

# Wahrscheinlichkeitsrechnung und Statistik für Studierende der Biologie **Einführung: Deskriptive Statistik**

Noémie Becker & Dirk Metzler

9. April 2014

## Inhaltsverzeichnis

<b>1 Einführung</b>	<b>1</b>
1.1 Konzept und Quellen . . . . .	1
1.2 Plan . . . . .	2
<b>2 Ziele der deskriptiven (d.h. beschreibenden) Statistik</b>	<b>3</b>
<b>3 Graphische Darstellungen</b>	<b>3</b>
3.1 Histogramme und Dichtepolygone . . . . .	5
3.2 Stripcharts . . . . .	10
3.3 Boxplots . . . . .	10
3.4 Beispiel: Ringeltaube . . . . .	12
3.5 Beispiel: Darwin-Finken . . . . .	14
<b>4 Statistische Kenngrößen</b>	<b>17</b>
4.1 Median und andere Quartile . . . . .	18
4.2 Mittelwert und Standardabweichung . . . . .	19
<b>5 Vom Sinn und Unsinn von Mittelwerten</b>	<b>27</b>
5.1 Beispiel: Wählerische Bachstelzen . . . . .	27
5.2 Beispiel: Spiderman & Spiderwoman . . . . .	28
5.3 Beispiel: Kupfertoleranz beim Roten Straußgras . . . . .	29

## 1 Einführung

### 1.1 Konzept und Quellen

*It is easy to lie with statistics. It is hard to tell the truth without it.*

Andrejs Dunkels

Die Natur ist voller Variabilität.

Wie geht man mit variablen Daten um?

Es gibt eine mathematische Theorie des Zufalls: die **Stochastik**.

IDEE DER STATISTIK:

Variabilität (Erscheinung der Natur) durch Zufall (mathematische Abstraktion) modellieren.

Also: Statistik ist Datenanalyse mit Hilfe stochastischer Modelle.

## Quellen

Wir danken Matthias Birkner und Martin Hutzenthaler für die intensive Zusammenarbeit beim Erstellen früherer Version dieser Vorlesung sowie Brooks Ferebee, Gaby Schneider und Anton Wakolbinger für die Bereitstellung vieler Beispiele und Lehrmaterialien.

<http://joguinf.informatik.uni-mainz.de/~birkner/>

<http://www.math.uni-frankfurt.de/~wakolbin/statbio/>

<http://ismi.math.uni-frankfurt.de/schneider/statbio0708.html>

## 1.2 Plan

### Plan der Vorlesung

#### Klassische Statistik

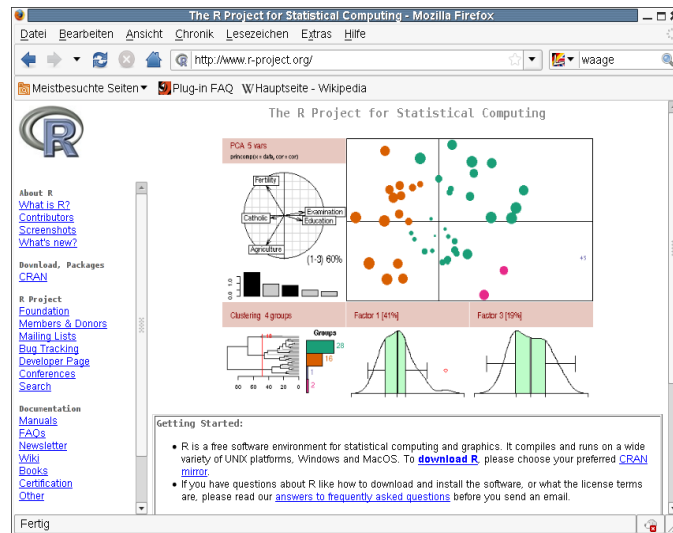
1. Beschreibende Statistik
2. Der Standardfehler
3. Der t-Test für gepaarte Stichproben
4. Der t-Test für unabhängige Stichproben
5. Häufigkeiten
6. Der Chi-Quadrat Test
7. Lineare Regression
8. Korrelation
9. Varianzanalyse (ANOVA)

### Plan der Vorlesung

#### Weitere Themen

- Nichtparametrische Tests
- Diskriminanzanalyse
- Grundbegriffe der Wahrscheinlichkeitstheorie
- Parameterschätzung
- Moderne Anwendung: Analyse von Genexpressionsdaten (vielleicht)
- R

## Statistik-Software R



<http://www.r-project.org>

Folien, R-Befehle, Quellen und Übungen

<http://evol.bio.lmu.de/statgen/StatBiol/12SS>

## 2 Ziele der deskriptiven (d.h. beschreibenden) Statistik

Beschreibende Statistik

Beschreibende Statistik: Ein erster Blick auf die Daten

## 3 Graphische Darstellungen

Beispiel

Daten aus einer Diplomarbeit aus 2001 am Forschungsinstitut Senckenberg,  
Frankfurt am Main

