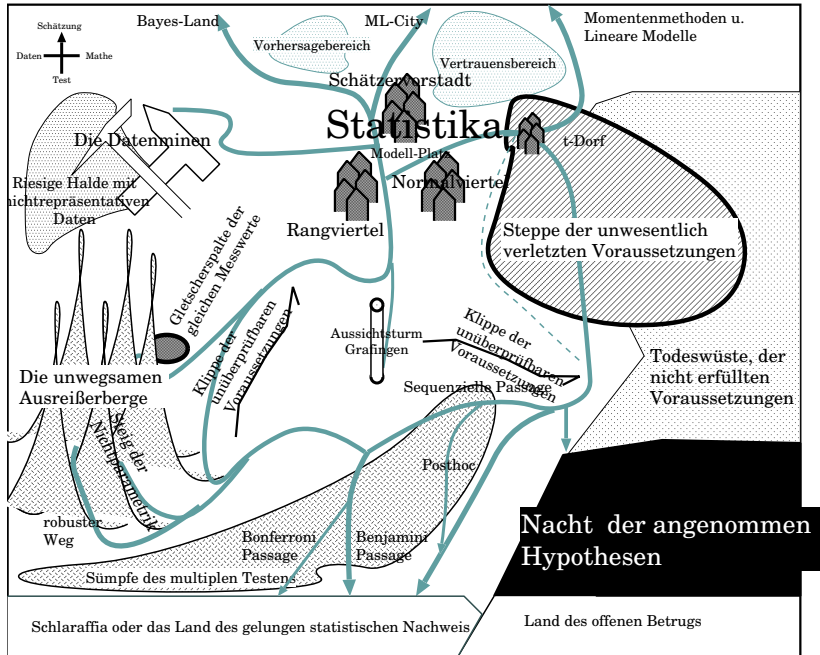


Statistik

Vorlesung 2 (Graphiken für stetige Daten)

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

29. Oktober 2019



Einteilung der Graphiken und Parameter

		Erste Variable	
		diskret	stetig
zweite Variable	keine	?	?
	diskret	?	?
	stetig	?	?

- ▶ stetige Daten
- ▶ diskrete Daten
- ▶ stetig–stetig
- ▶ diskret–diskret
- ▶ diskret–stetig

Lernziele

Zu jeder Graphik lernen wir:

- ▶ Für welche Daten eignet sich die Graphik?

Warum lernen wir das?

Lernziele

Zu jeder Graphik lernen wir:

- ▶ Für welche Daten eignet sich die Graphik?
- ▶ Wie ist die Graphik aufgebaut?

Warum lernen wir das?

Lernziele

Zu jeder Graphik lernen wir:

- ▶ Für welche Daten eignet sich die Graphik?
- ▶ Wie ist die Graphik aufgebaut?
- ▶ Was kann man in der Graphik sehen?

Warum lernen wir das?

Lernziele

Zu jeder Graphik lernen wir:

- ▶ Für welche Daten eignet sich die Graphik?
- ▶ Wie ist die Graphik aufgebaut?
- ▶ Was kann man in der Graphik sehen?
- ▶ Woran kann man es erkennen?

Warum lernen wir das?

Lernziele

Zu jeder Graphik lernen wir:

- ▶ Für welche Daten eignet sich die Graphik?
- ▶ Wie ist die Graphik aufgebaut?
- ▶ Was kann man in der Graphik sehen?
- ▶ Woran kann man es erkennen?
- ▶ Was übersieht man in der Graphik?

Warum lernen wir das?

Lernziele


Zu jeder Graphik lernen wir:

- ▶ Für welche Daten eignet sich die Graphik?
- ▶ Wie ist die Graphik aufgebaut?
- ▶ Was kann man in der Graphik sehen?
- ▶ Woran kann man es erkennen?
- ▶ Was übersieht man in der Graphik?
- ▶ Für welche Fragestellungen eignet sich die Graphik?

Warum lernen wir das?

Vorbereitung: Darstellung des Wertes durch die Lage

Streudiagramm




Graphiken für stetige Daten

- ▶ Punktdiagramm (stapeln, verzittern)
- ▶ Histogramm
- ▶ Kastendiagramm / Boxplot
- ▶ Q Q-Plots (Quantils-Quantils Plot)
- ▶ (Empirische Verteilungsfunktion)


		Erste Variable	
		diskret	stetig
zweite Variable	keine		X
	diskret		
	stetig		

Punktdiagramm


Punktdiagramm



gestapeltes Punktdiagramm




verzerrtes Punktdiagramm




Punktdiagramm

- ▶ Vollständig bis auf Überdeckung
- ▶ Verzittern und Stapeln
- ▶ Was “sieht” man?

