Vorlesung 3 (Graphik für diskrete Skalen und mehr als eine Variable)

K.Gerald van den Boogaart
http://www.stat.boogaart.de

29. Oktober 2019

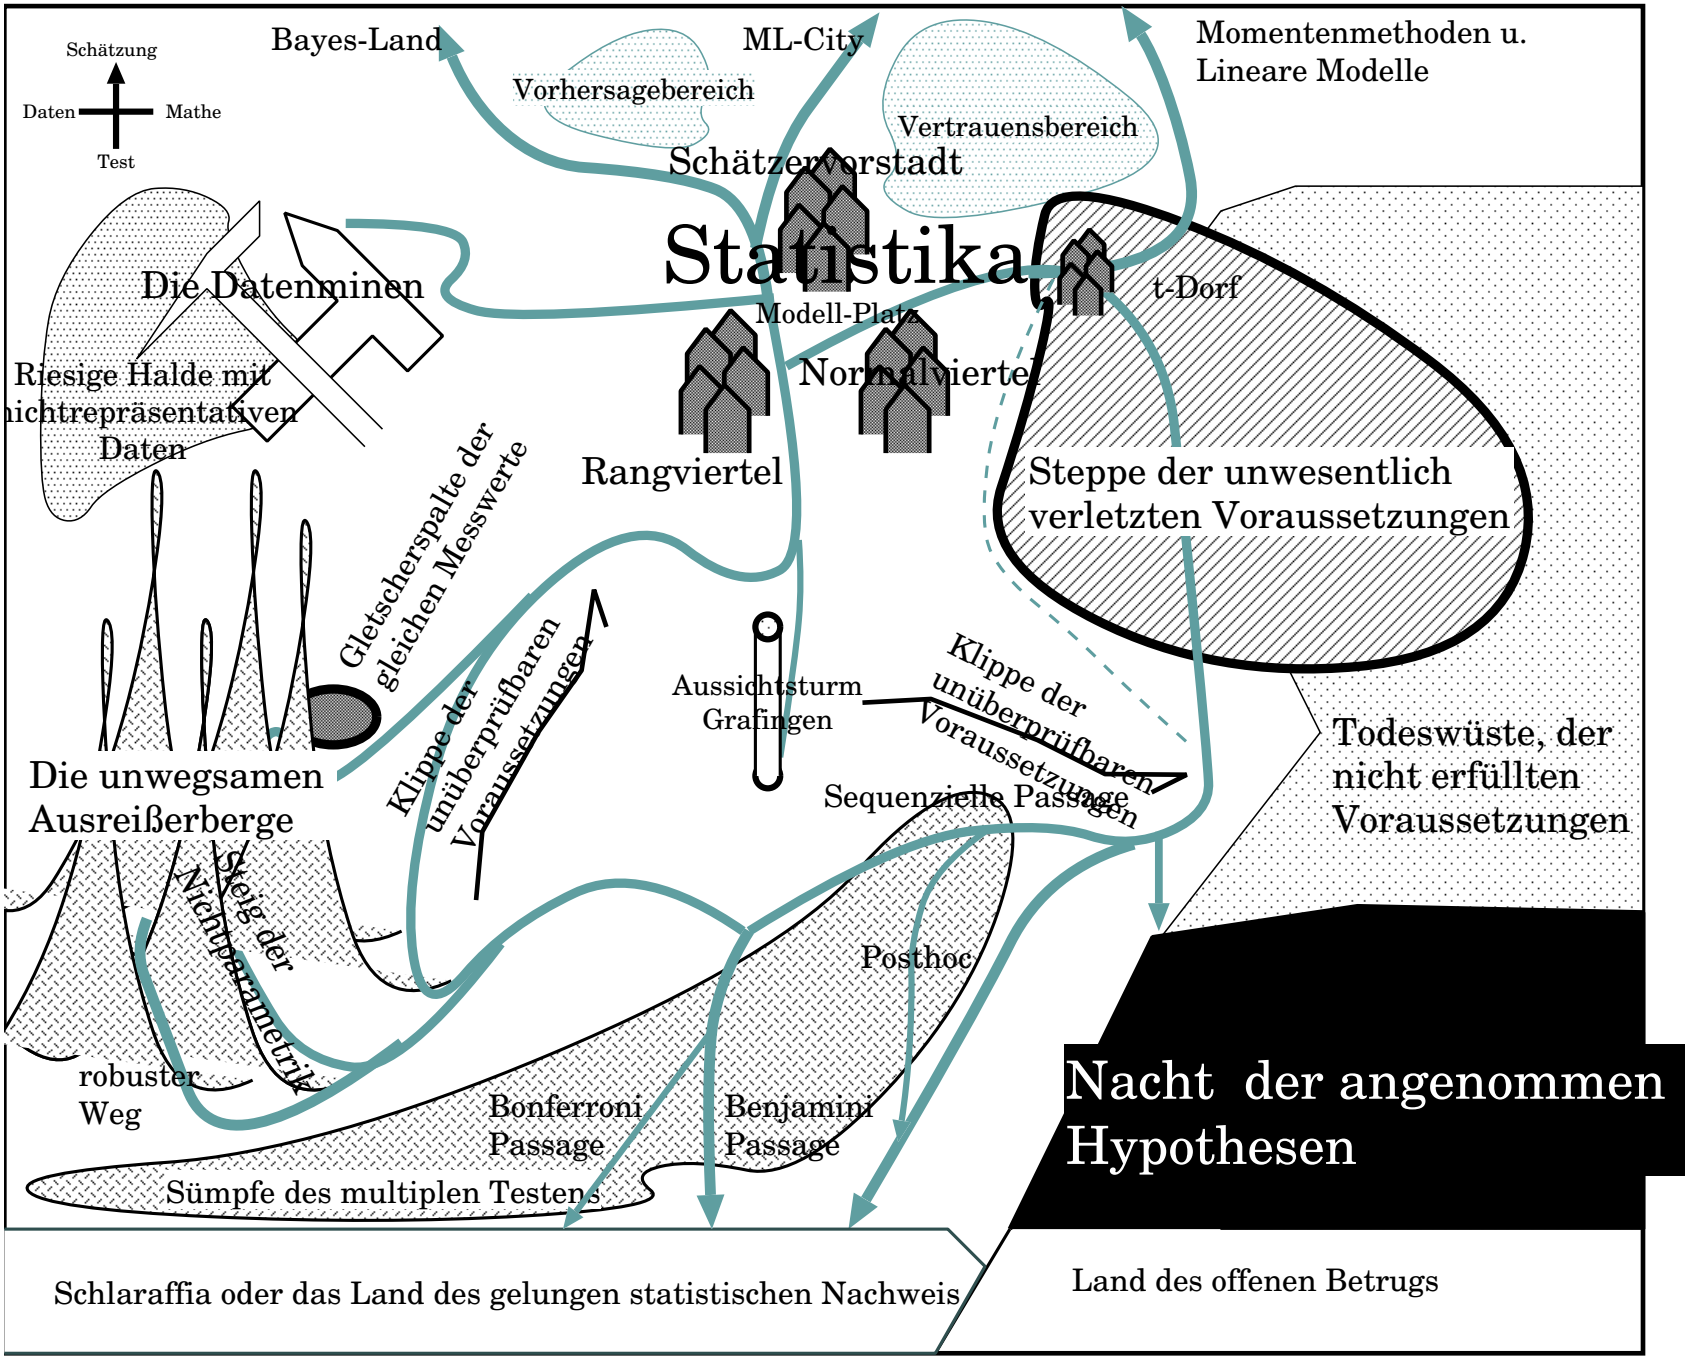
Schätzung
Daten
Mathe
Test
Bayes-Land
ML-City
Momentenmethoden u.
Lineare Modelle
Vorhersagebereich
Vertrauensbereich
Schätzervorstadt
Statistika
Die Datenminen
Modell-Platz
t-Dorf
Riesige Halde mit
nichtrepräsentativen
Daten
Normalviertel
Rangviertel
Steppe der unwesentlich
verletzten Voraussetzungen
Gletscherspalte der
gleichen Messwerte
Klippe der
unüberprüfbaren
Voraussetzungen
Aussichtsturm
Grafingen
Klippe der
unüberprüfbaren
Voraussetzungen
Todeswüste, der
nicht erfüllten
Voraussetzungen
Die unwegsamen
Ausreißerberge
Sequenzielle Passage
Steig der
Nichtparametrik
Posthoc
robuster
Weg
Bonferroni
Passage
Benjamini
Passage
Sümpfe des multiplen Testens
Nacht der angenommen
Hypothesen
Schlaraffia oder das Land des gelungen statistischen Nachweis
Land des offenen Betrugs

Einteilung der Graphiken und Parameter

		Erste Variable	
		diskret	stetig
	keine		x
zweite Variable	diskret		
	stetig		

- *stetige Daten
- diskrete Daten
- stetig–stetig
- diskret–diskret
- diskret–stetig

Einteilung der Graphiken und Parameter

		Erste Variable	
		diskret	stetig
	keine	X	x
zweite Variable	diskret		
	stetig		

- *stetige Daten
- diskrete Daten als nächstes
- stetig–stetig
- diskret–diskret
- diskret–stetig

Graphiken und Kenngrößen für diskrete Skalen

- Kenngrössen
- Balkendiagramme (praktisch und funktional)
- Kuchendiagramme (Vorsicht Zucker)
- Tortendiagramm (Vorsicht Cholsterin und Zucker)

Datensatz

```
> margin <- function(x,...) apply(x,pmatch(c(...),names(dimnames(x))),sum)
> data(Titanic)
> ftable(Titanic,col.vars=c("Class","Survived"))
```

	Class	1st		2nd		3rd		Crew	
	Survived	No	Yes	No	Yes	No	Yes	No	Yes
Sex	Age								
Male	Child	0	5	0	11	35	13	0	0
	Adult	118	57	154	14	387	75	670	192
Female	Child	0	1	0	13	17	14	0	0
	Adult	4	140	13	80	89	76	3	20

Kenngrössen

Anteile:

```
> margin(Titanic,"Survived")/sum(Titanic)

      No      Yes
0.676965 0.323035

> margin(Titanic,"Sex")/sum(Titanic)

     Male    Female
0.7864607 0.2135393

> margin(Titanic,"Class")/sum(Titanic)

      1st       2nd       3rd      Crew
0.1476602 0.1294866 0.3207633 0.4020900
```

Balkendiagramm

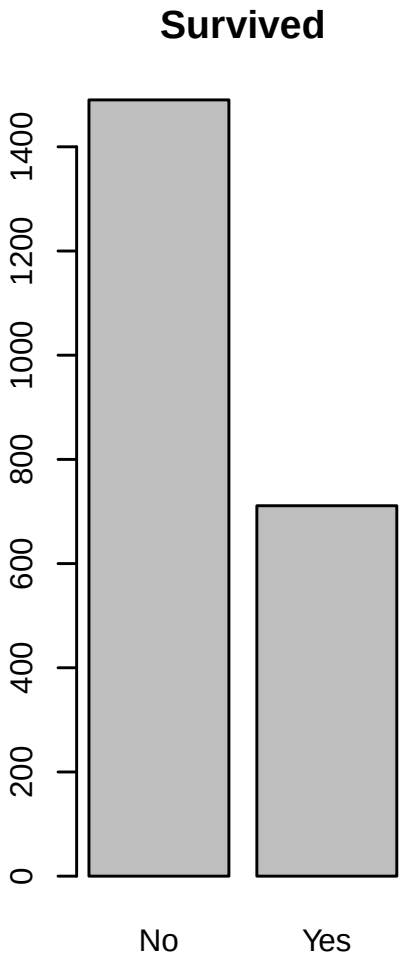

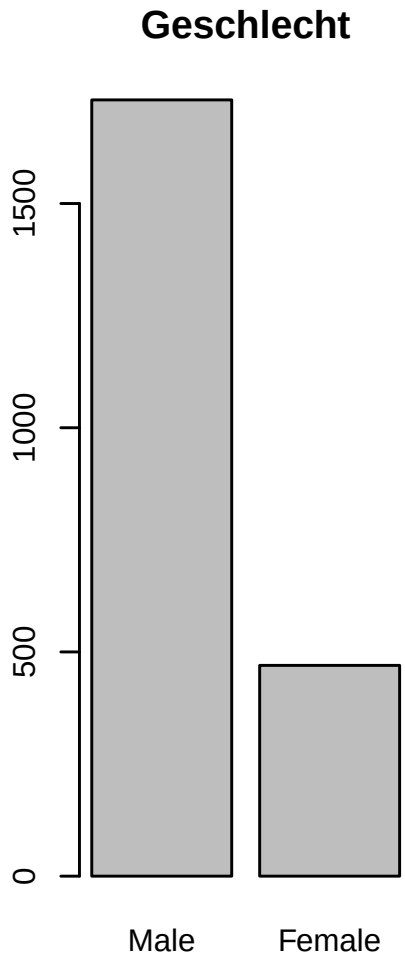

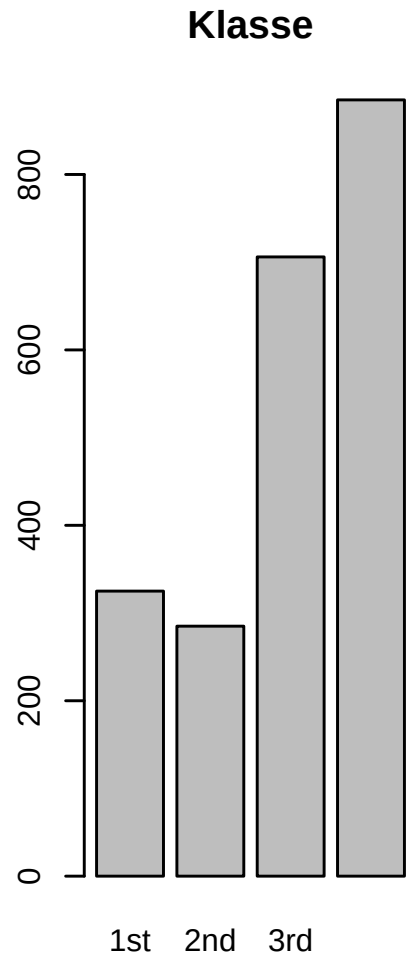

Balkendiagramm

- Häufigkeiten werden als Flächen dargestellt.
- Häufigkeiten werden als Höhen dargestellt.
- Was sind die Unterschiede zum Histogramm?
- Was muß man bei ordinalen Daten beachten?