Crustaceensektion

*Leitung: Dr. Michael Türkay*

*Charybdis acutidens TÜRKAY 1985*

Der Springkrebs  
*Galathea intermedia*




Helgoländer Tiefe Rinne, Fang vom 6.9.1988

Carapaxlänge (mm): Nichteiertragende Weibchen ( $n = 215$ )

2,9	3,0	2,9	2,5	2,7	2,9	2,9	3,0
3,0	2,9	3,4	2,8	2,9	2,8	2,8	2,4
2,8	2,5	2,7	3,0	2,9	3,2	3,1	3,0
2,7	2,5	3,0	2,8	2,8	2,8	2,7	3,0
2,6	3,0	2,9	2,8	2,9	2,9	2,3	2,7
2,6	2,7	2,5	.	.	.	.	.

Nichteiertragende Weibchen am 6. Sept. '88, n=215




### 3.1 Histogramme und Dichtepolygone

Eine Möglichkeit der graphischen Darstellung:


das Histogramm

**Nichteiertragende Weibchen am 6. Sept. '88, n=215**




Analoge Daten zwei Monate später (3.11.88):

**Nichteiertragende Weibchen am 3. Nov. '88, n=57**



### Nichteiertragende Weibchen




Vergleich der beiden Verteilungen

Problem: ungleiche Stichprobenumfänge: 6.Sept:  $n = 215$   
 3.Nov :  $n = 57$


Idee: stauche vertikale Achse so, dass Gesamtfläche = 1.

Nichteiertragende Weibchen am 6. Sept. '88,  $n=215$






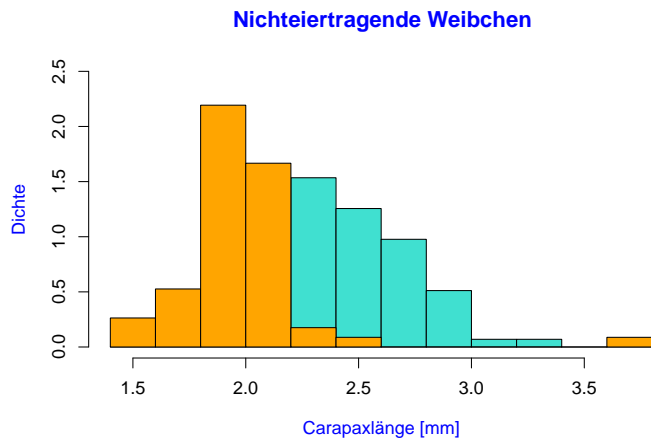
Die neue vertikale Koordinate ist jetzt eine Dichte (engl. *density*).

Nichteiertragende Weibchen am 6. Sept. '88,  $n=215$



Die beiden Histogramme sind jetzt vergleichbar, denn sie haben dieselbe Gesamtfläche:

Versuche, die Histogramme zusammen zu zeigen:



**Unser Rat an Sie:**

Wenn Sie Schauwerbegestalter(in) sind:

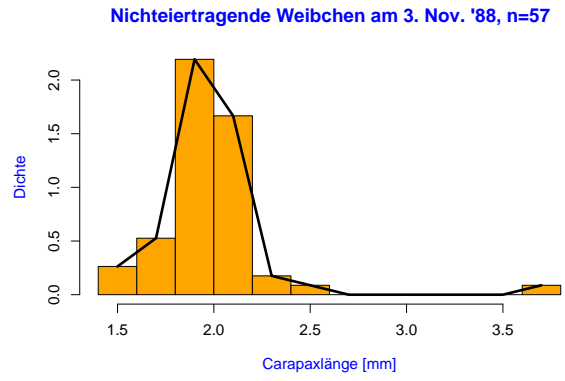

Beeindrucken Sie Jung und Alt mit total abgefahrenen 3D-Plots!

Wenn Sie Wissenschaftler(in) werden wollen:


**Bevorzugen Sie einfache und klare 2D-Darstellungen.**

Problem: Histogramme kann man nicht ohne weiteres in demselben Graphen darstellen, weil sie einander überdecken würden.