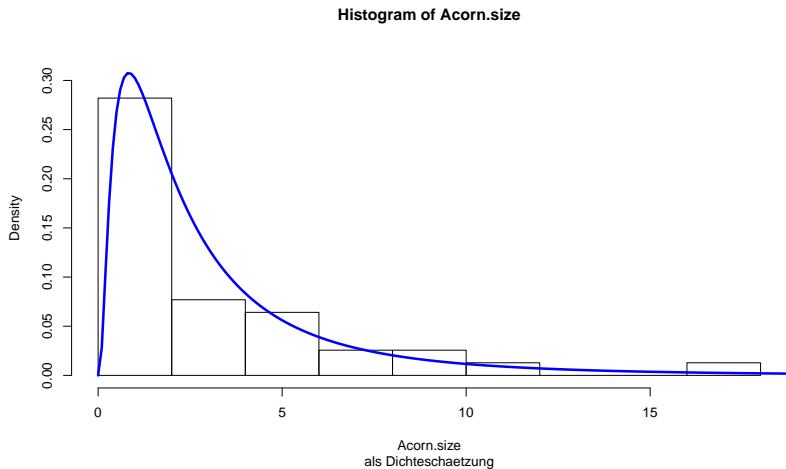
Histogramm



Histogramm




Histogramm und Wahrscheinlichkeitsdichtefunktion



Wahrscheinlichkeitsdichtefunktion $f(x)$

Histogram of Acorn.size




$$P([a, b]) = \int_a^b f(x)dx = \text{Fläche unter der Kurve}$$

Histogramm


- ▶ Stellt Anzahl von Datenpunkten im Intervall dar.
- ▶ Stellt die Dichte (Datenpunkte pro Punkt und Einheitslänge) der Punkte dar.
- ▶ Balkenhöhe ist zufällig.
- ▶ Variation von Balkenanfang und Balkenanzahl führt zu verschiedenen Eindrücken.
- ▶ Zu kleine Balken \Rightarrow "Zufallsflimmer"
- ▶ Zu große Balken \Rightarrow Information zu sehr zusammengefaßt.
- ▶ Extreme Ausreißer eventuell am linken oder rechten Rand erkennbar.

Einfluß des Balkenanfangs


Histogram of Acorn.size




Histogram of Acorn.size




Histogram of Acorn.size




Histogram of Acorn.size



Histogram of Acorn.size












Histogram of Acorn.size




Beschreibung der Verteilungsform und Normalverteilung als Referenzverteilung









Normalverteilung



Dichte der Normalverteilung



Verteilungseigenschaften



Kenngößen und Parameter

- ▶ Lage

Kenngößen und Parameter sind konventionelle Zusammenfassungen der Daten in einzelne Zahlen, die jeweils einen bestimmten Aspekt quantitativ erfassen.

Kenngößen und Parameter

- ▶ Lage
- ▶ Streuung

Kenngößen und Parameter sind konventionelle Zusammenfassungen der Daten in einzelne Zahlen, die jeweils einen bestimmten Aspekt quantitativ erfassen.

Kenngößen und Parameter

- ▶ Lage
- ▶ Streuung
- ▶ Form

Kenngößen und Parameter sind konventionelle Zusammenfassungen der Daten in einzelne Zahlen, die jeweils einen bestimmten Aspekt quantitativ erfassen.

Kenngrößen und Parameter

- ▶ Lage
- ▶ Streuung
- ▶ Form
- ▶ Verteilung

Kenngrößen und Parameter sind konventionelle Zusammenfassungen der Daten in einzelne Zahlen, die jeweils einen bestimmten Aspekt quantitativ erfassen.

Lageparameter

- ▶ Lage
 - ▶ Mittelwert (geometrisch und arithmetisch)
 - ▶ Median
 - ▶ Modus
 - ▶ Quantile (Quartile, Dezentile)
- ▶ Streuung
- ▶ Form
- ▶ Verteilung

(arithmetischer) Mittelwert


$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} (x_1 + x_2 + \dots + x_n)$$

```
> mean(iris$Sepal.Length)
```


```
[1] 5.843333
```

Mittelwert


Histogram of Sepal.Length




Histogram of Sepal.Width



Histogram of Petal.Length



Histogram of Petal.Width



(geometrischer) Mittelwert

Für die ratio-Skala gibt es noch den geometrischen Mittelwert

$$\bar{x} = \sqrt[n]{\prod_{i=1}^n x_i} = (x_1 x_2 \cdots x_n)^{\frac{1}{n}}$$

```
> exp(mean(log(iris$Sepal.Length)))
```

```
[1] 5.78572
```


Median

Der Median ist der mittlere Wert:

```
> median( c(4,5,1,3,6,7,8))
```

```
[1] 5
```

```
> median( c(4,1,3,6,7,8))
```

```
[1] 5
```

```
> median(iris$Sepal.Length)
```

```
[1] 5.8
```


```
> sapply(iris[,1:4],median)
```

Sepal.Length	Sepal.Width	Petal.Length	Petal.Width
5.80	3.00	4.35	1.30


Modus

Der Modus oder Modalwert bezeichnet den Bereich mit der größten Punktdichte.