Kuchendiagramme

Survived

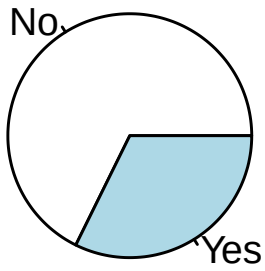

Geschlecht

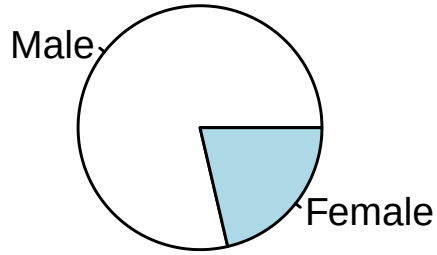

Klasse

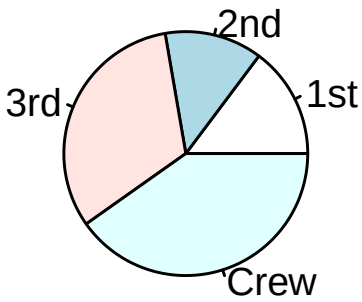

Torte oder Diät

	A	B
1	Lustigen	23
2	Alternativen	37
3	Ernsten	40
4		
5		
6		
7		
8		
9		
10		
11		
12		
13		
14		
15		
16		
17		

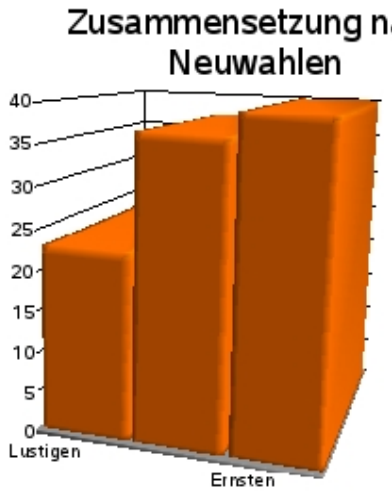

Lesbare diskrete Graphiken

- Balkendiagramme

Einteilung der Graphiken

		Erste Variable	
		diskret	stetig
	keine	x	x
zweite Variable	diskret		
	stetig		

- *stetige Daten
- *diskrete Daten
- stetig–stetig
- diskret–diskret
- diskret–stetig

Einteilung der Graphiken

		Erste Variable	
		diskret	stetig
	keine	x	x
zweite Variable	diskret		
	stetig		X

- *stetige Daten
- *diskrete Daten
- stetig–stetig als nächstes
- diskret–diskret
- diskret–stetig

Stetig–Stetig

- Streudiagramm
- Kenngrößen für stetige Abhängigkeit
- QQ-plot
- Streudiagrammmatrix

Streudiagramm

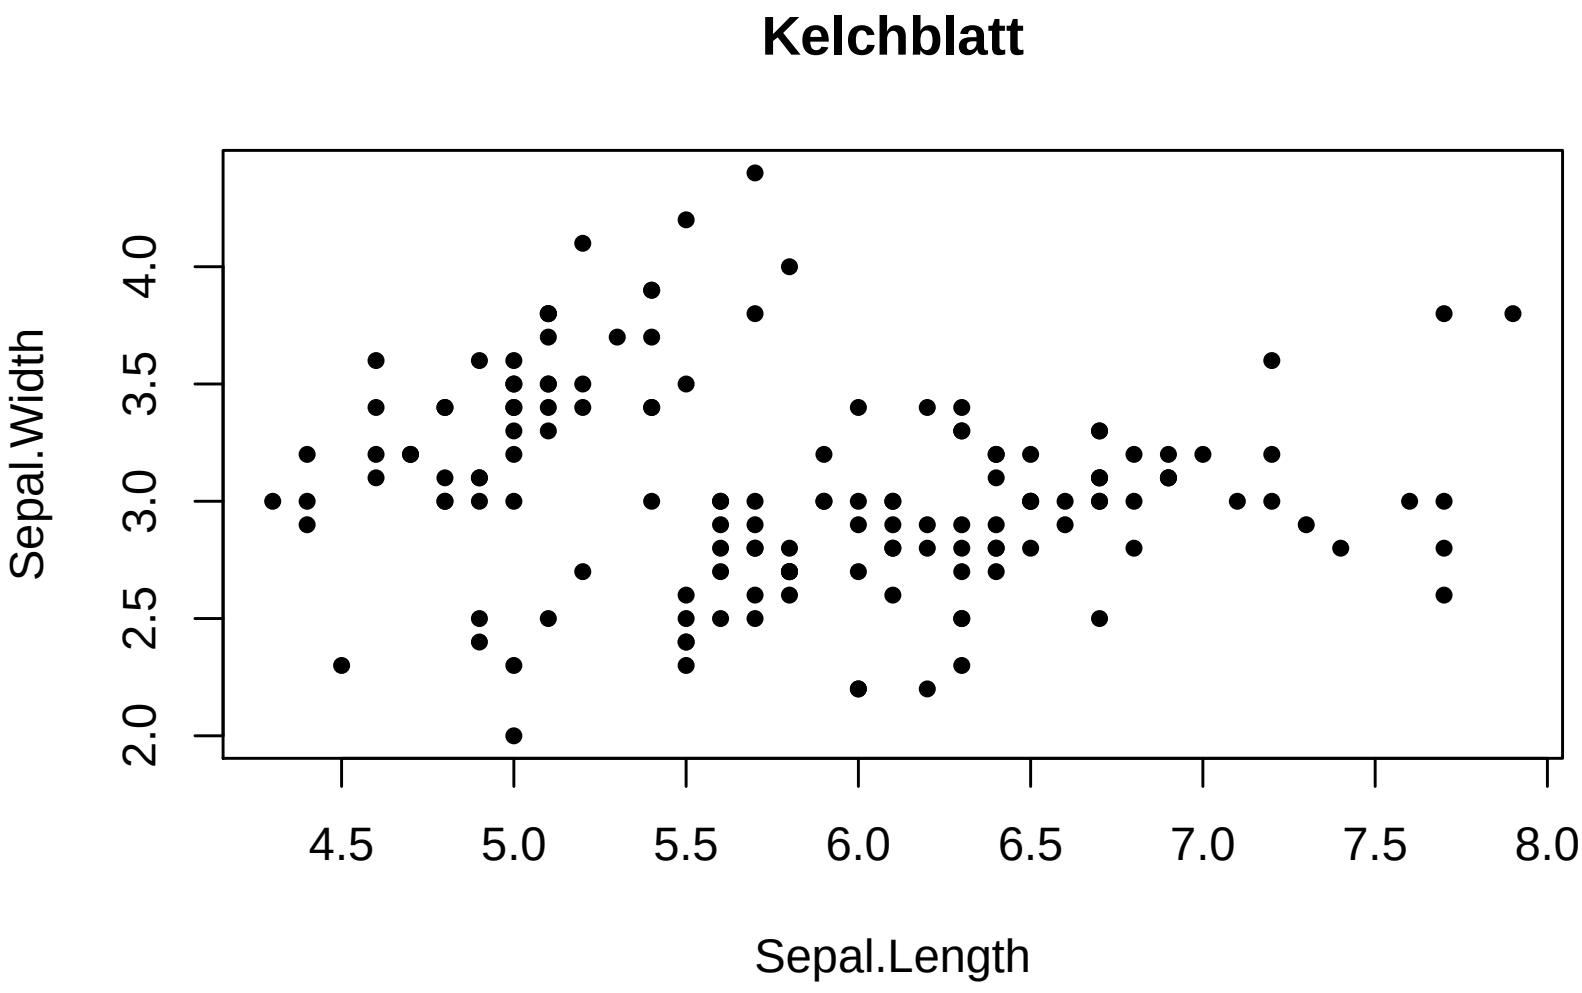

Streudiagramm

- Überlagerung bei Bindungen
- Verzerrung durch Ausreißer
- Probleme bei extremer Schiefe
- Nicht: Kenngrößen, nahe Ausreißer

(Pearson) Korrelation

$$
\begin{aligned}
\hat{\mathrm{cor}}(X, Y) &= \frac{\hat{\mathrm{cov}}(X, Y)}{\sqrt{\hat{\mathrm{var}}(X)\hat{\mathrm{var}}(Y)}} \\
\hat{var}(X) &= \frac{1}{n-1}\sum_{i=1}^{n}(X_i - \bar{X})^2 \\
\hat{var}(Y) &= \frac{1}{n-1}\sum_{i=1}^{n}(Y_i - \bar{Y})^2 \\
\hat{cov}(X, Y) &= \frac{1}{n-1}\sum_{i=1}^{n}(X_i - \bar{X})(Y_i - \bar{Y})
\end{aligned}
$$

Theoretischen Interpretation

- $-1 \leq \hat{\text{cor}}(X, Y) \leq 1$
- stochastisch unabhängig
  $\Rightarrow \text{cov}(X, Y) = 0 \Rightarrow \text{cor}(X, Y) \not\Rightarrow \hat{\text{cor}}(X, Y) = 0$
- $\text{cor}(X, Y) = 1 \Leftrightarrow X \propto Y$
- $\text{cor}(X, Y) = -1 \Leftrightarrow X \propto -Y$