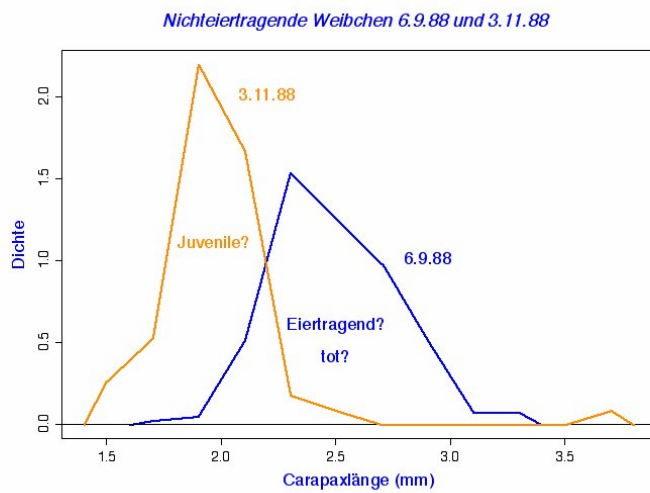
**Einfache und klare Lösung: Dichtepolygone**



**Zwei und mehr Dichtepolygone in einem Plot**






Biologische Interpretation der Verschiebung?



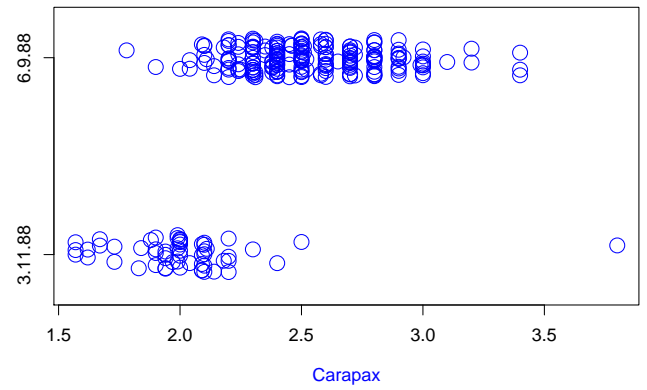

Anzahl vs. Dichte






Also: Bei Histogrammen mit ungleichmäßiger Unterteilung immer Dichten verwenden!


### 3.2 Stripcharts



Boxplots, horizontal



Boxplots, vertikal



Histogramme und Dichtepolygone geben ein ausführliches Bild eines Datensatzes. Manchmal zu ausführlich.


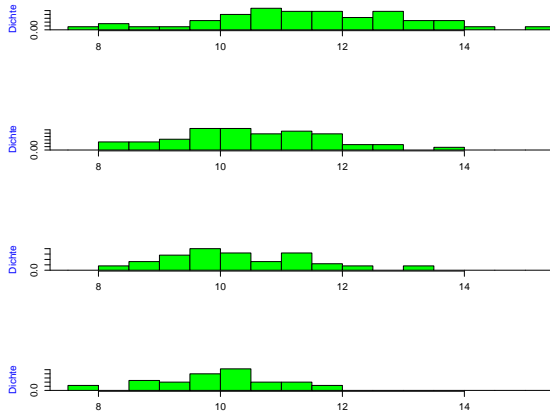
### 3.3 Boxplots

Zu viel Information erschwert den Überblick

Baum Baum Baum Baum Baum Baum Baum Baum Baum Baum Baum Baum Baum Baum

Wald?