Histogram of iris\$Sepal.Length




Histogram of iris\$Petal.Length



Quantile

Das (empirische) p-Quantil \hat{q}_p ist der Wert für den der Anteil p des sortierten Datensatzes kleiner ist.

Quantile



Spezielle Quantile

- ▶ $\frac{1}{2}$ -Quantil ist der Median
- ▶ $\frac{1}{4}$ -Quantil heißt auch **erstes Quartil**
- ▶ $\frac{3}{4}$ -Quantil heißt auch **drittes Quartil**
- ▶ $\frac{n}{10}$ -Quantil heißt auch **n-tes Dezantil**
- ▶ 0-Quantil heißt auch Minimum (sehr zufällig!!!)
- ▶ 1-Quantil heißt auch Maximum (sehr zufällig!!!)

Streuparameter

- ▶ Lage
- ▶ Streuung
 - ▶ Varianz
 - ▶ Standardabweichung
 - ▶ IQR
 - ▶ Variationkoeffizient
 - ▶ geometrische Standardabweichung
- ▶ Form
- ▶ Verteilung

Streuparameter für die reelle Skala

- Varianz

$$\widehat{var}(X) = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

Streuparameter für die reelle Skala

- Varianz

$$\widehat{var}(X) = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

- Standardabweichung

$$\widehat{sd}(X) = \sqrt{\widehat{var}(X)}$$

Streuparameter für die reelle Skala

- ▶ Varianz

$$\widehat{var}(X) = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$


- ▶ Standardabweichung

$$\widehat{sd}(X) = \sqrt{\widehat{var}(X)}$$


- ▶ Interquartilsabstand

$$\widehat{IQR}(X) = q_{0.75} - q_{0.25}$$


classical
mean= 5.84 sd= 0.83




classical
mean= 3.76 sd= 1.77



robust:
mean= 5.83 sd= 0.81



robust:
mean= 4.85 sd= 0.92



Streuparameter für die ratio Skala

- Variationskoeffizient

$$\hat{v}(X) = \frac{\hat{sd}(X)}{\bar{x}}$$

Streuparameter für die ratio Skala

- ▶ Variationskoeffizient

$$\hat{v}(X) = \frac{\hat{sd}(X)}{\bar{x}}$$

- ▶ Standardabweichung des Logarithmus

$$\hat{sd}(\ln(X))$$

Streuparameter für die ratio Skala

- ▶ Variationskoeffizient

$$\hat{v}(X) = \frac{\hat{sd}(X)}{\bar{x}}$$





- ▶ Standardabweichung des Logarithmus

$$\hat{sd}(\ln(X))$$

- ▶ Geometrische Standardabweichung

$$\exp(\hat{sd}(\ln(X)))$$

Blick mit der Ratioskala



Weitere Parameter

- ▶ Lage
- ▶ Streuung
- ▶ Form

- ▶ Schiefe $\widehat{skewness}(X) = \sum_{i=1}^n \frac{(X - \bar{X})^3}{\widehat{sd}(X)^3}$

- ▶ Wölbung $\widehat{kurtosis}(X) = \sum_{i=1}^n \frac{(X - \bar{X})^4}{\widehat{sd}(X)^4}$

- ▶ ...

- ▶ Verteilung

- ▶ Hängt vom Verteilungsmodell ab.