(Pearson) Korrelation

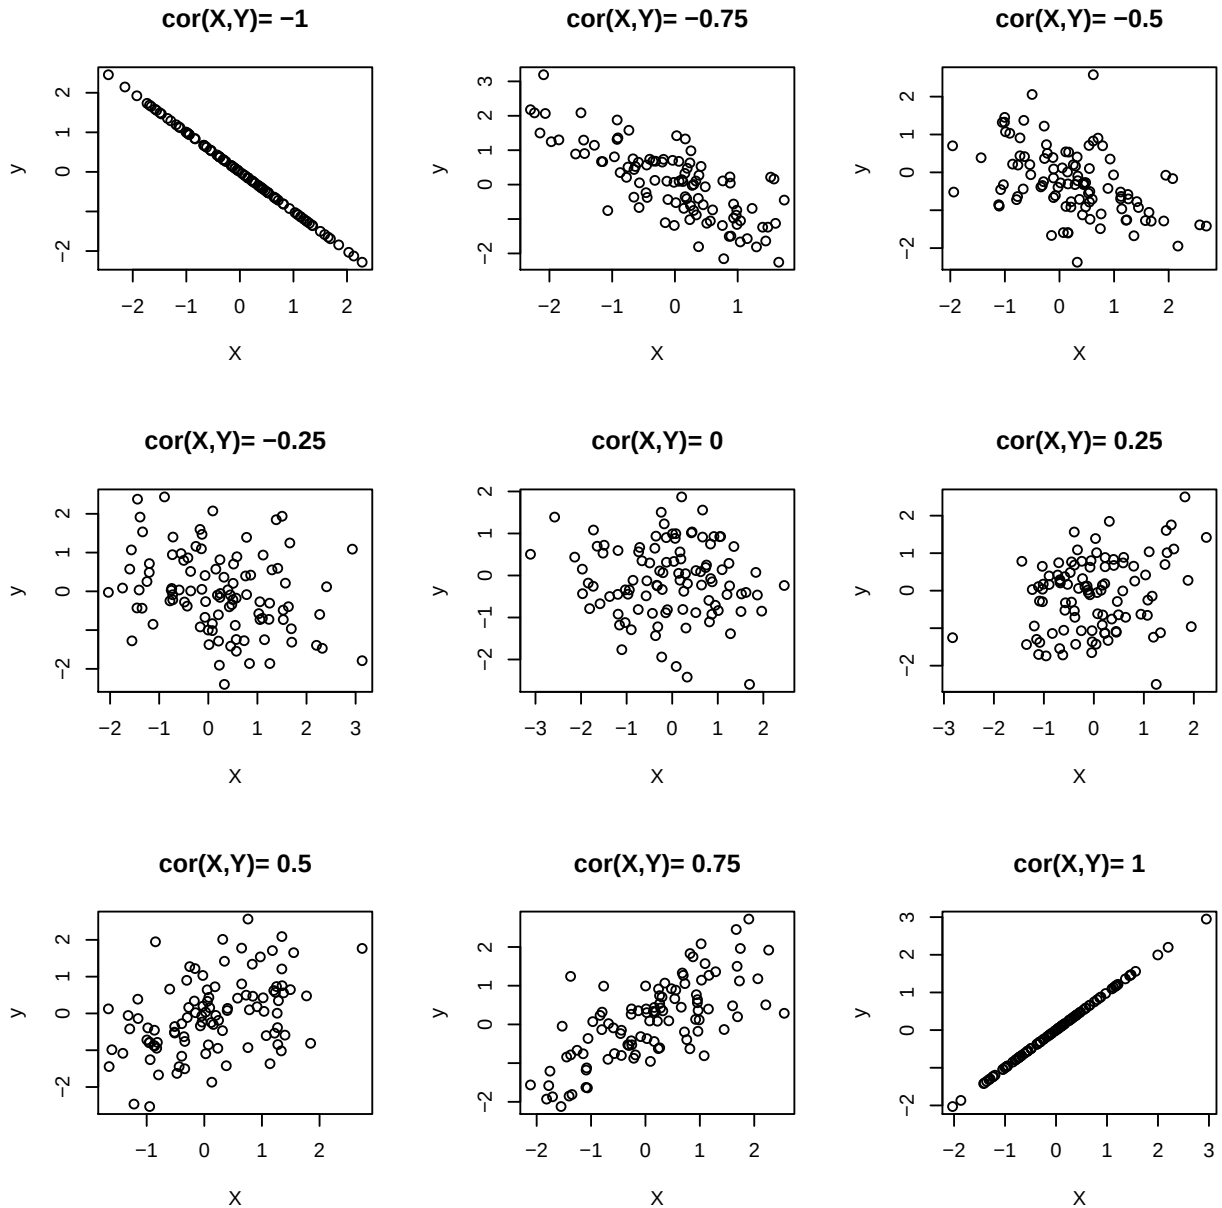

Motivation für Rangkorrelation

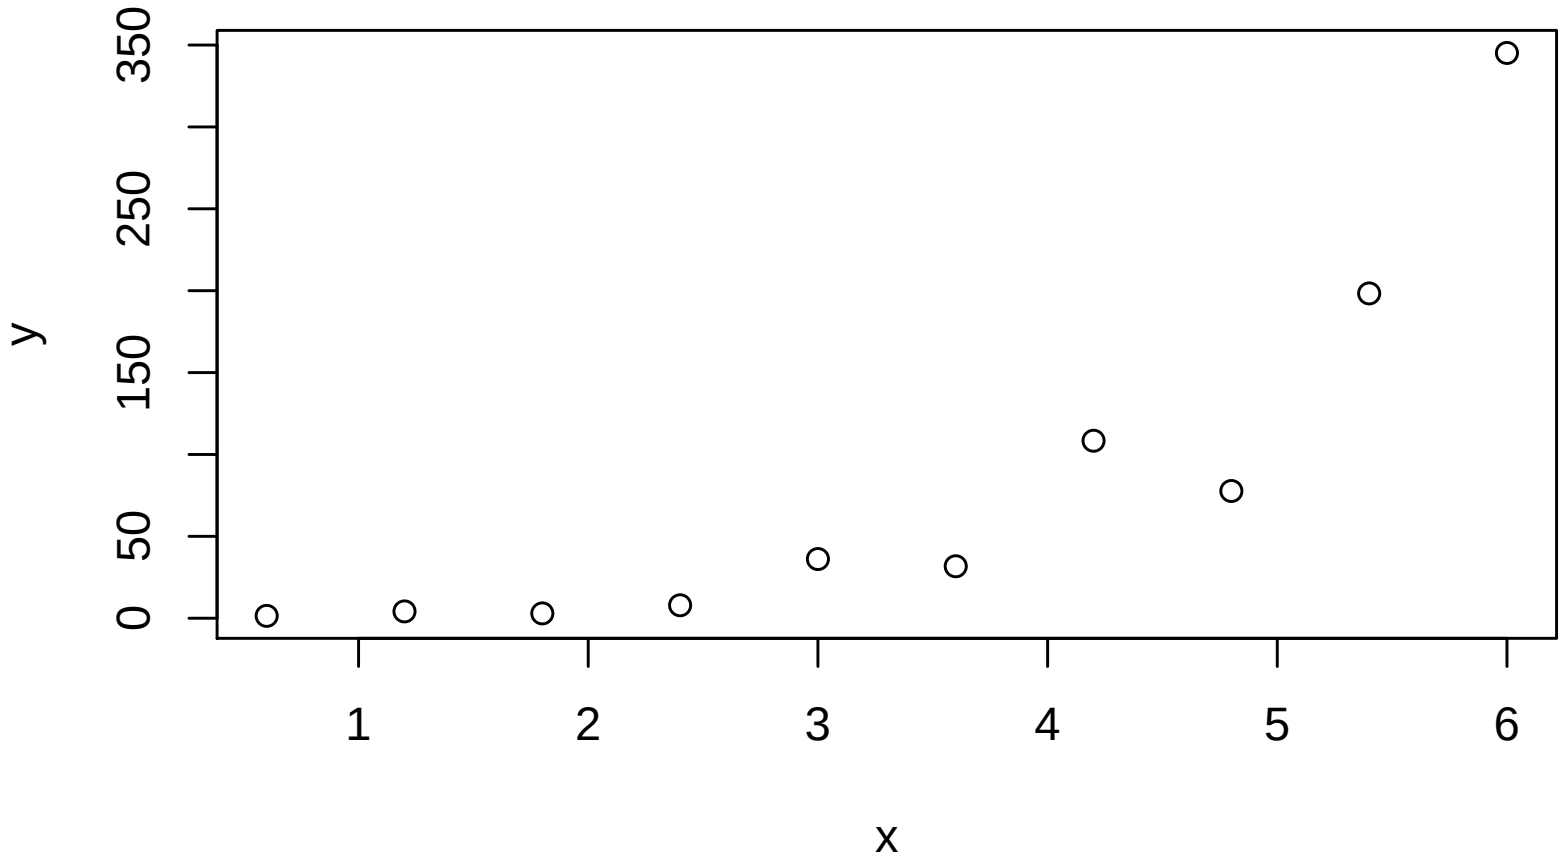

Rangziffern

$$r_{\uparrow i} = \text{Rang der i-ten Beobachtung}$$

```
> x

 [1] 1.8 1.2 0.6 2.4 3.0 3.6 4.2 4.8 6.0 5.4

> rank(x)

 [1]  3  2  1  4  5  6  7  8 10  9

> y

 [1]   2.963372   4.191878   1.482011   7.934833  36.176051
 [6]  31.753800 108.401706  77.721528 345.201323 198.373120

> rank(y)

 [1]  2  3  1  4  6  5  8  7 10  9
```

Rangverfahren

- **Idee:** Ersetzte Daten durch ihren Rang

Rangverfahren

- **Idee:** Ersetzte Daten durch ihren Rang
- **Vorteil:** Die Auswertbarkeit ist unabhängig von der Verteilung.

Rangverfahren

- **Idee:** Ersetzte Daten durch ihren Rang
- **Vorteil:** Die Auswertbarkeit ist unabhängig von der Verteilung.
- **Nachteil 1:** Man verliert Information.

Rangverfahren

- **Idee:** Ersetzte Daten durch ihren Rang
- **Vorteil:** Die Auswertbarkeit ist unabhängig von der Verteilung.
- **Nachteil 1:** Man verliert Information.
- **Nachteil 2:** Interpretation schwieriger.

Rangverfahren

- **Idee:** Ersetzte Daten durch ihren Rang
- **Vorteil:** Die Auswertbarkeit ist unabhängig von der Verteilung.
- **Nachteil 1:** Man verliert Information.
- **Nachteil 2:** Interpretation schwieriger.
- **Problem:** Rangziffernbestimmung bei Bindungen problematisch

Spearman Korrelation

```
> plot(rank(x),rank(y))
```

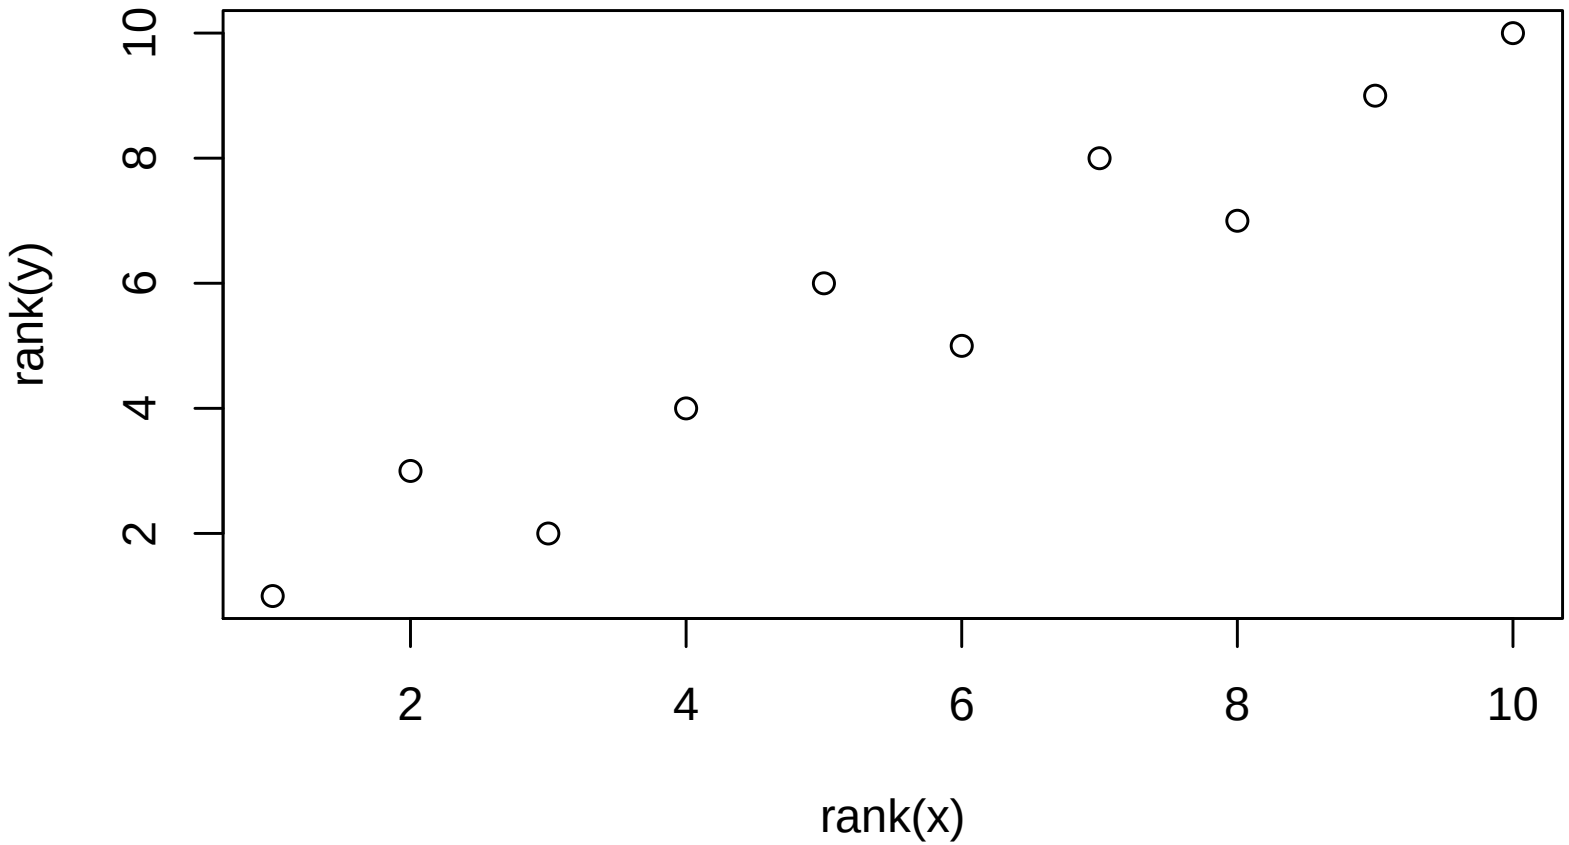

Spearman Korrelation

```
> cor(x,y)
[1] 0.8411657
> cor(rank(x),rank(y))
[1] 0.9636364
> cor(x,y,method="spearman")
[1] 0.9636364
> cor(x,y,method="pearson")
[1] 0.8411657
```

Vergleich

- Pearson Korrelation quantifiziert lineare Abhängigkeit
- Spearman Korrelation quantifiziert monotone Abhängigkeit

