot` das Argument `fill = drv` hinzu, um den Barplot farblich aufzuhübschen. Führen Sie den Befehl aus der vorherigen Aufgabe danach erneut aus, um den Plot zu aktualisieren.
4. Fügen Sie dem Plot nun eine Beschriftungs-Ebene mit dem Befehl `labs()` hinzu. Vergeben Sie in `labs()` mithilfe der Argumente `x = "text"`, `y = "text"`, `title = "text"` und `fill = "text"` sinnvolle Namen für die x- und y-Achse, geben Sie dem Plot einen Titel und eine Beschriftung für die Farben.
5. Verleihen Sie den Säulen einen schwarzen Rand, indem Sie im Befehl `stat_summary()` das Argument `color = "black"` hinzufügen.

Linienplot

1. Bauen Sie den folgenden Plot nach. Hinweis: Die Punkte stellen die Mittelwerte dar.

```
## Warning: `fun.y` is deprecated. Use `fun` instead.
```



2. Nutzen Sie den Befehl `stat_summary()`, um dem Plot eine Ebene mit einer Linie hinzuzufügen, die die Punkte verbindet. Tipp: Nutzen Sie das Argument `aes(group = 1)` in `stat_summary()`, um ggplot mitzuteilen, dass alle Punkte in einer Gruppe gruppiert werden.
3. Nutzen Sie den Befehl `stat_summary()` mit den Argumenten `fun.data = mean_cl_normal` und `geom = "errorbar"`, um dem Plot eine Ebene mit Fehlerbalken hinzuzufügen, die die 95%-Konfidenzintervalle der Mittelwerte angeben.
4. Nutzen Sie das Argument `width = 0.2` in `stat_summary()`, um die Breite der Konfidenzintervalle einzustellen.
5. Fügen Sie dem Plot sinnvolle Achsenbeschriftungen und einen Titel hinzu.

Histogramm

1. Nutzen Sie `geom_histogram()`, um sich ein Histogramm der *Miles per Gallon* (Stadt) anzeigen zu lassen.
2. Auf Seite 2 des [ggplot2-Cheatsheets](#) (unten, rechts mittig) finden Sie eine Übersicht über verschiedene *Themes*, mit denen Sie Ihre Plots verschönern können. Geben Sie Ihrem Histogramm ein *Theme*, das Ihnen gefällt.


Plot nachbauen

Bauen Sie mit dem Datensatz `text_messages.dat` den unten angezeigten Plot nach. Sie müssen ihn dafür zunächst einlesen und dann vom *wide* ins *long* Format bringen. Der Datensatz enthält die Testergebnisse in

einem Grammatik-Test zu einem Baseline-Zeitpunkt und einem 6-Monats-Follow up. Es gab zwei Gruppen, die in der Variable `Groups` definiert sind.

```
## Warning: `fun.y` is deprecated. Use `fun` instead.
```

```
## Warning: `fun.y` is deprecated. Use `fun` instead.
```



Tipps:

1. Der Datensatz enthält Spalten, die mit *Tabstops* getrennt sind. Diese werden in R durch "`\t`" kodiert.
2. Sie müssen den Datensatz nicht nur einlesen, sondern auch vom *wide-* ins *long* Format bringen. Denken Sie dazu an den Befehl `gather()`.
3. Denken Sie daran, bei den Ebenen passende Gruppierungen anzugeben. Sie können Variablen zum Gruppieren benutzen.
4. Werfen Sie einen Blick auf das [ggplot2-Cheatsheet](#) zu den Befehlen `geom_point()` und `geom_line()`. Deren Argumente können Sie auch in `stat_summary()` verwenden, wenn Sie dort `geom = "point"` oder `geom = "line"` spezifiziert haben.

Als Barplot

Versuchen Sie nun die gleiche Information, inklusive Fehlerbalken, als Barplot darzustellen.

Tipps:

1. Bei Barplots gibt `fill` die Farbe der Säule (die Füllung) an, und `color` die Farbe des Rahmens.

2. Das Argument `position = "dodge"` kann helfen, wenn die Säulen sich überlappen.
3. Das Argument `position = position_dodge(width = .90)` kann helfen, schmale Ebenen an breiteren Ebenen auszurichten.

Rendern

Rendern, bzw. knitten Sie nun das Dokument über die Tastenkombination `strg + shift + k` (Windows) oder `cmd + shift + k`. Wenn das funktioniert: Top gemacht! Wenn nicht: Schauen Sie sich die Fehlermeldung an, und betrachten Sie insbesondere die Zeilen Ihrer Syntax, die in der Fehlermeldung auftauchen. Suchen Sie nach dem Fehler und probieren Sie es erneut!

Literatur

Anmerkung: Diese Übungszettel basieren zum Teil auf Aufgaben aus dem Lehrbuch *Discovering Statistics Using R* (Field, Miles & Field, 2012). Sie wurden für den Zweck dieser Übung modifiziert, und der verwendete R-Code wurde aktualisiert.

Field, A., Miles, J., & Field, Z. (2012). *Discovering Statistics Using R*. London: SAGE Publications Ltd.