- e.g. Ausfallrate λ bei Exponentialverteilung, Untergrenze x_{\min} und Exponent k bei der Paretoverteilung

Empirische und theoretische Größen

- ▶ empirisch: Ermittelt für die Stichprobe

$$\bar{X}, \widehat{var}(X), \widehat{sd}(X), \dots$$

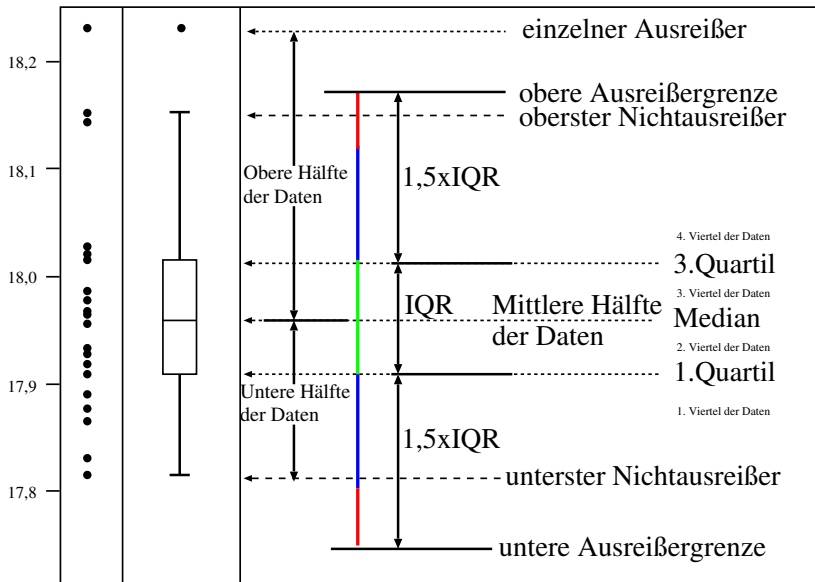
- ▶ theoretisch (wahr): Ermittelt für Grundgesamtheit / wahre Verteilung

$$E[X], var(X), sd(X), \dots$$

Kastendiagramm/Boxplot


Dotplot Boxplot

Erklärung zum Boxplot



Kastendiagramme / Boxplot

Boxplots der reellen Variablen des Iris Datensatzes



Interpretation

- ▶ **Ausreißer**
- ▶ **Stichprobenlage / Median**
- ▶ **Stichprobenstreuung / IQR**
- ▶ **Symmetrie und Schiefe der Verteilung**
- ▶ **eventuell extreme Werthäufungen**

Exkurs: Ausreißer

Definition: Ein Ausreißer ist ein Datenpunkt der einen “ungewöhnlich” extremen Wert hat.

Mögliche Ursachen:

- ▶ Zufall (Es gibt halt extreme Werte)

Exkurs: Ausreißer

Definition: Ein Ausreißer ist ein Datenpunkt der einen “ungewöhnlich” extremen Wert hat.

Mögliche Ursachen:

- ▶ Zufall (Es gibt halt extreme Werte)
- ▶ Schwere Verteilungsschwänze (Ausreißer hier typisch)

Exkurs: Ausreißer

Definition: Ein Ausreißer ist ein Datenpunkt der einen “ungewöhnlich” extremen Wert hat.

Mögliche Ursachen:

- ▶ Zufall (Es gibt halt extreme Werte)
- ▶ Schwere Verteilungsschwänze (Ausreißer hier typisch)
- ▶ Datenfehler oder Übermittlungsfehler

Exkurs: Ausreißer

Definition: Ein Ausreißer ist ein Datenpunkt der einen “ungewöhnlich” extremen Wert hat.

Mögliche Ursachen:

- ▶ Zufall (Es gibt halt extreme Werte)
- ▶ Schwere Verteilungsschwänze (Ausreißer hier typisch)
- ▶ Datenfehler oder Übermittlungsfehler
- ▶ Untypischer Spezialfall (der Millionär mit Zweitwohnsitz im armen Bergbauerndorf)

Exkurs: Ausreißer

Definition: Ein Ausreißer ist ein Datenpunkt der einen “ungewöhnlich” extremen Wert hat.

Mögliche Ursachen:

- ▶ Zufall (Es gibt halt extreme Werte)
- ▶ Schwere Verteilungsschwänze (Ausreißer hier typisch)
- ▶ Datenfehler oder Übermittlungsfehler
- ▶ Untypischer Spezialfall (der Millionär mit Zweitwohnsitz im armen Bergbauerndorf)
- ▶ Individuum fehlerhafterweise in der Stichprobe (z.B. andere Art)





Exkurs: Ausreißer

Definition: Ein Ausreißer ist ein Datenpunkt der einen “ungewöhnlich” extremen Wert hat.

Mögliche Ursachen:

- ▶ Zufall (Es gibt halt extreme Werte)
- ▶ Schwere Verteilungsschwänze (Ausreißer hier typisch)
- ▶ Datenfehler oder Übermittlungsfehler
- ▶ Untypischer Spezialfall (der Millionär mit Zweitwohnsitz im armen Bergbauerndorf)
- ▶ Individuum fehlerhafterweise in der Stichprobe (z.B. andere Art)
- ▶ Anthropogene Überprägung (das verlorene Geldstück mit hohem Kupfergehalt.)