Vergleich

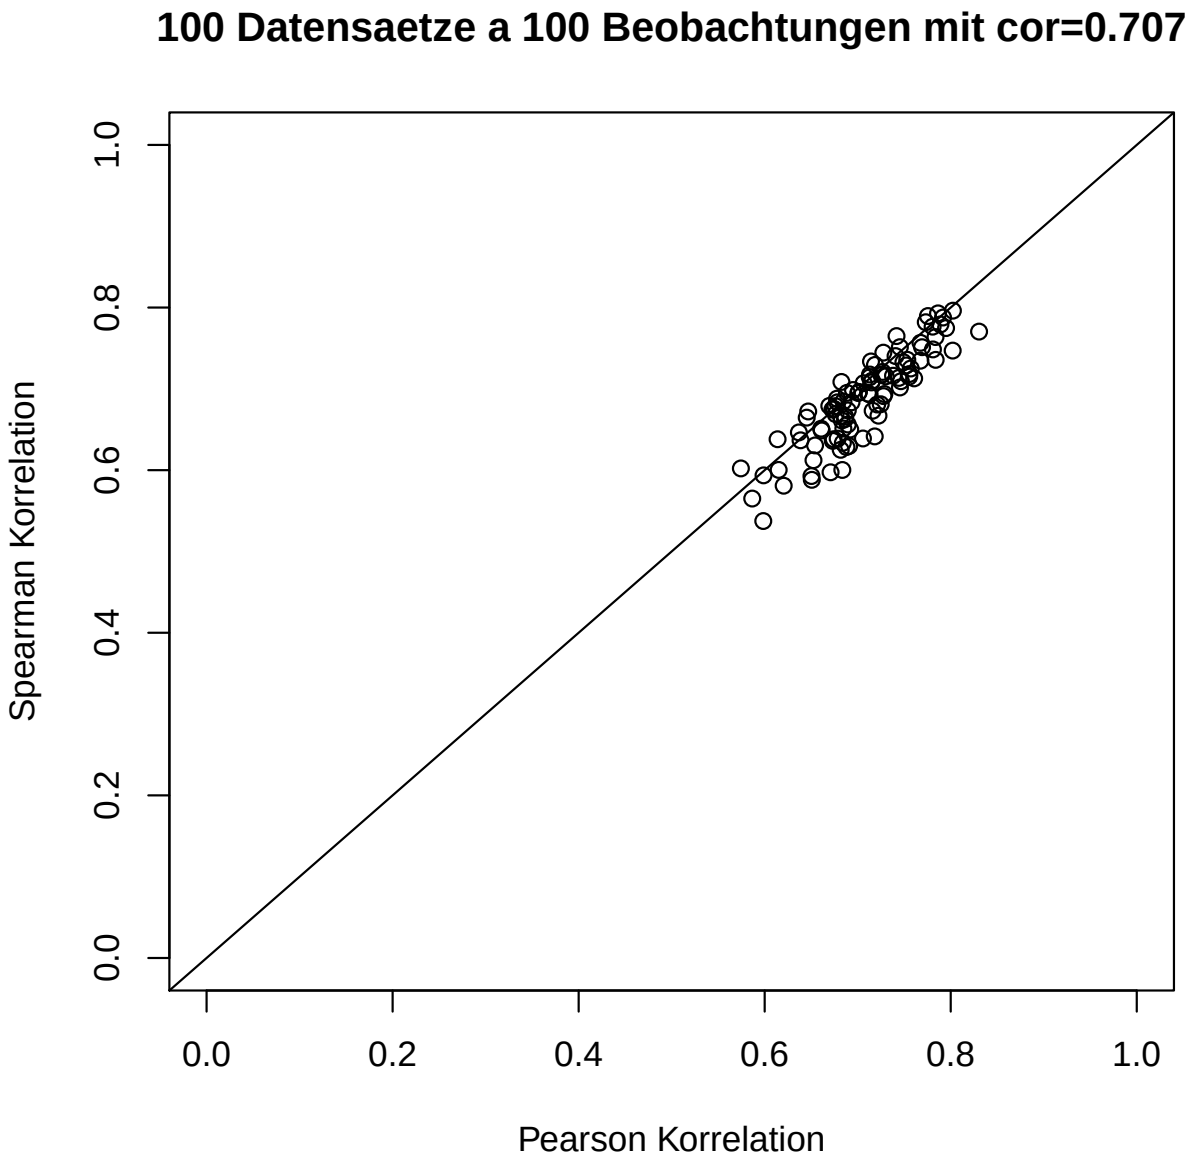
100 Datensaetze a 100 Beobachtungen mit cor=0.707
Spearman Korrelation
Pearson Korrelation
0.0
0.2
0.4
0.6
0.8
1.0

Streudiagrammmatrix

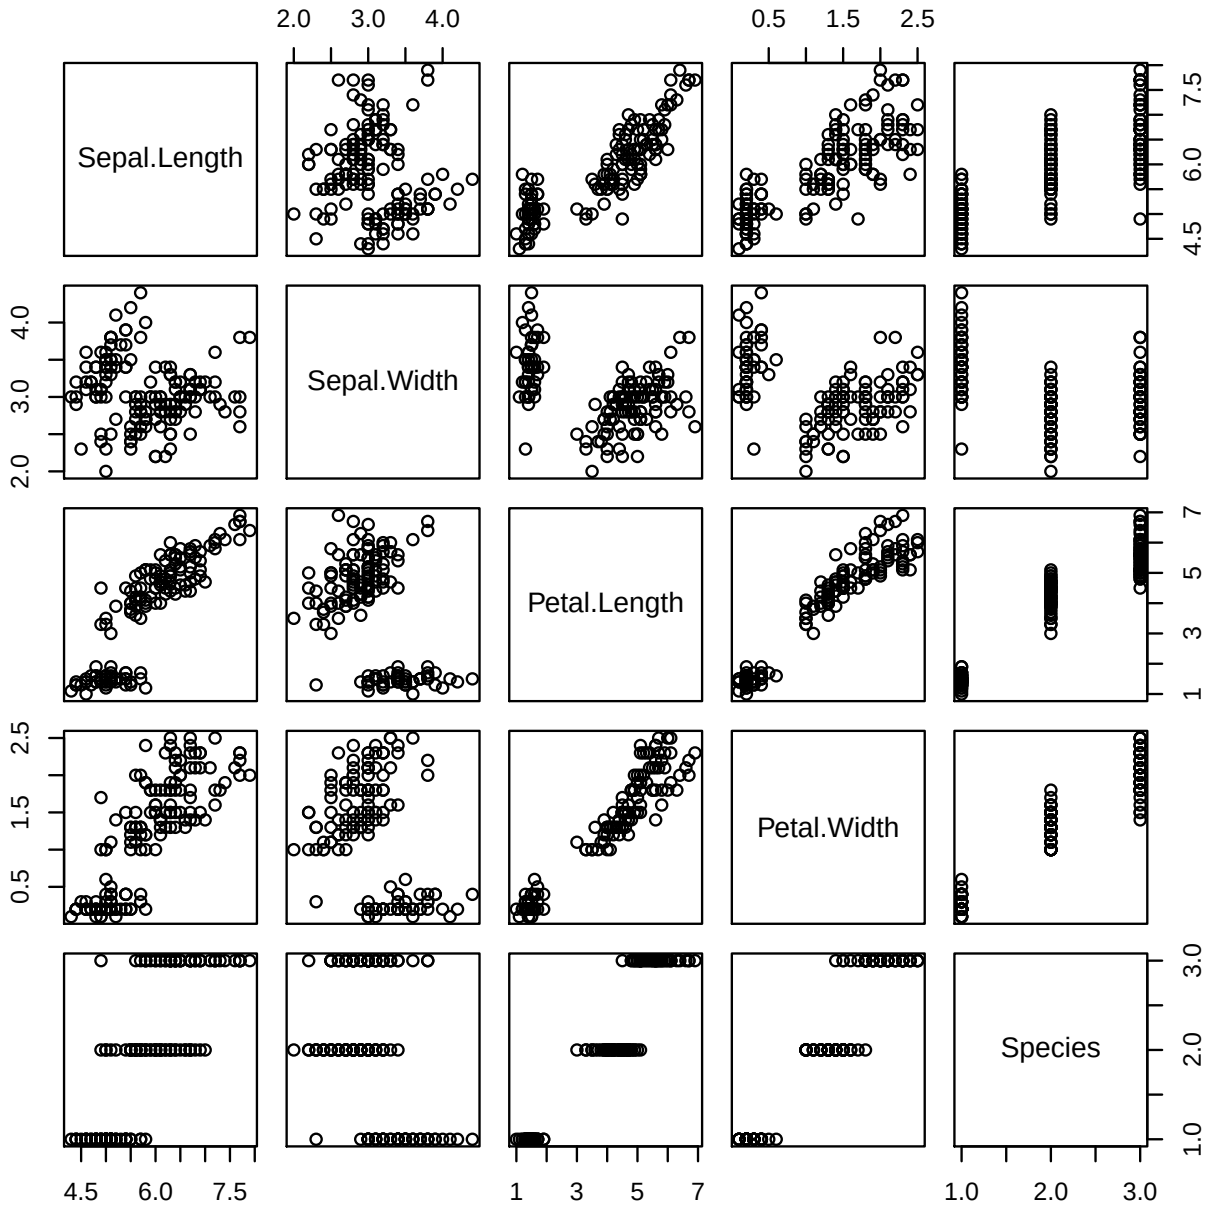

Einteilung der Graphiken

		Erste Variable	
		diskret	stetig
	keine	x	x
zweite Variable	diskret		
	stetig		x

- *stetige Daten
- *diskrete Daten
- *stetig–stetig
- diskret–diskret
- diskret–stetig

Einteilung der Graphiken

		Erste Variable	
		diskret	stetig
	keine	x	x
zweite Variable	diskret	X	
	stetig		x

- *stetige Daten
- *diskrete Daten
- *stetig–stetig
- diskret–diskret als nächstes
- diskret–stetig

diskret–diskret

- gestapelte Balkendiagramme
- paralle Balkendiagramme
- Mosaikplots

Passagiere der Titanic

```
> data(Titanic)
> X <- apply(Titanic,c(2,3),sum)
> X

        Age
Sex      Child Adult
  Male      64  1667
  Female    45   425
```