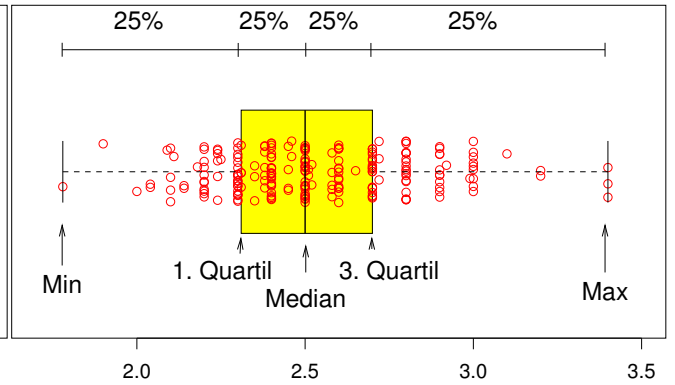

Beispiel:  
Vergleich von mehreren Gruppen



Der Boxplot

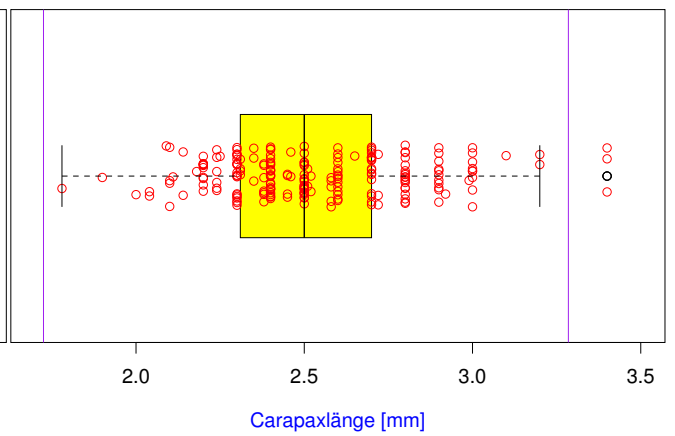

Boxplot, einfache Ausführung

Boxplot, einfache Ausführung

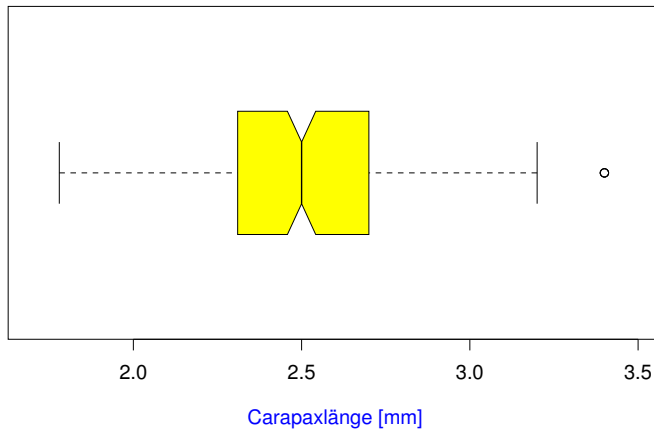


Carapaxlänge [mm]  
Boxplot, Standardausführung

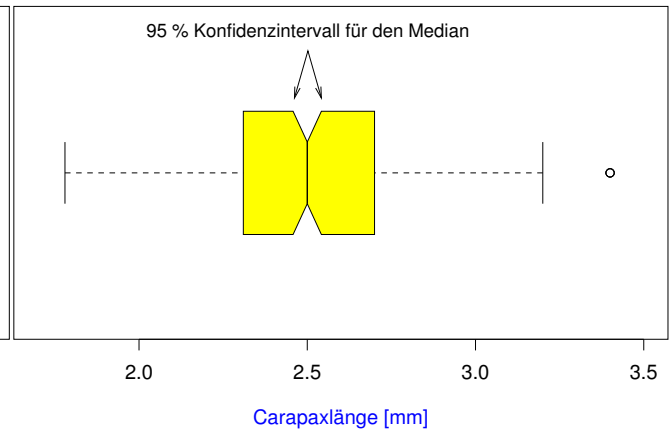
Carapaxlänge [mm]  
Boxplot, Standardausführung



Boxplot, Profiausstattung



Boxplot, Profiausstattung



### 3.4 Beispiel: Ringeltaube

Beispiel:

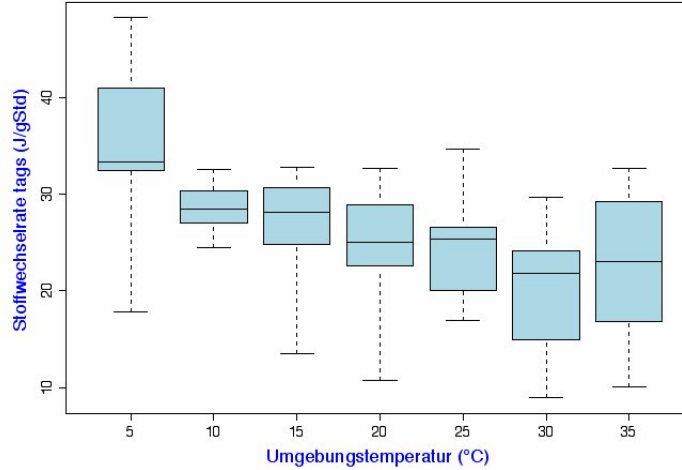
Die Ringeltaube

*Palumbus palumbus*

Wie hängt die Stoffwechselrate bei der Ringeltaube von der Umgebungstemperatur ab?

Daten aus dem AK Stoffwechselphysiologie  
Prof. Prinzing Universität Frankfurt

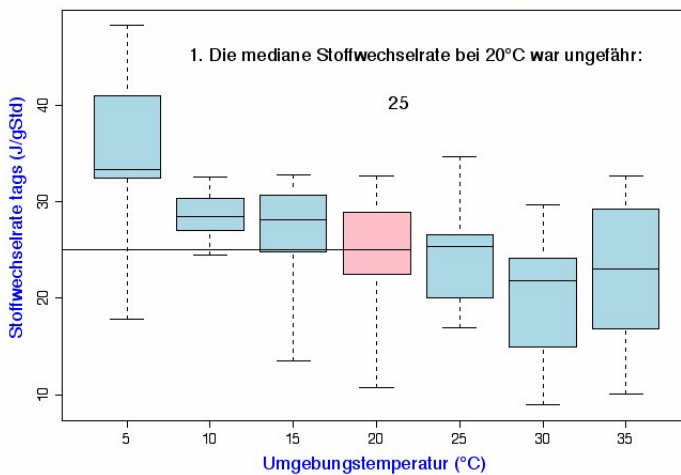
Stoffwechselrate und Umgebungstemperatur bei Ringeltauben (n=90)




Klar: Stoffwechselrate *höher* bei *tiefen* Temperaturen

Vermutung: Bei *hohen* Temperaturen nimmt die Stoffwechselrate wieder zu (Hitze**st**ress).