QQ-Plots / Quantile – Quantile – Plot



Interpretation Q Q-Plot

- ▶ Ungefähre Gerade \Leftrightarrow Verteilungsmodell passend
- ▶ “Treppenstufen” \Leftrightarrow Bindungen (gleiche Werte)
- ▶ “Gegen S” \Leftrightarrow Ausreißer? schwere Verteilungsschwänze?

Exkurs: Bindungen

Definition: Von einer **Bindung** spricht man, wenn ein Datenwert in einer stetigen Variable zwei oder mehrfach auftritt.

Mögliche Ursachen:


- ▶ Rundung
- ▶ Ungenau Datenerhebung
- ▶ Spezieller Wert hat positive Wahrscheinlichkeit
- ▶ Variable nicht wirklich stetig

Manche statistische Verfahren verlieren an zunehmend an Genauigkeit je mehr Bindungen auftreten.


Empirische Verteilungsfunktion

$$\hat{F}(x) = \text{Anteil des Datensatzes } \leq x$$


Sepal.Length




Sepal.Width



Petal.Length



Petal.Width




Emprische Verteilungsfunktion


- ▶ Quantile können leicht abgelesen werden.
- ▶ Wahrscheinlichkeiten können leicht abgelesen werden.
- ▶ Bindungen erzeugen hohe Sprünge (fast unsichtbar).
- ▶ Sonst kann eigentlich nichts abgelesen werden.

Log-Transformation bei Ratioskala I


verzerrtes Punktdiagramm




Histogram



verzerrtes Punktdiagramm




Histogram




Log-Transformation bei Ratioskala II


Acorn Size




log10(Acorn Size)



Acorn Size



ecdf(Acorn.size)



Log-Transformation bei Ratioskala III

- ▶ Tip: Bei ratio-Daten lohnt es sich oft auch den Logarithmus der Daten als Daten anzusehen.
- ▶ Ratioskalierte Daten haben nur positive Werte
- ▶ Eine logarithmische Darstellung
 - ▶ zeigt den richtigen Abstandsbegriff (Verhältnisse werden zu Abständen)
 - ▶ zeigen oft eine größere Annäherung an die Normalverteilung (z.B. keine Ausreißer)
- ▶ Punktdiagramm, empirische Verteilungsfunktion:
 - ▶ Man kann einfach die x-Achse logarithmisch einteilen
- ▶ Histogramm, Boxplot:
 - ▶ Darstellung mit log-Daten wird prinzipiell anders

Logit-Transformation bei Anteilskala

Bei Anteilskalierten Daten lohnt sich oft die logit Transformation

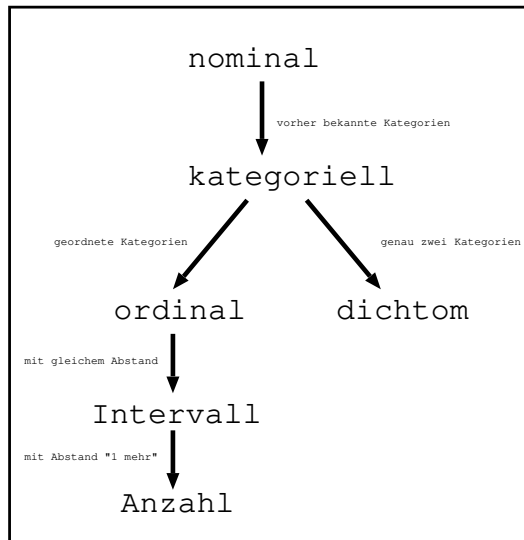
$$\text{logit}(x) = \log\left(\frac{x}{1-x}\right)$$

```
> logit <- function(x) log(x/(1-x))
```


Für kleine Anteile kann diese durch die log-Transformation approximiert werden.

Das feinste Skalenniveau

diskret



stetig



Zusammenfassung zu stetigen Daten

- ▶ **Lage- und Streuparameter** / quantitativ
- ▶ **Punktdiagramm** (stapeln, verzittern) / Daten
- ▶ **Histogramm** (Balken variieren) / Verteilungsform
- ▶ **Kastendiagramm** / Ausreißer, Streuung, Lage, Symmetrie
- ▶ **Q Q-Plot** / Vergleich mit Verteilung
- ▶ **Empirische Verteilungsfunktion** / Quantile
- ▶ **log-Skala für ratio Daten** / wie modifiziert man die Graphiken
- ▶ **logit-Skala für Anteil Daten** / wie modifiziert man die Graphiken