gestapelte Balkendiagramme

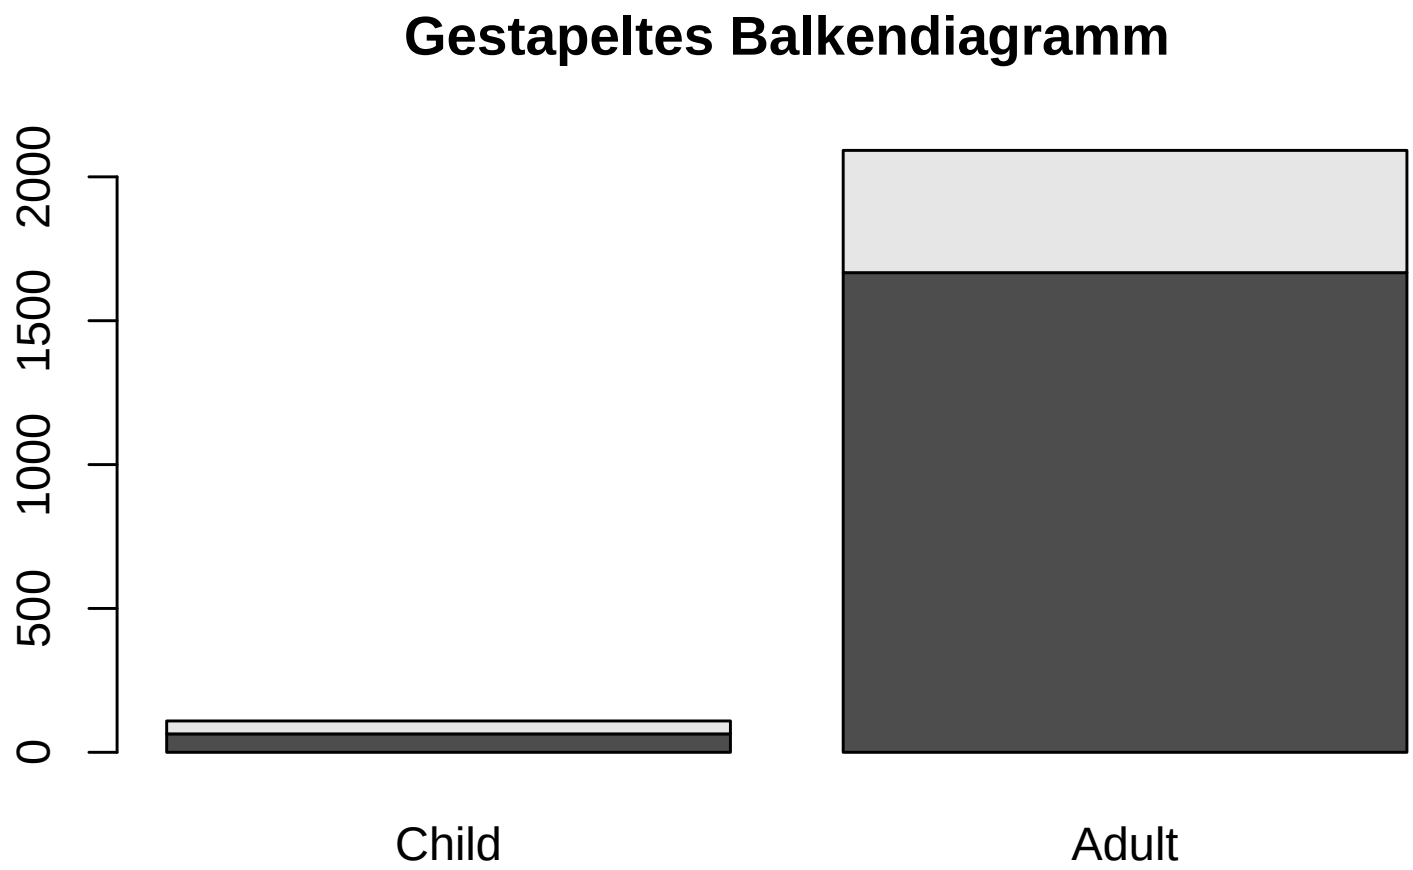

parallele Balkendiagramme

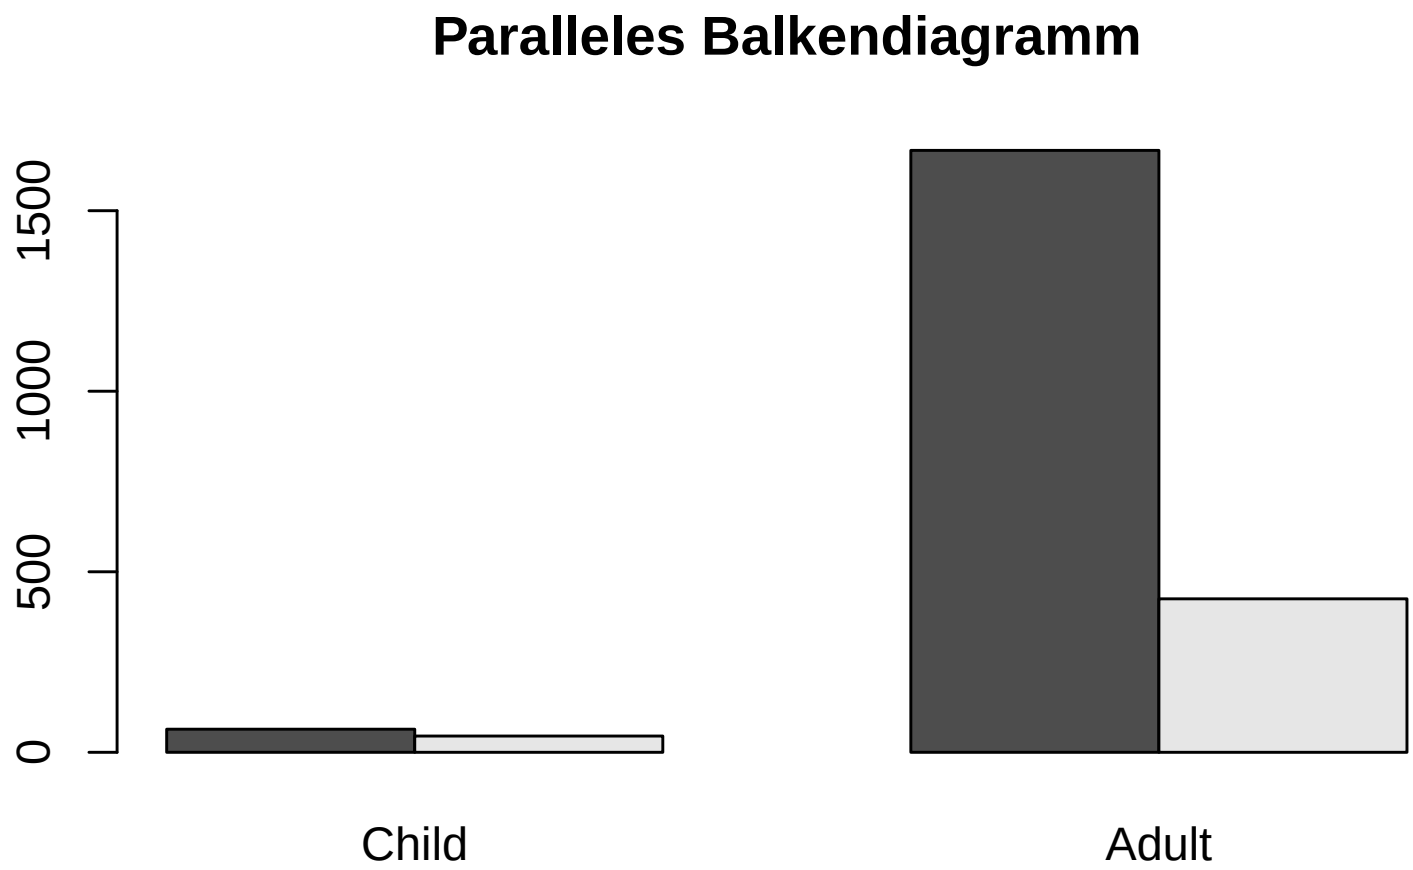

Mosaikplot (1 Variable)

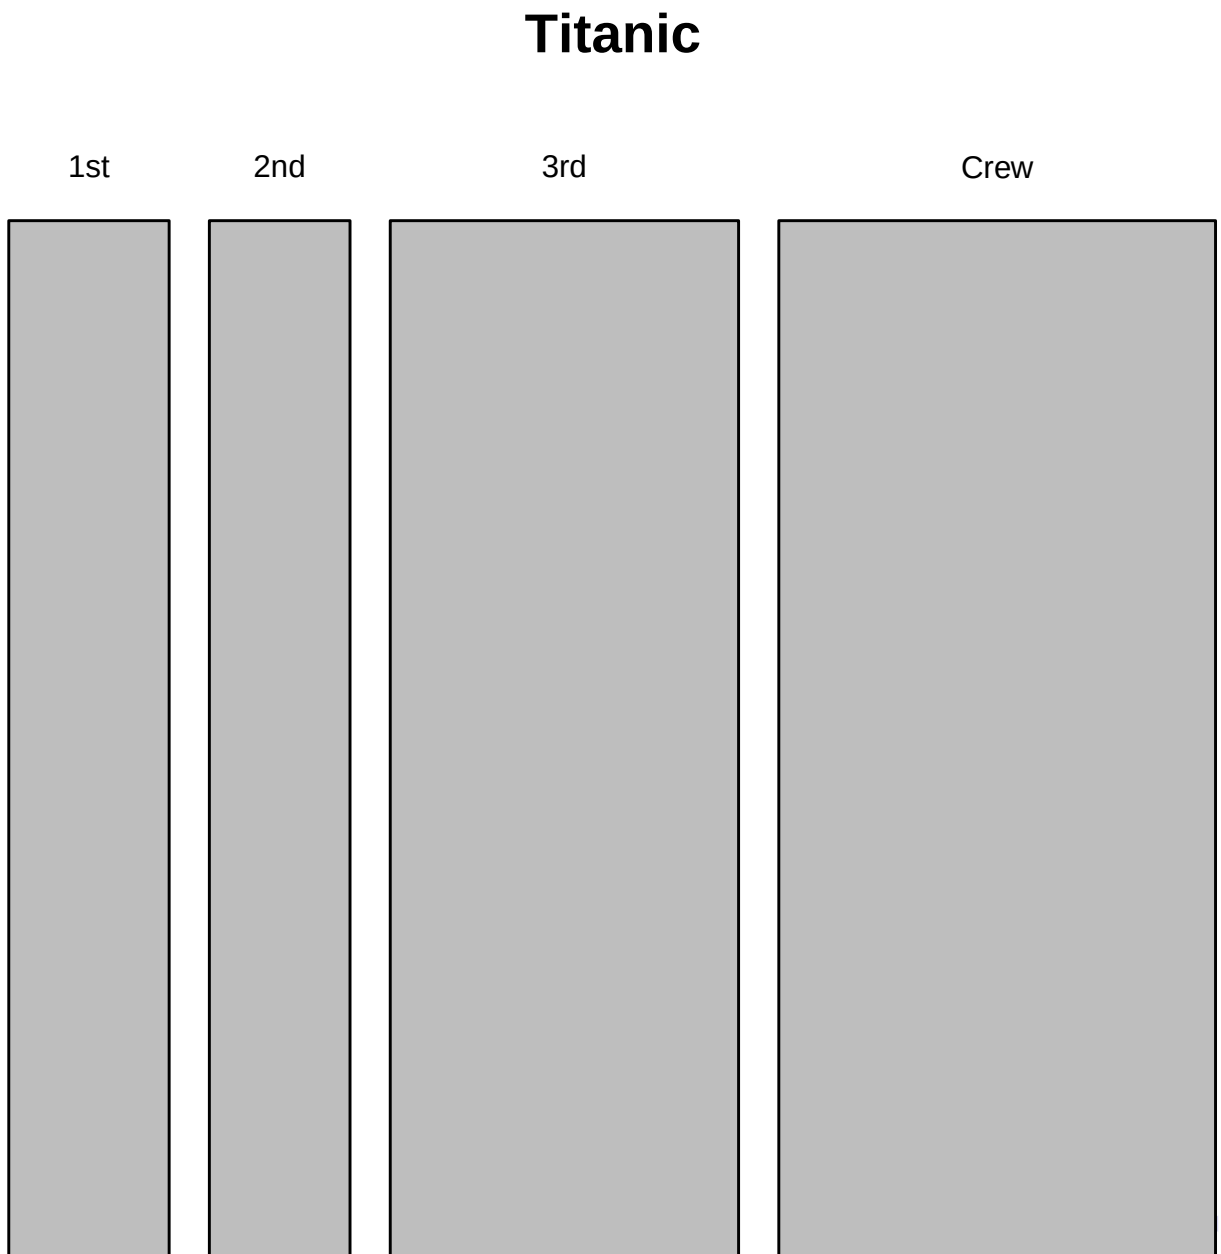

Mosaikplot (2 Variablen)

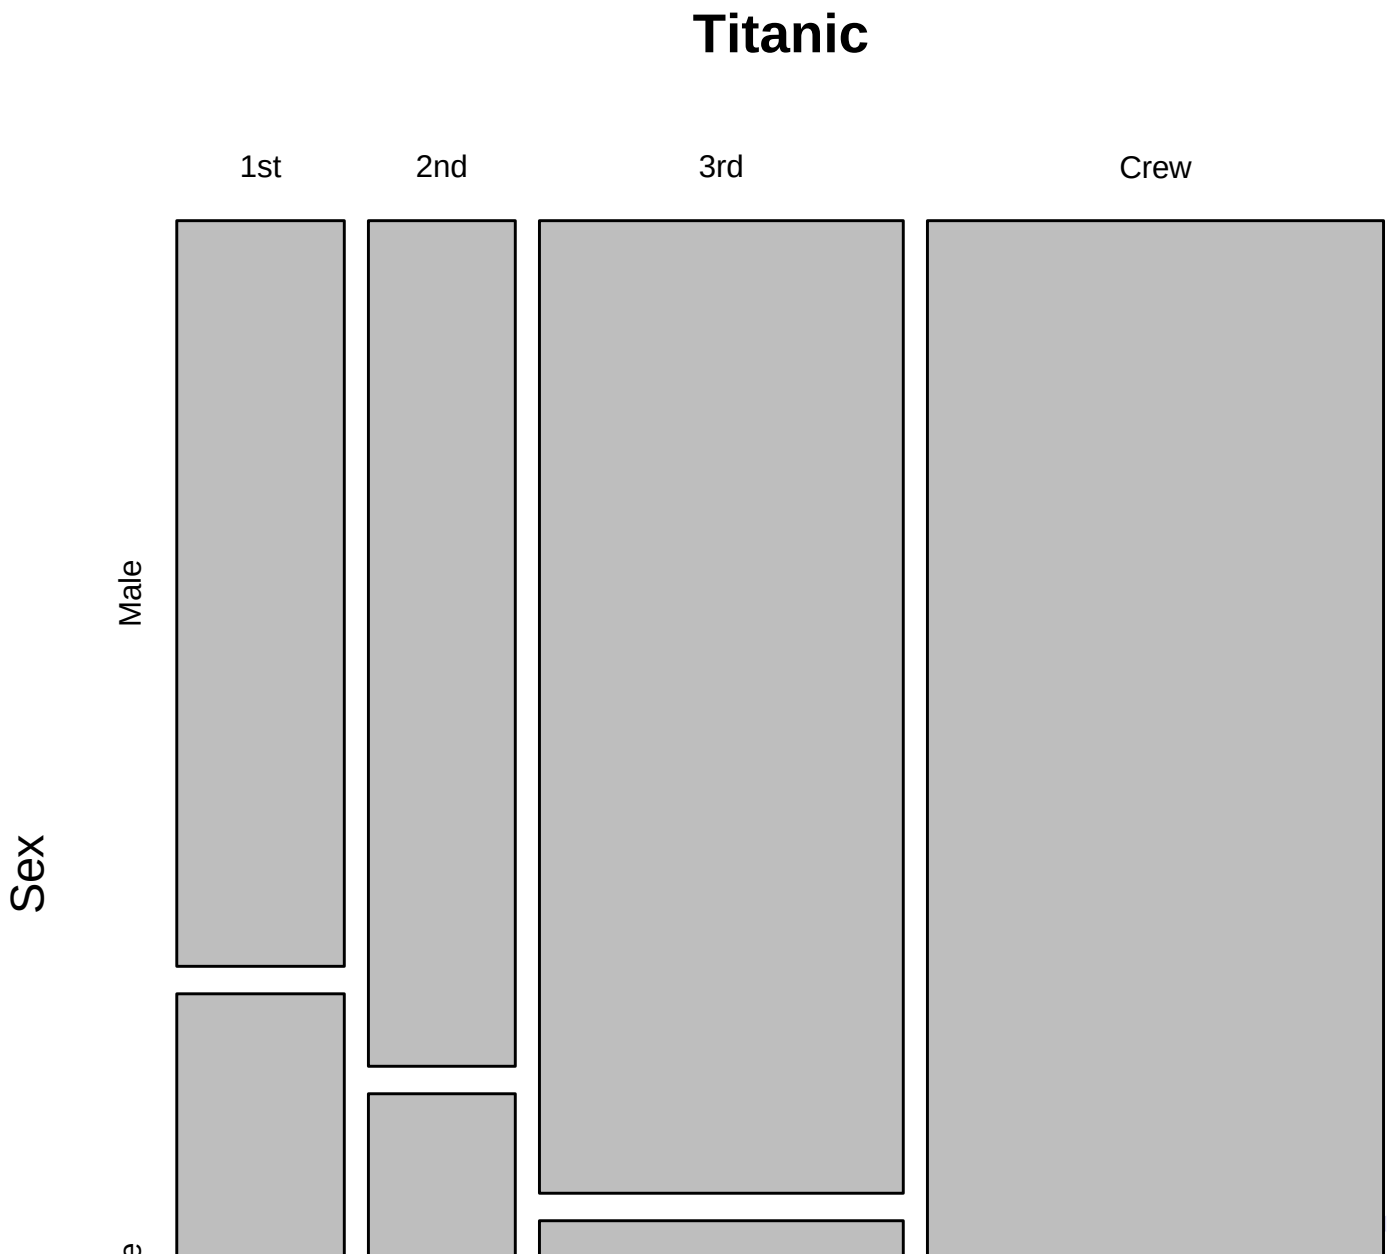

Mosaikplot (3 Variablen)