Stoffwechselrate und Umgebungstemperatur bei Ringeltauben (n=90)



Stoffwechselrate und Umgebungstemperatur bei Ringeltauben (n=90)



Stoffwechselrate und Umgebungstemperatur bei Ringeltauben (n=90)




### 3.5 Beispiel: Darwin-Finken

Charles Robert Darwin (1809-1882)



## Darwin-Finken



[http://darwin-online.org.uk/graphics/Zoology\\_Illustrations.html](http://darwin-online.org.uk/graphics/Zoology_Illustrations.html)

## Darwins Finken-Sammlung



## Literatur

[1] Sulloway, F.J. (1982) The Beagle collections of Darwin's Finches (Geospizinae). *Bulletin of the British Museum (Natural History), Zoology series* **43**: 49-94.


[2] <http://datadryad.org/repo/handle/10255/dryad.154>

## Flügelängen der Darwin-Finken


Flügelängen je nach Insel




Flügelängen je nach Insel




Barplot für Flügelängen (Anzahlen)




Histogramm (Dichten!) mit Transparenz



Dichteplot







### Fazit

1. Histogramme erlauben einen detaillierten Blick auf die Daten
2. Dichtepolygone erlauben Vergleiche zwischen vielen Verteilungen
3. Boxplot können große Datenmengen vereinfacht zusammenfassen
4. Bei kleinen Datenmengen eher Stripcharts verwenden
5. Vorsicht mit Tricks wie 3D oder halbtransparenten Farben
6. Jeder Datensatz ist anders; keine Patentrezepte

## 4 Statistische Kenngrößen

Es ist oft möglich, das Wesentliche an einer Stichprobe mit ein paar Zahlen zusammenzufassen.

Wesentlich:

1. Wie groß?

*Lageparameter*

## 2. Wie variabel?

### *Streuungsparameter*

Eine Möglichkeit kennen wir schon aus dem Boxplot:

#### Lageparameter

*Der Median*

#### Streuungsparameter

*Der Quartilabstand ( $Q_3 - Q_1$ )*

### 4.1 Median und andere Quartile

*Der Median:*

die Hälfte der Beobachtungen sind kleiner,  
die Hälfte sind größer.

Der Median ist  
das 50%-*Quantil*  
der Daten.

#### Die Quartile

*Das erste Quartil,  $Q_1$ :* ein Viertel der Beobachtungen sind kleiner, drei  
Viertel sind größer.

$Q_1$  ist das 25%-*Quantil* der Daten.

#### Die Quartile

*Das dritte Quartil,  $Q_3$ :* drei Viertel der Beobachtungen sind kleiner, ein  
Viertel sind größer.

$Q_3$  ist das 75%-*Quantil* der Daten.

## 4.2 Mittelwert und Standardabweichung

Am häufigsten werden benutzt:

Lageparameter

*Der Mittelwert  $\bar{x}$*

Streuungsparameter

*Die Standardabweichung  $s$*

Der Mittelwert

*(engl. mean)*

**NOTATION:**

Wenn die Beobachtungen  $x_1, x_2, x_3, \dots, x_n$  heißen,  
schreibt man oft  $\bar{x}$  für den Mittelwert.

**DEFINITION:**

Mittelwert[lex] = [lex]

Summe der Messwerte

-----  
Anzahl der Messwerte

Summe

-----  
Anzahl

Der Mittelwert von  $x_1, x_2, \dots, x_n$  als Formel:

$$\bar{x} = (x_1 + x_2 + \dots + x_n)/n$$

$$= \frac{1}{n} \sum_{i=1}^n x_i$$

Beispiel:

$$x_1 = 3, x_2 = 0, x_3 = 2, x_4 = 3, x_5 = 1$$

$$\bar{x} = \text{Summe/Anzahl}$$

$$\bar{x} = (3 + 0 + 2 + 3 + 1)/5$$

$$\bar{x} = 9/5$$


$$\bar{x} = 1,8$$

Geometrische Bedeutung des Mittelwerts:

Der Schwerpunkt

Wir stellen uns die Beobachtungen als gleich schwere Gewichte auf einer Waage vor:


Wo muß der Drehpunkt sein, damit die Waage im Gleichgewicht ist?