English Version

Exercise sheet in PDF format for printing [sheet_plots.pdf](#)

Some hints

1. Please give your answers in a .Rmd file. You may generate one from scratch using the file menu: 'File > new file > R Markdown ...' Delete the text below *Setup Chunk* (starting from line 11). Alternatively you may use this [sample Rmd](#) by downloading it.
2. You may need the informations from the [start page of this course](#).
3. Don't hesitate to google for solutions. Effective web searches to find solutions for R-problems is a very useful ability, professionals to that too ... A really good starting point might be the R area of the programmers platform [Stackoverflow](#)
4. You can find very useful [cheat sheets](#) for various R-related topics. A good starting point is the [Base R Cheat Sheet](#).

Ressources

This is a hands on course. We cannot present you all the useful commands in detail. Instead we give you links to useful resources, where you might find hints to help you with the exercises.

Ressource	Description
Field, Chapter 4	Book chapter with a step for step introduction to <code>ggplot2</code> .
ggplot2 Cheat Sheet	Recommendation! Overview of most common <code>ggplot2</code> commands
Peters ggplot2-Referenz	Peter offers a big collection of plots with source code to generate them. A resource to find running examples.

Tip of the week

We can insert the pipe symbol `%>%` using the shortcut `ctrl + shift + m` (Windows) oder `cmd + shift + m` (Mac).

Read data

1. Define an appropriate working directory for this exercise sheet. This should usually be the folder, where your Rmd-file is located. Insert a command to do that in your Rmd-document.
2. Load the data `mpg.csv` and store it in your working directory. You might still have the folder you used for your last sheet - then store the data in a data subdirectory.
3. Open the file `mpg.csv` in a text editor and check, which character separates the content in the lines to form the future columns.
4. Assure, that the package `tidyverse` are loaded. Insert a code line for that in the beginning of your Rmd-file.
5. Use the command `read_delim()` and define a data object named `mpg_data` using the data in file `mpg.csv`. `read_delim()` is a generalized version of `read_csv()`, with which you define manually the separator used in your data file by setting the argument `delim = "<separator>"`. C. f. Tabulator is specified by `"\t"`.

Plot basics

We use package `ggplot2` for creating plots. This package is part of `tidyverse` and we don't have to load it separately, when we already have loaded `tidyverse` (see task 1.4).

Create plot objekt

Generating plots works always the same. We create a plot-object using the command `ggplot()`

```
example_plot <- ggplot(data, aes(x = variable_1, y = variable_2))
```

As we can see, the first argument is the data-object to use. With `aes()` we define, which variable assigned to x-axis and y-axis respectively.

Add a layer

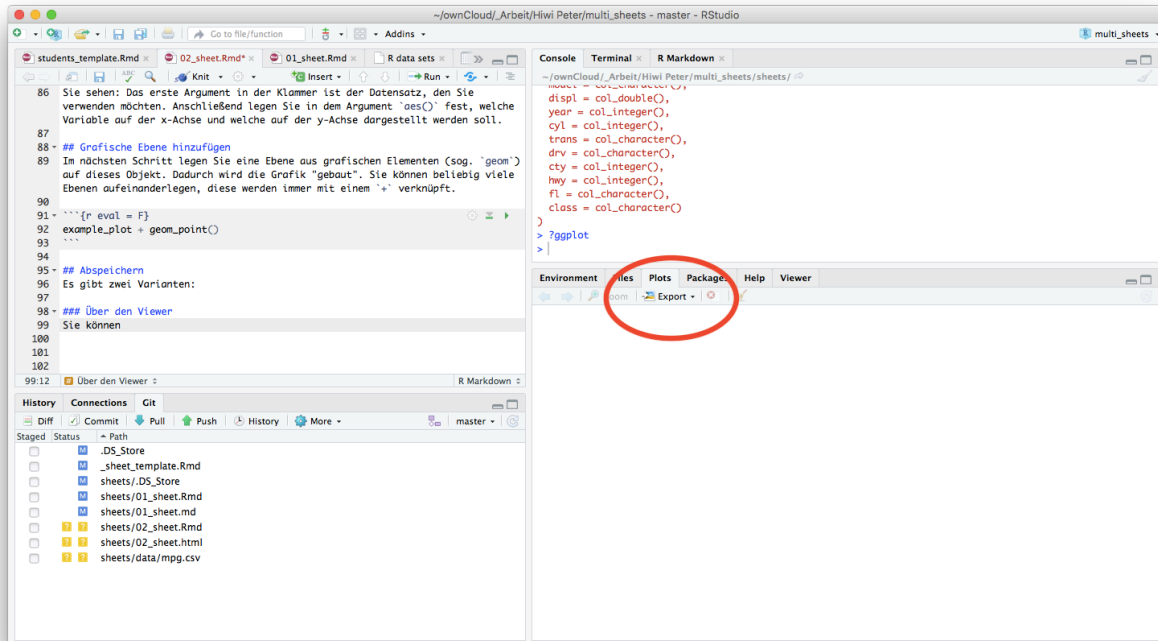
Next step is to add a layer of graphical elements, a so called `geom` to the object. This is, how plots are constructed. We may add as much layers, as we like. They are always connected using `+`.

```
example_plot + geom_point()
```