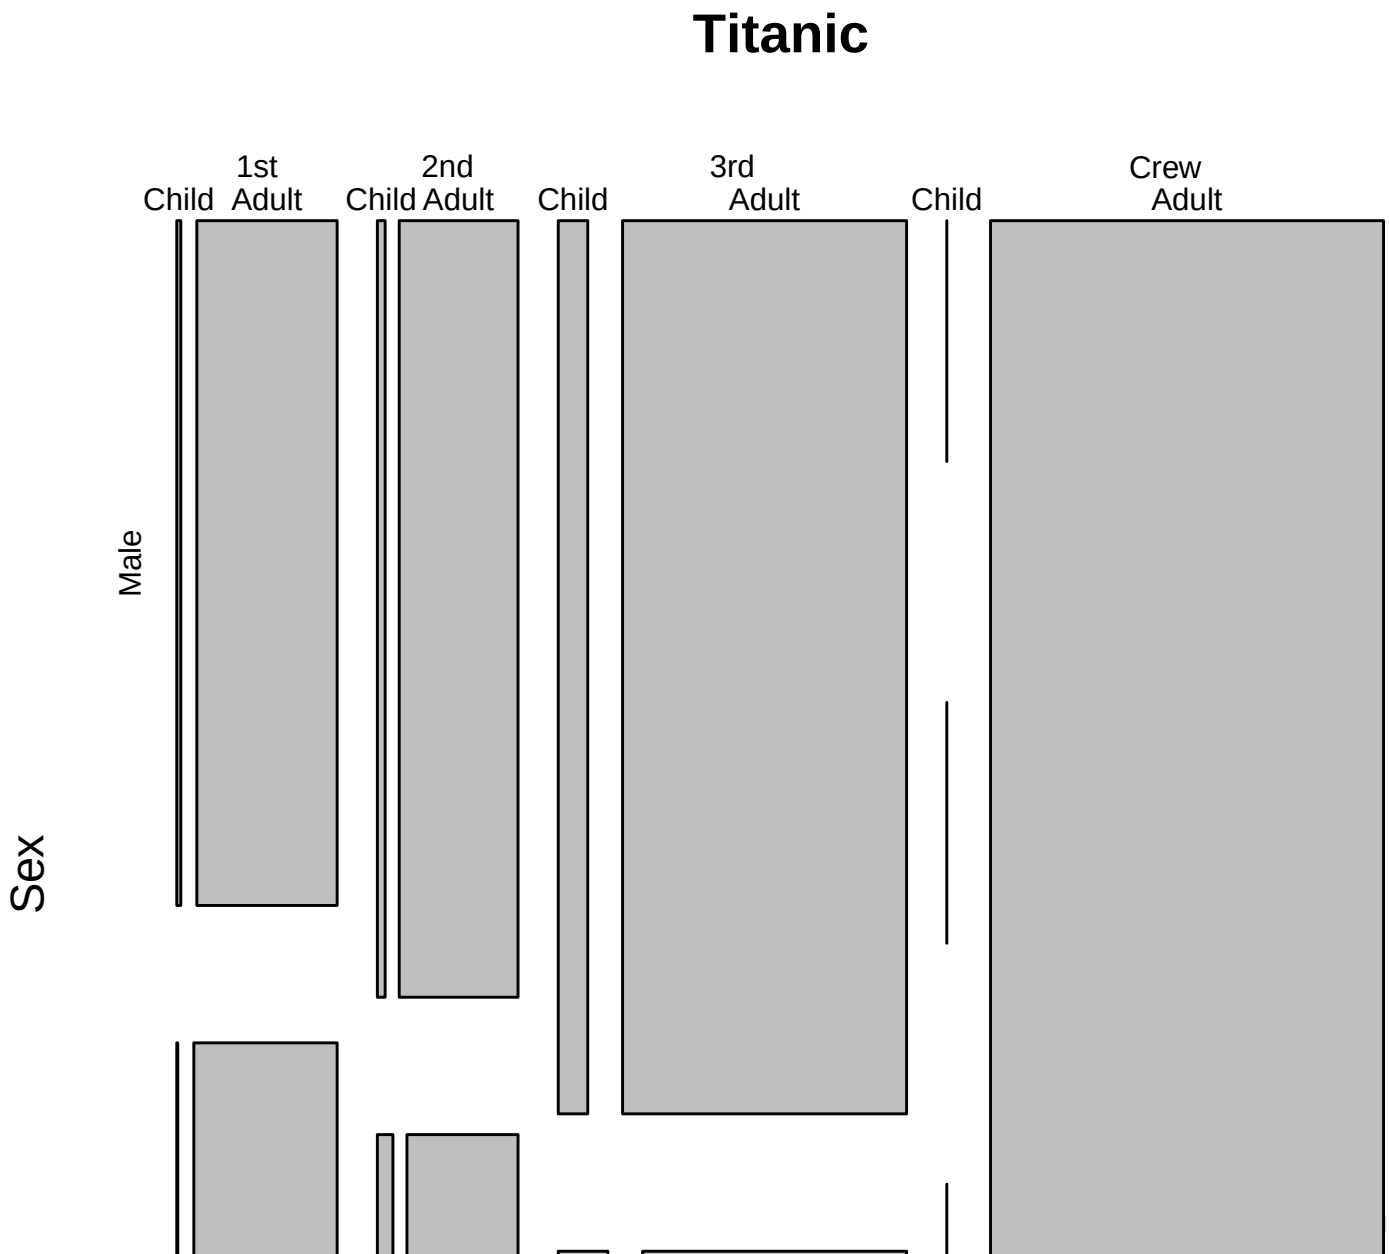

Mosaikplot (4 Variablen)

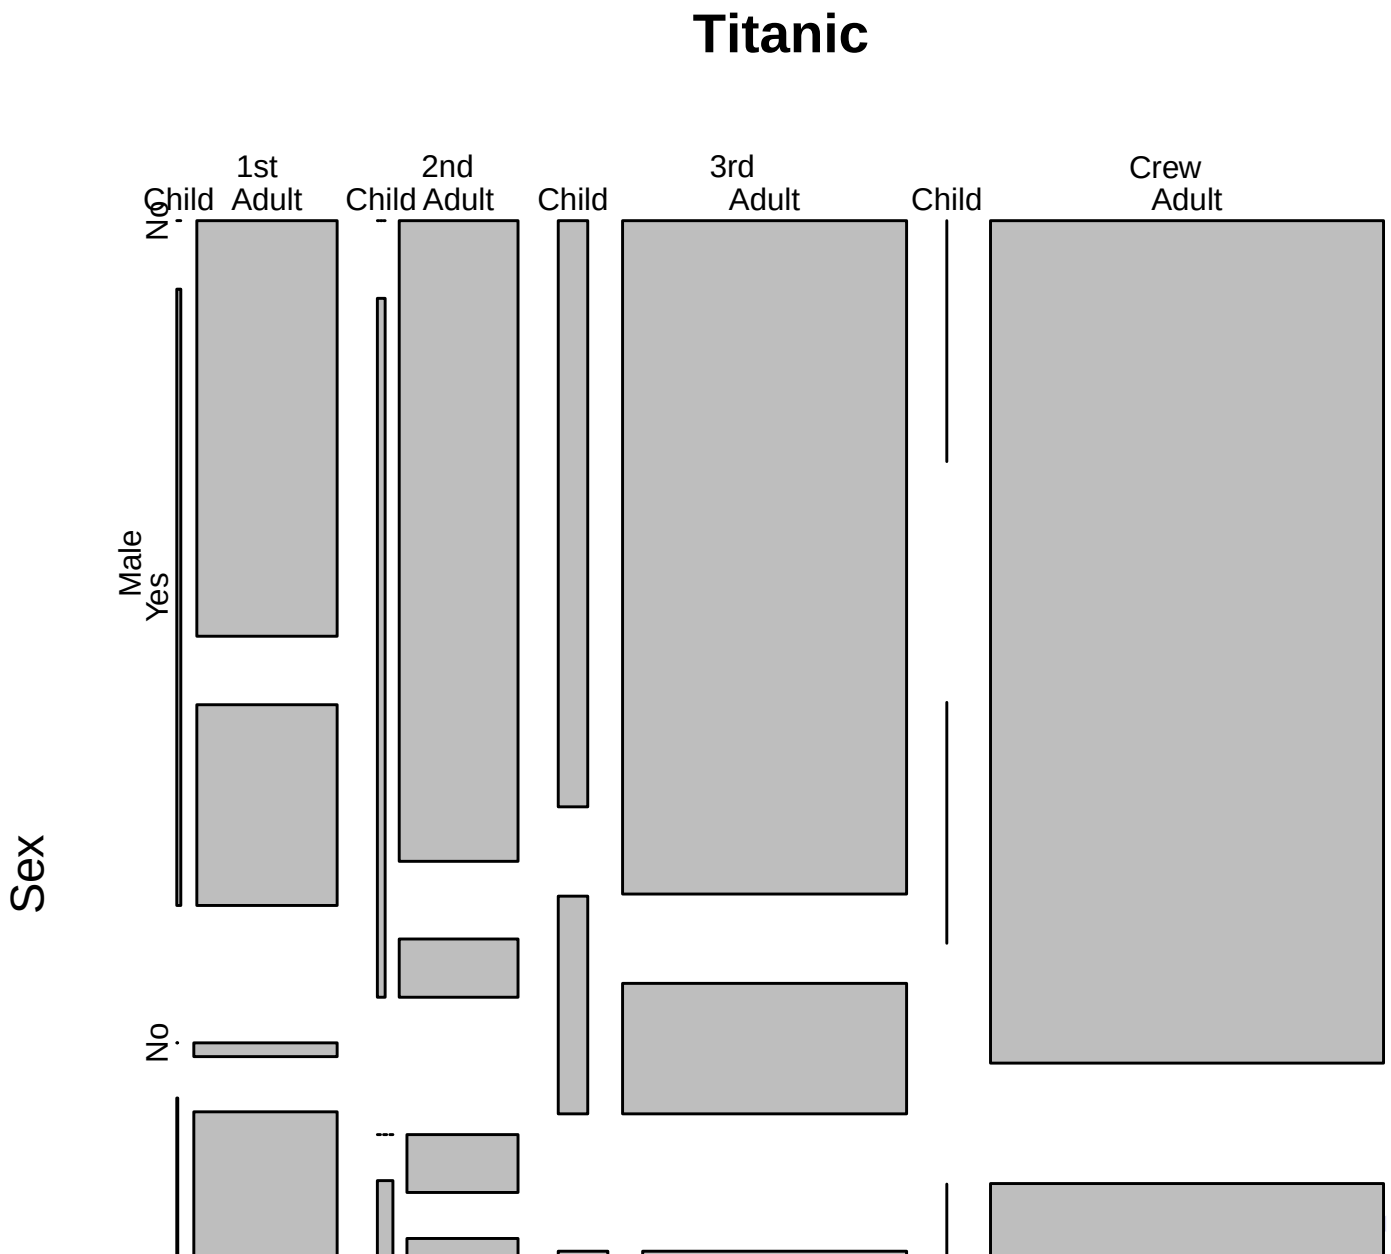

Mosaikplot (Andere Reihenfolge)