$$m = 1,5 ?$$

$$m = 2 ?$$

$$m = 1,8 ?$$





zu klein

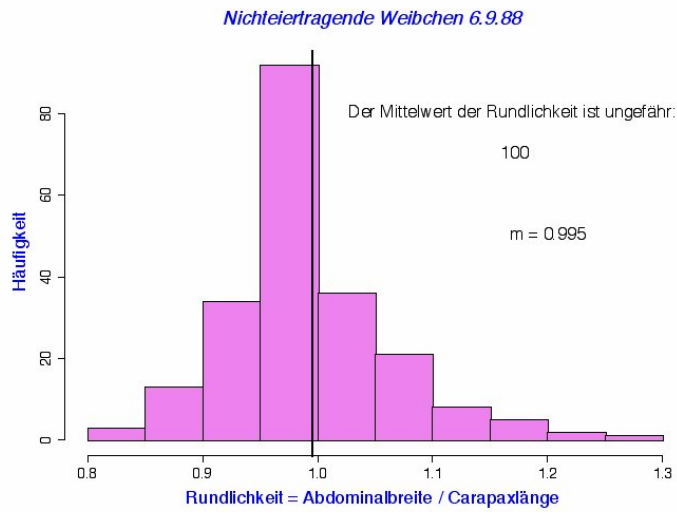
zu groß

richtig

Beispiel: *Galathea intermedia*

„Rundlichkeit“ :=  $\text{Abdominalbreite} / \text{Carapaxlänge}$

Vermutung: Rundlichkeit nimmt bei Geschlechtsreife zu




Beispiel:

3.11.88

Die Standardabweichung

Wie weit weicht eine typische Beobachtung vom Mittelwert ab ?



Die *Standardabweichung*  $\sigma$  (“sigma”) [auch *SD* von engl. *standard deviation*] ist ein etwas komisches gewichtetes Mittel der Abweichungsbeträge und zwar

$$\sigma = \sqrt{\text{Summe}(\text{Abweichungen}^2)/n}$$


Die *Standardabweichung* von  $x_1, x_2, \dots, x_n$  als Formel:

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$$

$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$  heißt *Varianz*.


#### Faustregel für die Standardabweichung

Bei ungefähr glockenförmigen (also eingipfligen und symmetrischen) Verteilungen liegen ca. 2/3 der Ver-



teilung zwischen  $\bar{x} - \sigma$  und  $\bar{x} + \sigma$ .

#### Standardabweichung der Carapaxlängen nichteiertragender Weibchen vom 6.9.88



Hier liegt der Anteil zwischen  $\bar{x} - \sigma$  und  $\bar{x} + \sigma$  bei 72%.

### Varianz der Carapaxlängen nichteiertragender Weibchen vom 6.9.88

Alle Carapaxlängen im Meer:  $\mathcal{X} = (X_1, X_2, \dots, X_N)$ . Carapaxlängen in unserer Stichprobe:  $\mathcal{S} = (S_1, S_2, \dots, S_{n=215})$   
 Stichprobenvarianz:

$$\sigma_S^2 = \frac{1}{n} \sum_{i=1}^{215} (S_i - \bar{S})^2 \approx 0,0768$$

Können wir 0,0768 als Schätzwert für die Varianz  $\sigma_X^2$  in der ganzen Population verwenden? Ja, können wir machen. Allerdings ist  $\sigma_S^2$  im Durchschnitt um den Faktor  $\frac{n-1}{n}$  ( $= 214/215 \approx 0,995$ ) kleiner als  $\sigma_X^2$ .

### Varianzbegriffe

Varianz in der Population:  $\sigma_X^2 = \frac{1}{N} \sum_{i=1}^N (X_i - \bar{X})^2$

Stichprobenvarianz:  $\sigma_S^2 = \frac{1}{n} \sum_{i=1}^n (S_i - \bar{S})^2$

korrigierte Stichprobenvarianz:

$$\begin{aligned} s^2 &= \frac{n}{n-1} \sigma_S^2 \\ &= \frac{n}{n-1} \cdot \frac{1}{n} \cdot \sum_{i=1}^n (S_i - \bar{S})^2 \\ &= \frac{1}{n-1} \cdot \sum_{i=1}^n (S_i - \bar{S})^2 \end{aligned}$$




Mit "Standardabweichung von  $\mathcal{S}$ " ist meistens das korrigierte  $s$  gemeint.