Saving

There are two variants:

Via menu We can click on “Export” in the “Plots” tab in the lower right part of RStudio:



Via syntax To save a plot object with all its layers we have to first store the complete plot-object:

```
example_plot <- example_plot + geom_point()
```

Then we use `ggsave()` to save the plot-object. It is stored in your working directory. Add a name for the plot-file in quotation marks (including extension) as first parameter. Next parameter is the plot-object to store.

```
ggsave("example_plot.png", example_plot)
```

Scatterplot

1. Use the command `?mpg` to get a description of the data we use.
2. Create a ggplot-object named `displ_plot`, which uses `mpg_data` as dataset. X-axis should show *engine displacement* of the model. Y-axis should visualize the *city miles per gallon*.
3. Use `geom_point()` to add a layer to the above object that shows points at the coordinates of the two variables.
4. Use `geom_smooth()` with the arguments `method = "lm"` and `se = FALSE` to add an additional layer with a regression line.
5. Try what happens if you don't add the above two arguments you set in your `geom_smooth()` command.

Barplot


1. Create a new plot-object named `drv_plot` with the following specifications: The dataset should be `mpg_data` again. X-axis should be type of drive `drv` (front, rear or 4wd). Y-axis should be consumption *Miles per Gallon*.
2. Add a *summary*-layer using `stat_summary()`. In `stat_summary()` use argument `fun.y = mean` to tell `ggplot` that you want to show the mean of the observed data on the y-axis. Use also the argument `geom = "bar"` to get a barplot.
3. Add argument `fill = drv` while defining object `drv_plot` to colorize the barplot. Rerun the command of the subtask above to update the plot.
4. Add a label-layer to the plot using the command `labs()`. In `labs()` set arguments `x = "text"` and `y = "text"` and `fill = "text"` to give meaningful informations. Add also a title and an information of the meaning of the colors used.
5. Add a black margin to the bars using the argument `color = "black"` in the command `stat_summary()`.

Lineplot

1. Create the following plot.

Hint: points show mean values.

```
## Warning: `fun.y` is deprecated. Use `fun` instead.
```



2. Use the command `stat_summary()` to add a layer that connects the points with a line. Tip: use argument `aes(group = 1)` in `stat_summary()` to tell `ggplot` that all points should be grouped in one single group.
3. Use the command `stat_summary()` with the arguments `fun.data = mean_cl_normal` and `geom = "errorbar"` to add a layer with errorbars, that show the 95% confidence interval around the means.
4. Use the argument `width = 0.2` in `stat_summary()` to configure the width of the whiskers of the confidence interval indicator.
5. Add meaningful labels for the axes and an appropriate title.

Histogram


1. use `geom_histogram()` to get a histogram of *Miles per Gallon* (city).
2. On page 2 of the [ggplot2-Cheatsheets](#) (below, mid right) you find an overview of various *Themes* that are useful to make your plots more beautiful. Apply a *Theme* you like to your histogram.

Reconstruct plot

Use dataset `text_messages.dat` to reconstruct the plot below. You have to first read in the data and then convert them from long to wide format. The data are test results of a grammar test from a baseline and a 6 month follow up. There are two groups that are defined in variable `Groups`.

```
## Warning: `fun.y` is deprecated. Use `fun` instead.
```

```
## Warning: `fun.y` is deprecated. Use `fun` instead.
```



Tips:

1. The delimiters used in the data file are *tabs*. In R you code tabulators using `"\t"`.
2. You don't have to simply read in the data, you also have to convert it from *wide* to *long* format. Remember the command `gather()` in this context.
3. Remember to set adequate grouping to the layers. You may use variables to group.
4. See [ggplot2-Cheatsheet](#) with regard to the commands `geom_point()` and `geom_line()`. Their arguments can also be used in `stat_summary()` if you specified `geom = "point"` or `geom = "line"` there.

As Barplot

Try to visualize the same information including errorbars as barplot.

Tips:

1. Command `barplot()` understands parameter `fill` that specifies the color of the column (filling) and `color` refers to the frame color.
2. The argument `position = "dodge"` may help, if the columns overlap.
3. The argument `position = position_dodge(width = .90)` may help to adapt smaller layers to larger layers.

Rendering

Render or knit your Rmd file using the shortcut `strg + shift + k` (Windows) or `cmd + shift + k`. If that works: Well done! If not, look at the error message, in special the lines in the syntax, where the error occurred. Correct the error and start over again.

Literature

Annotation: This exercise sheet is based in part on the exercises from the textbook *Discovering Statistics Using R* (Field, Miles & Field, 2012). We modified it for the purpose of this exercise and actualized the R-Code.

Field, A., Miles, J., & Field, Z. (2012). *Discovering Statistics Using R*. London: SAGE Publications Ltd.

Version: 16 April, 2021 22:39