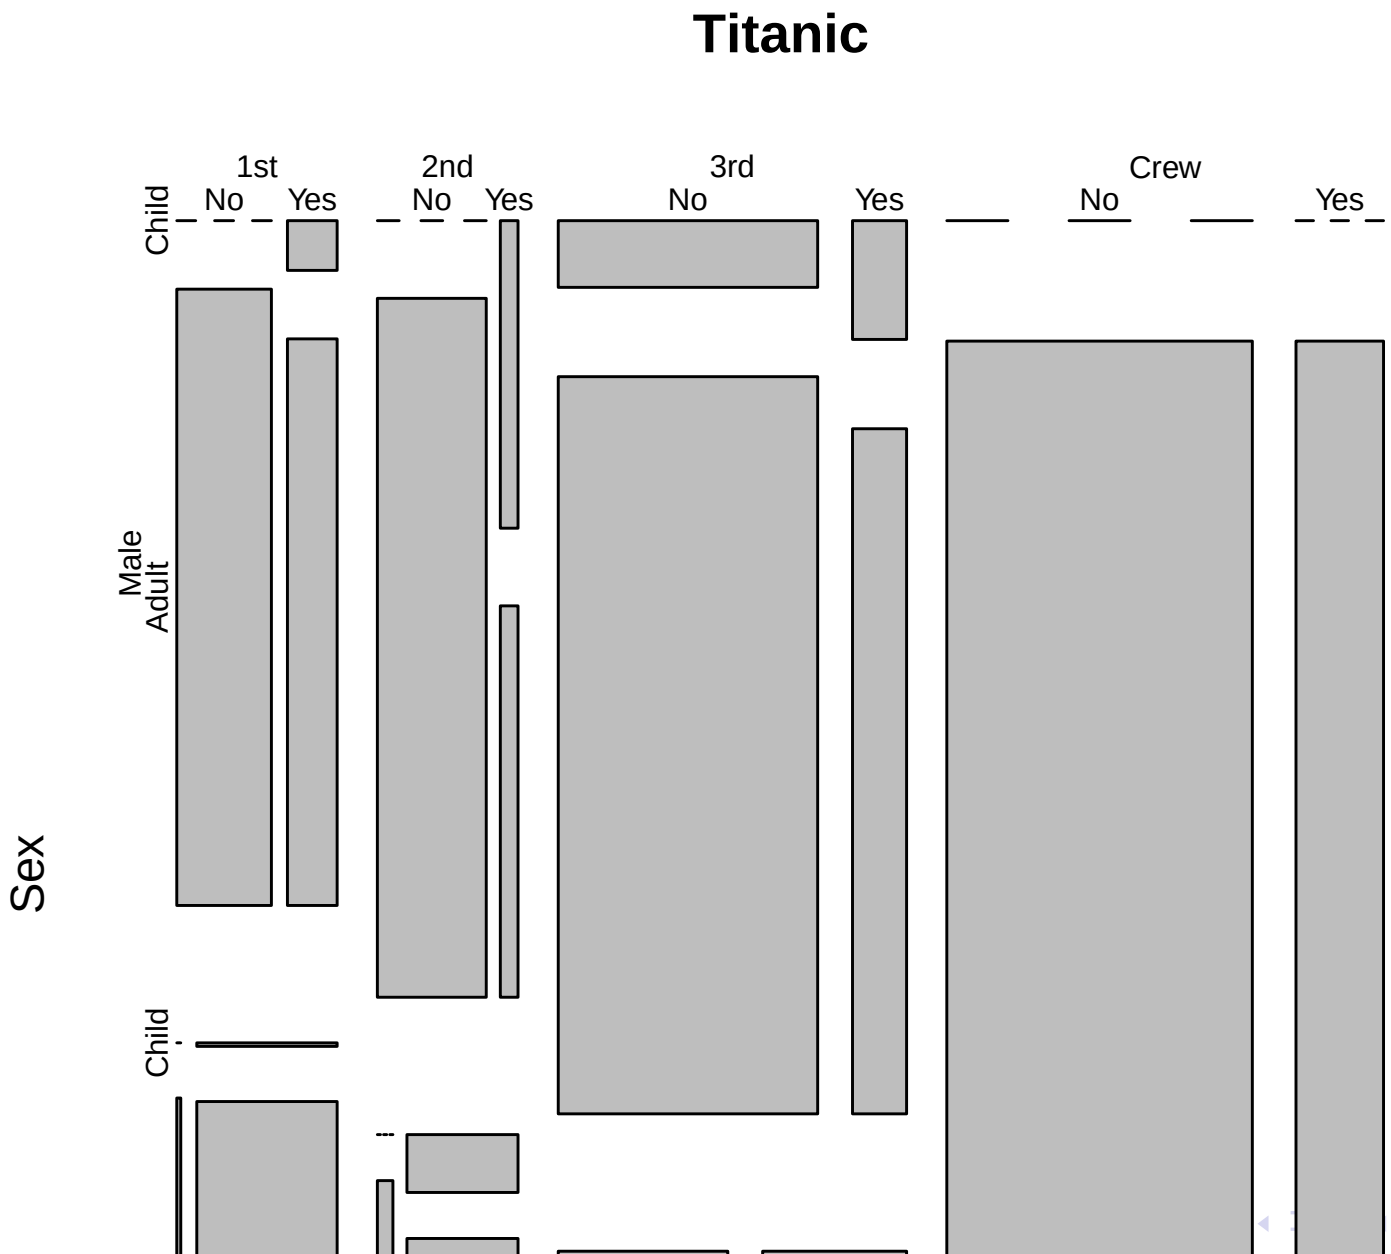

Vergleich

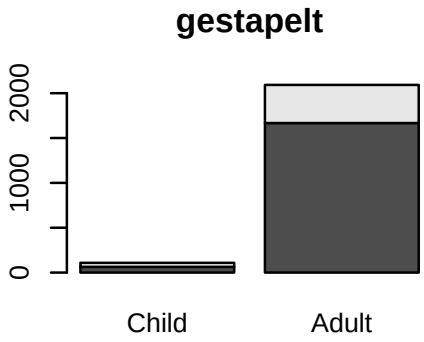
gestapelt
0
1000
2000
Child
Adult

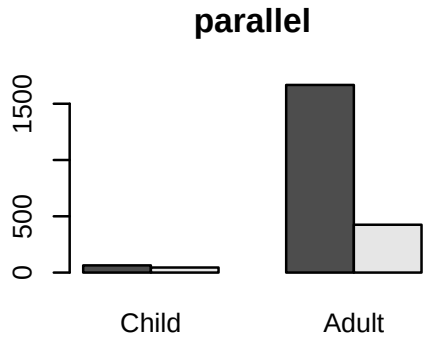
parallel
0
500
1500
Child
Adult

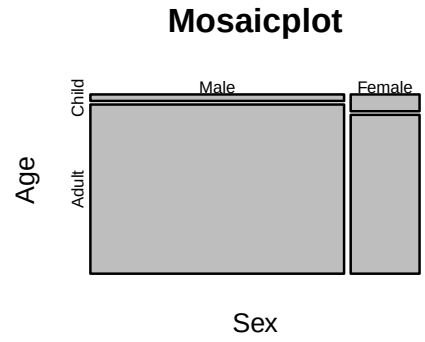
Mosaicplot
Age
Child
Adult
Male
Female
Sex

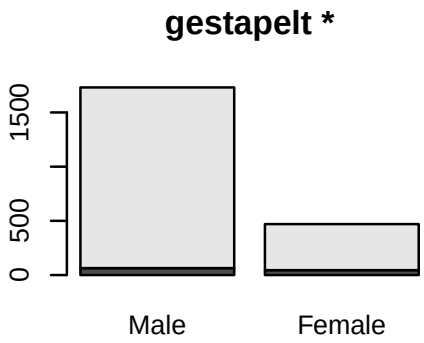
gestapelt *
0
500
1500
Male
Female

parallel *
0
500
1500
Male
Female

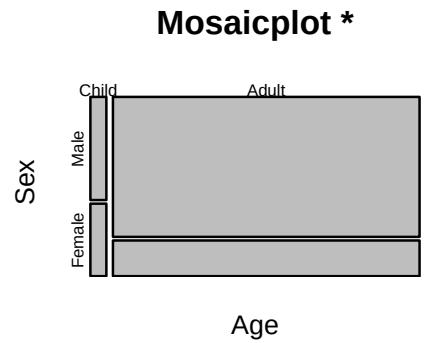
Mosaicplot *
Sex
Male
Female
Child
Adult
Age

Wer kann was?

- Überblick: stapeln
- Vergleich von Teilgruppen: parallel
- Bedingte Wahrscheinlichkeiten: Mosaik

Einteilung der Graphiken

		Erste Variable	
		diskret	stetig
	keine	x	x
zweite Variable	diskret	x	
	stetig		x

- *stetige Daten
- *diskrete Daten
- *stetig–stetig
- *diskret–diskret
- diskret–stetig

Einteilung der Graphiken

		Erste Variable	
		diskret	stetig
	keine	x	x
zweite Variable	diskret	x	X
	stetig	X	x

- *stetige Daten
- *diskrete Daten
- *stetig–stetig
- *diskret–diskret
- diskret–stetig als nächstes

diskret–stetig

- Farben und Symbole
- parallele Punktdiagramme
- parallele Boxplots
- gekerbte Boxplots