Beispiel Die Daten  $\bar{x} = ?$   $\bar{x} = 10/5 = 2$   
*Summe*

$x$	1	3	0	5	1	10
$x - \bar{x}$	-1	1	-2	3	-1	0
$(x - \bar{x})^2$	1	1	4	9	1	16



$$\begin{aligned} s^2 &= \text{Summe}((x - \bar{x})^2) / (n - 1) \\ &= 16 / (5 - 1) = 4 \\ s &= 2 \end{aligned}$$







Die folgenden Histogramme zeigen die Standardabweichungen, die aus 1000 verschiedenen Stichproben aus der selben Verteilung geschätzt wurden. Die durchgezogenen Linien stellen die tatsächliche Standardabweichung der Verteilung dar, die gestrichelten Linien die Mittelwerte der geschätzten Standardabweichungen.



**$\sigma$  mit  $n$  oder  $n - 1$  berechnen?**

Die Standardabweichung  $\sigma$  eines Zufallsexperiments mit  $n$  gleichwahrscheinlichen Ausgängen  $x_1, \dots, x_n$  (z.B. Würfelwurf) ist klar definiert durch

$$\sqrt{\frac{1}{n} \sum_{i=1}^n (\bar{x} - x_i)^2}.$$

Wenn es sich bei  $x_1, \dots, x_n$  um eine Stichprobe handelt (wie meistens in der Statistik), sollten Sie die

Formel

$$\sqrt{\frac{1}{n-1} \sum_{i=1}^n (\bar{x} - x_i)^2}$$

verwenden.

## 5 Vom Sinn und Unsinn von Mittelwerten

Mittelwert und Standardabweichung...

- charakterisieren die Daten gut, falls deren Verteilung glockenförmig ist
- und müssen andernfalls mit Vorsicht interpretiert werden.

Wir betrachten dazu einige Lehrbuch-Beispiele aus der Ökologie, siehe z.B.

### Literatur

[BTH08] M. Begon, C. R. Townsend, and J. L. Harper. *Ecology: From Individuals to Ecosystems*. Blackell Publishing, 4 edition, 2008.

Im Folgenden verwenden wir zum Teil simulierte Daten, wenn die Originaldaten nicht verfügbar waren. Glauben Sie uns also nicht alle Datenpunkte.

### 5.1 Beispiel: Wählerische Bachstelzen

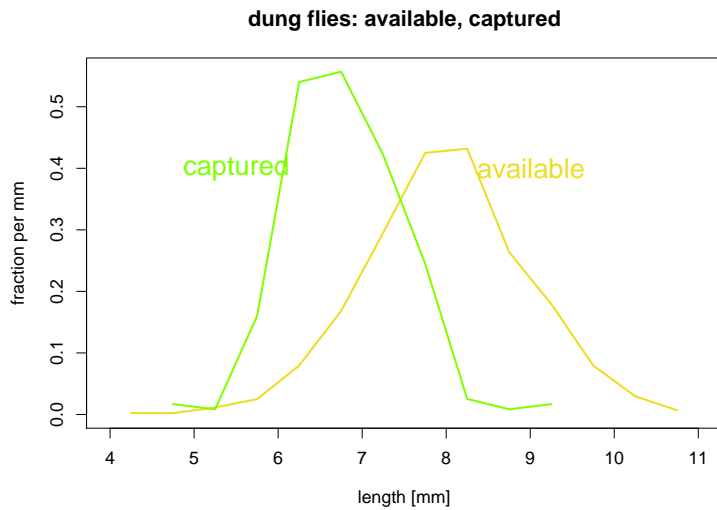
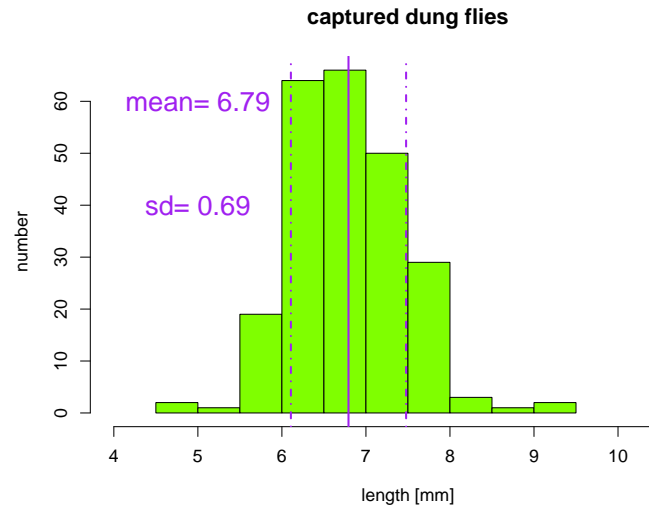

Bachstelzen fressen Dungfliegen

Vermutung

- Die Fliegen sind unterschiedlich groß
- Effizienz für die Bachstelze = Energiegewinn / Zeit zum Fangen und fressen
- Laborexperimente lassen vermuten, dass die Effizienz bei 7mm großen Fliegen maximal ist.

### Literatur

[Dav77] N.B. Davies. Prey selection and social behaviour in wagtails (Aves: Motacillidae). *J. Anim. Ecol.*, 46:37–57, 1977.



### Vergleich der Größenverteilungen

	captured		available
Mittelwert	6.29	<	7.99
Standardabweichung	0.69	<	0.96

### Interpretation

Die Bachstelzen bevorzugen Dungfliegen, die etwa 7mm groß sind.

Hier waren die Verteilungen glockenförmig und es genügten 4 Werte (die beiden Mittelwerte und die beiden Standardabweichungen), um die Daten adäquat zu beschreiben.




## 5.2 Beispiel: Spiderman & Spiderwoman

### Simulated Data:

Eine Stichprobe von 70 Spinnen

Mittlere Größe: 21,06 mm

Standardabweichung der Größe: 12,94 mm



### Fazit des Spinnenbeispiels

Wenn die Daten aus verschiedenen Gruppen zusammengesetzt sind, die sich bezüglich des Merkmals deutlich unterscheiden, kann es sinnvoll sein, Kenngrößen wie den Mittelwert für jede Gruppe einzeln zu berechnen.

### 5.3 Beispiel: Kupfertoleranz beim Roten Straußgras

## Literatur


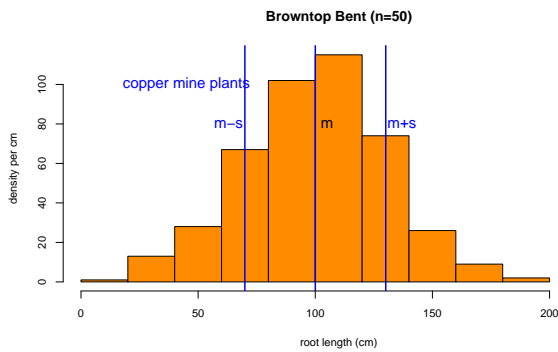
[Bra60] A.D. Bradshaw. Population Differentiation in *agrostis tenuis* Sibth. III. populations in varied environments. *New Phytologist*, 59(1):92 – 103, 1960.

[MB68] T. McNeilly and A.D Bradshaw. Evolutionary Processes in Populations of Copper Tolerant *Agrostis tenuis* Sibth. *Evolution*, 22:108–118, 1968.

Wir verwenden hier wieder simulierte Daten, da die Originaldaten nicht zur Verfügung stehen.

### Anpassung an Kupfer?

- Pflanzen, denen das Kupfer schadet, haben kürzere Wurzeln.
- Die Wurzellängen von Pflanzen aus der Umgebung von Kupferminen wird gemessen.
- Samen von unbelasteten Wiesen werden bei Kupferminen eingesät.
- Die Wurzellängen dieser “Wiesepflanzen” werden gemessen.

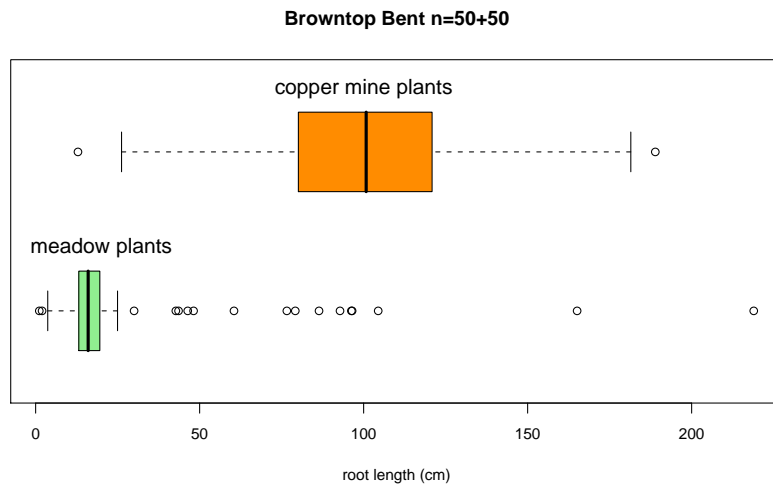


2/3 der Wurzellängen innerhalb  $[m-sd, m+sd]$ ???? **Nein!**

### Fazit des Straußgras-Beispiels

Manche Verteilungen können nur mit mehr als zwei Variablen angemessen beschrieben werden.

z.B. mit den fünf Werten der Boxplots:  
 min,  $Q_1$ , median,  $Q_3$ , max



### Schlussfolgerung

In der Biologie sind viele Datenverteilungen annähernd glockenförmig und können durch den **Mittelwert** und die **Standardabweichung** hinreichend beschrieben werden.

Es gibt aber auch Ausnahmen. Also:  
**Immer** die Daten erst mal graphisch untersuchen!

Verlassen sie sich **niemals** allein auf numerische Kenngrößen!