Farben und Symbole

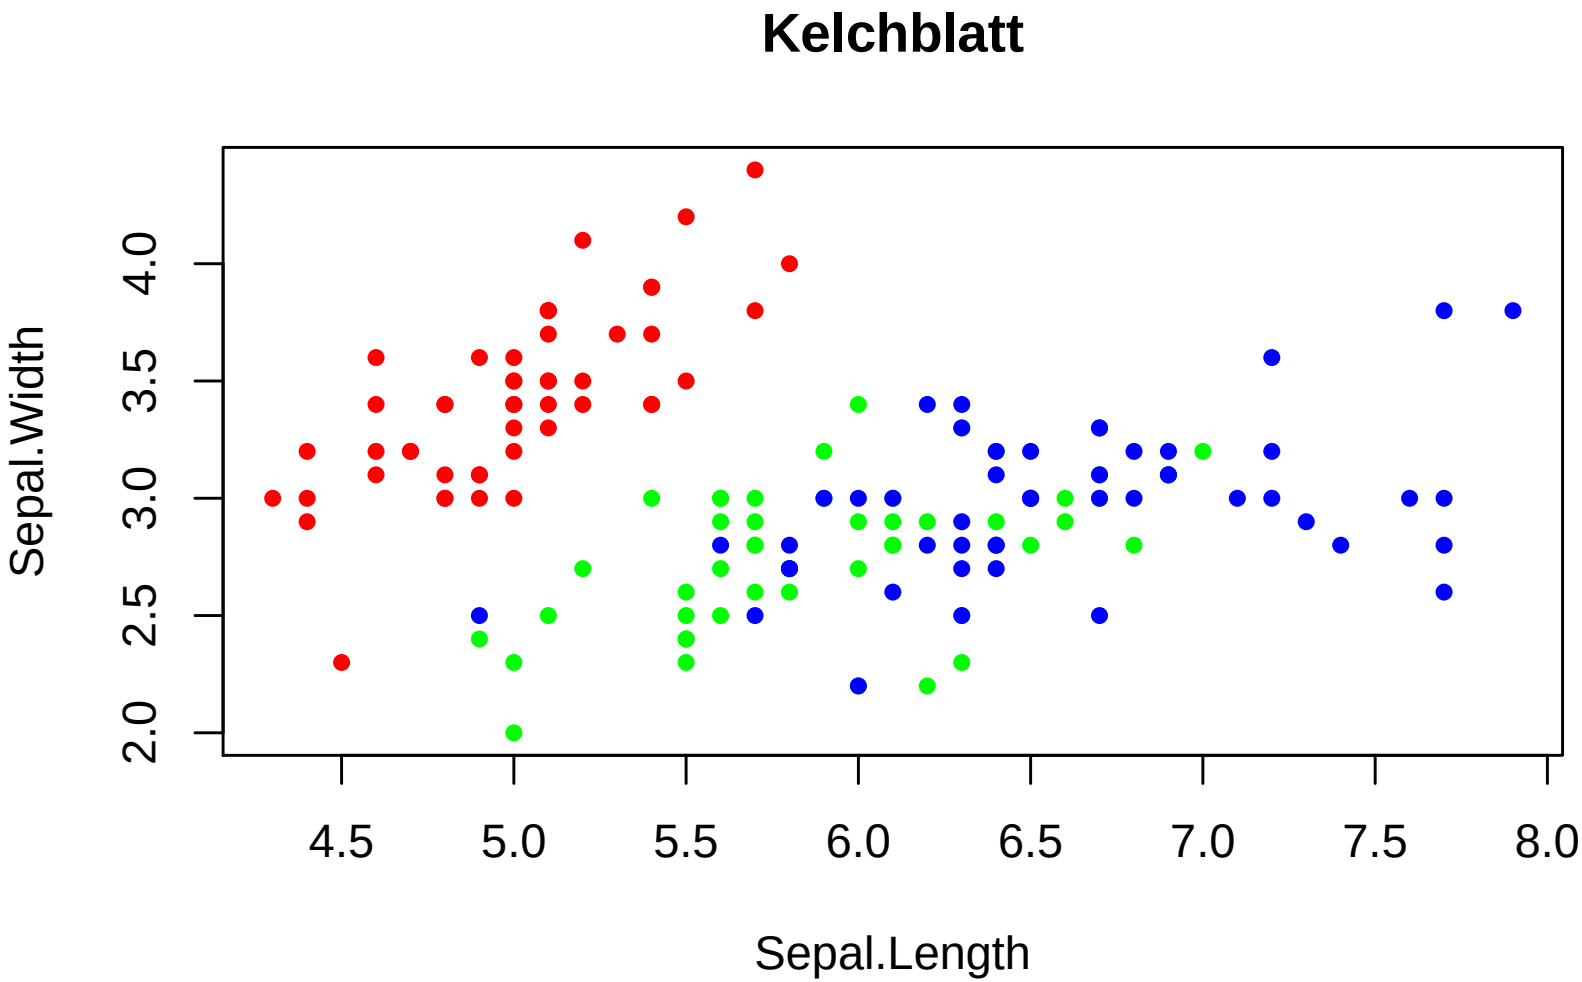

parallele Punktdiagramme

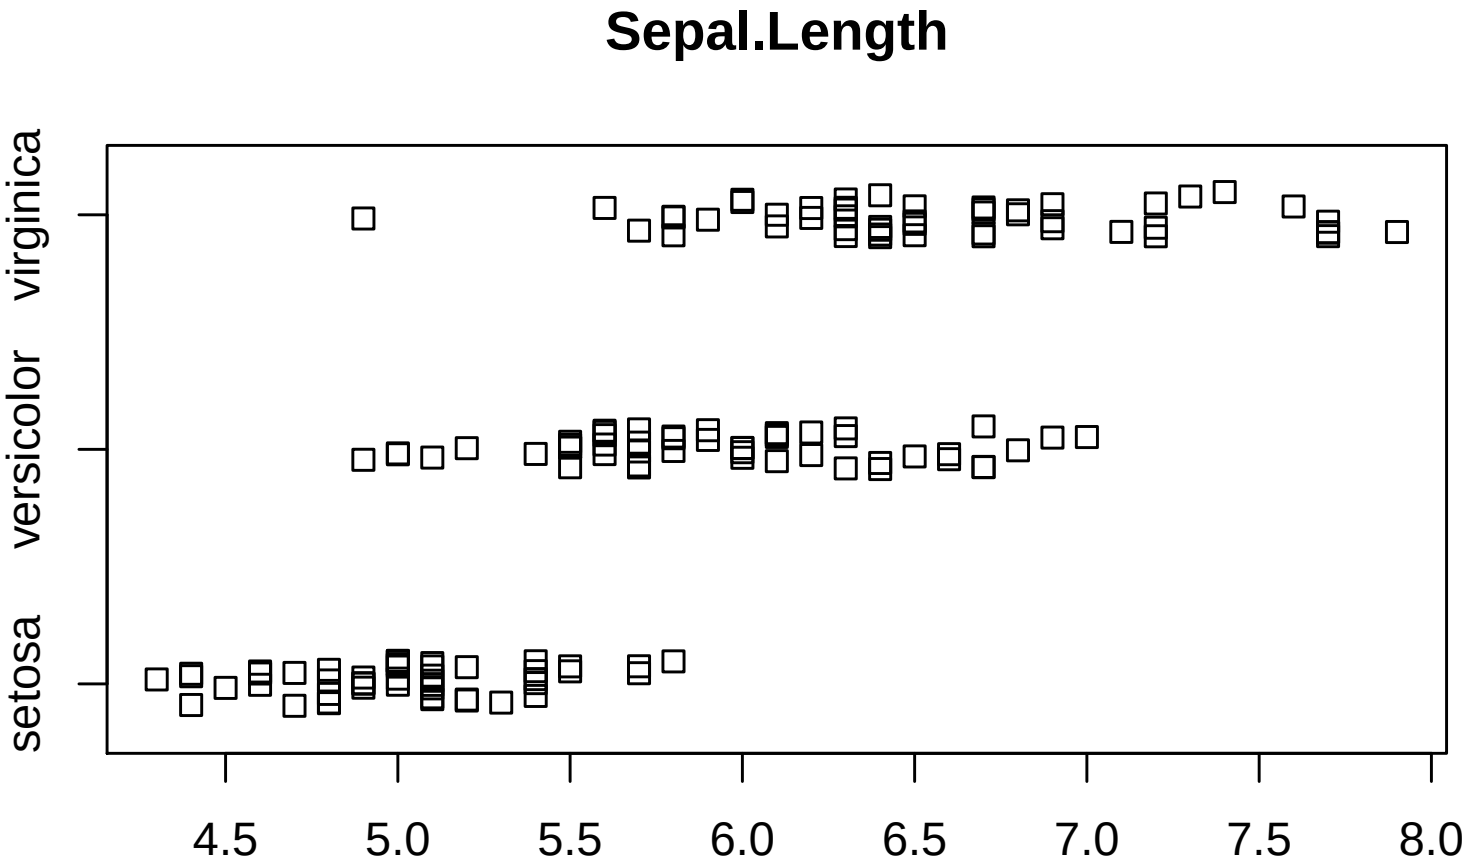

parallele Boxplot

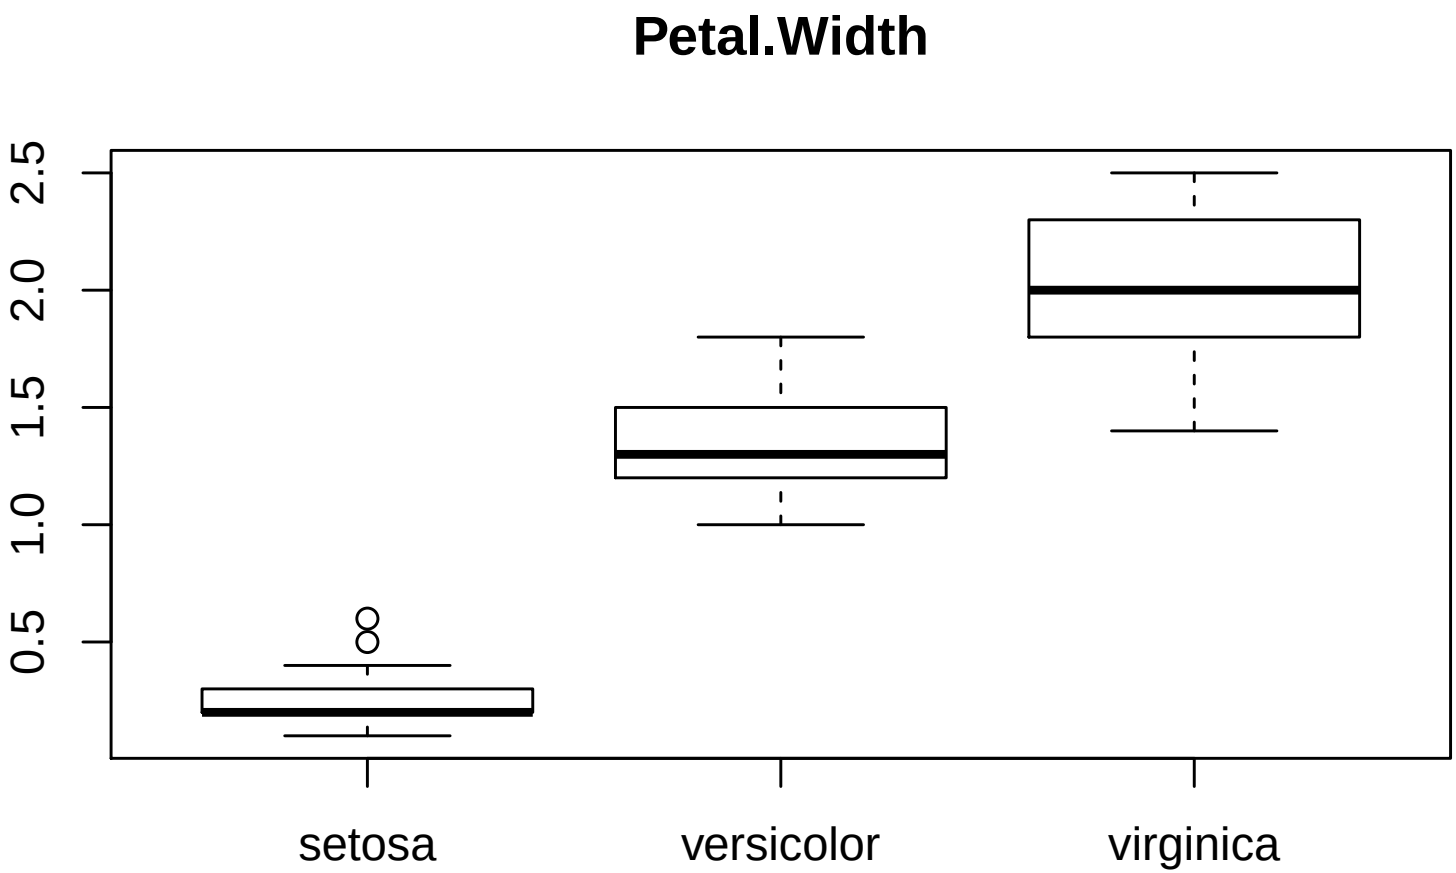

Boxplot (gekerbt)

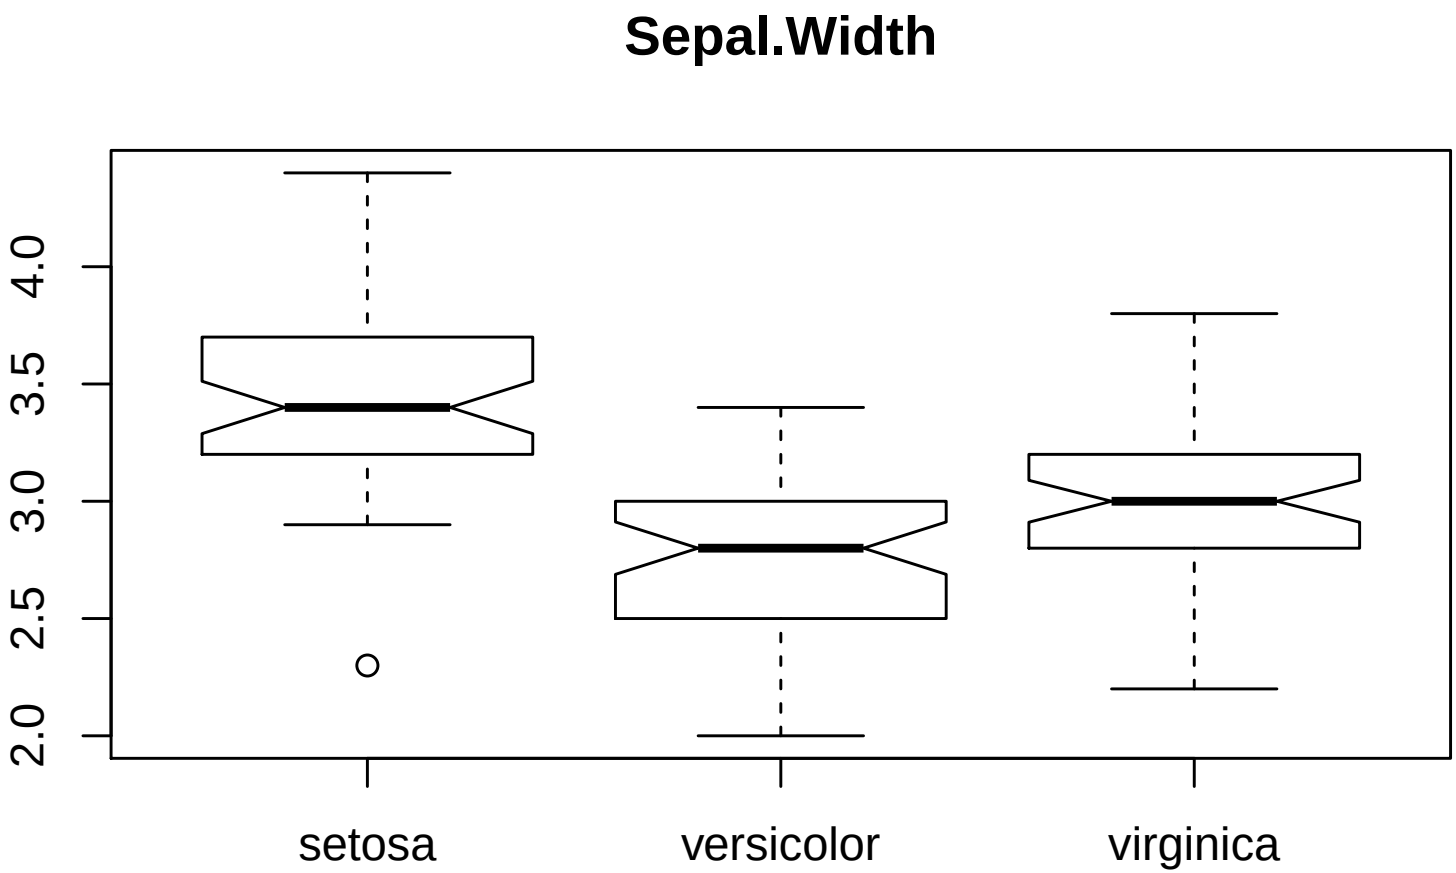

Interpretation

- Sind die Mediane gleich so überlagern sich die Kerben mit einer Wahrscheinlichkeit von 95%.
- Überlagern sich die Kerben nicht, so ist das ein Hinweis auf verschiedene Mediane.

Einteilung der Graphiken

		Erste Variable	
		diskret	stetig
	keine	x	x
zweite Variable	diskret	x	x
	stetig	s.o.	x

- *stetige Daten
- *diskrete Daten
- *stetig–stetig
- *diskret–diskret
- *diskret–stetig

Symbolik

- Kategorien $\sim$ Farben, Formen, Position
- Reelle Zahlen $\sim$ Position
- Positive Zahlen $\sim$ Position, Fläche, log Positionen
- Anzahlen, Wahrscheinlichkeiten $\sim$ Flächen, Höhen
- Dichten $\sim$ Höhe

Zweck der Graphik

- Wie sind die Daten?
- Gibt es Ausreißer und Verteilungsbesonderheiten?
- Welche Zusammenhänge kann man erkennen/vermuten?
- Können wir unsere Vermutungen graphisch bestätigen?
- Wie geht es weiter?

Fragen an die Graphiken

- Ist etwas ungewöhnlich? Warum?
- Wie sind die Daten verteilt?
- Gibt es Ausreißer oder Bindungen?
- Wird der optische Eindruck durch Besonderheiten verfälscht (z.B. Bindungen, zu kleine Balken, Überlagerung)
- Welche Abhängigkeiten sind erkennbar?
- Sind die Abhängigkeiten stark oder schwach, linear oder nichtlinear, zunehmen oder abnehmend?
- Entsprechend die Beobachtungen dem, was man inhaltlich erwarten würde?
- Was fällt sonst auf?

Masszahlen

Masszahlen werden verwendet um bestimmte Aspekte der Verteilung zusammenfassend darzustellen.

- Lage
- Streuung
- Form
- Zusammenhang
- Anteil
- fehlt noch: diskret-diskret, diskret-stetig (später R^2)