

Biostatistik, WS 2010/2011

Descriptive Statistik

Matthias Birkner

<http://www.mathematik.uni-mainz.de/~birkner/Biostatistik1011/>

19.11.2010



JOHANNES GUTENBERG

UNIVERSITÄT MAINZ

1/112

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

Andrejs Dunkels

3/112

Was ist Statistik?

Die Natur ist voller Variabilität.

Wie geht man mit variablen Daten um?

Es gibt eine mathematische Theorie des Zufalls:

die **Stochastik**.

Variabilität

(Erscheinung der Natur)

durch

Zufall

(mathematische Abstraktion)

modellieren.

Statistik

=

**Datenanalyse
mit Hilfe
stochastischer Modelle**

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*



9/112

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

10/112

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




Eine Möglichkeit der graphischen
Darstellung:
das Histogramm

Graphische Darstellungen


Histogramme und Dichtepolygone

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



14/112

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






Graphische Darstellungen

Histogramme und Dichtepolygone

Analoge Daten zwei Monate später
(3.11.88):

15/112






Histogramme und Dichtepolygonen


Graphische Darstellungen

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


19/112



Die beiden Histogramme sind jetzt vergleichbar
(sie haben dieselbe Gesamtfläche).



Versuche, die Histogramme zusammen zu zeigen:



22/112

Ratschlag

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.



23/112

Problem

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

24/1112


Einfache und Klare Lösung: Dichtepolygone



25/1112

Zwei und mehr Dichtepolygone in einem Plot


Nichtertragende Weibchen



Biologische Interpretation der Verschiebung?

26/1112


Nichtertragende Weibchen 6.9.88 und 3.11.88



27/1112

Anzahl vs. Dichte


Graphische Darstellungen Histogramme und Dichtepolygone



Also: Bei Histogrammen mit ungleichmäßiger Unterteilung immer Dichten verwenden!

28/1112


Graphische Darstellungen Stripcharts



Stripchart + Boxplots, horizontal

30/112

Boxplots, horizontal



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

Zu viel Information erschwert den Überblick




Baum Baum

Wald?

34/112


Beispiel:
Vergleich von mehreren Gruppen



35/112

Der Boxplot

Boxplot, einfache Ausführung



Beispiel:

Die Ringeltaube
Palumbus palumbus

Graphische Darstellungen Beispiel: Ringeltaube




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

Daten aus dem AK Stoffwechselphysiologie

Prof. Prinzinger
Universität Frankfurt

Stoffwechselrate und Umgebungstemperatur bei Ringeltauben (n=90)




Klar:
Stoffwechselrate
höher
bei
tiefen Temperaturen

Vermutung:
Bei **hohen** Temperaturen
nimmt die Stoffwechselrate
wieder zu
(Hitzestress).


Graphische Darstellungen

Beispiel: Ringeltaube


Stoffwechselrate und Umgebungstemperatur bei Ringeltauben ($n=90$)



Stoffwechselrate und Umgebungstemperatur bei Ringeltauben ($n=90$)



Stoffwechselrate und Umgebungstemperatur bei Ringeltauben ($n=90$)




45/112

Graphische Darstellungen


Beispiel: Darwin-Finken

Charles Robert Darwin (1809-1882)



47/112

Darwin-Finken



http://darwin-online.org.uk/graphics/Zoology_Illustrations.html

48/112

Darwins Finken-Sammlung




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

► <http://datadryad.org/repo/handle/10255/dryad.154>

49/112

Flügellängen der Darwin-Finken


Graphische Darstellungen Beispiel: Darwin-Finken



50/112

Graphische Darstellungen Beispiel: Darwin-Finken

Schnabelgröße je nach Art



51/112

Fazit

- ➊ Histogramme erlauben einen detaillierten Blick auf die Daten
- ➋ Dichtepolygone erlauben Vergleiche zwischen vielen Verteilungen
- ➌ Boxplot können große Datenn Mengen vereinfacht zusammenfassen
- ➍ Bei kleinen Datenn Mengen eher Stripcharts verwenden
- ➎ Vorsicht mit Tricks wie 3D oder halbtransparenten Farben
- ➏ Jeder Datensatz ist anders; keine Patentrezepte

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 ($Q_3 - Q_1$)

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.

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.

65/112

DEFINITION:

Mittelwert =
$$\frac{\text{Summe der Messwerte}}{\text{Anzahl der Messwerte}}$$

$$\frac{\text{Summe}}{\text{Anzahl}}$$

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

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

66/112

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?



$$m = 1,8 ?$$




richtig

Beispiel: *Galathea intermedia*

„Rundlichkeit“
:=
Abdominalbreite / Carapaxlänge

Vermutung:
Rundlichkeit nimmt
bei Geschlechtsreife zu

Nichttragende Weibchen 6.9.88




Beispiel:
3.11.88

Nichtertragende Weibchen 3.11.88


Die mittlere Rundlichkeit ist ungefähr:

$$\bar{x} = 0.944$$



Die Standardabweichung
Wie weit weicht
eine typische Beobachtung
vom
Mittelwert
ab ?

typische Mittelwert=2,8
~~Abweichung = 2,8 - 2,8 = 0,0~~



Die **Standardabweichung** σ (“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 Verteilung zwischen $\bar{x} - \sigma$ und $\bar{x} + \sigma$.



79/112

Standardabweichung der Carapaxlängen nichteiertragender Weibchen vom 6.9.88

Nichteiertragende Weibchen



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

80/112

Varianz der Carapaxlängen nichtertragender 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 σ_X^2 in der ganzen Population verwenden?
 Ja, können wir machen. Allerdings ist σ_S^2 im Durchschnitt um den Faktor $\frac{n-1}{n}$ ($= 214/215 \approx 0,995$) kleiner als σ_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 S " ist meistens das korrigierte s gemeint.





Statistische Kenngrößen Mittelwert und Standardabweichung

σ mit n oder $n - 1$ berechnen?

Die Standardabweichung σ 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.

86/112

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.



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.

Bachstelzen fressen Dungfliegen

Vom Sinn und Unsinn von Mittelwerten

Beispiel: Wälderische Bachstelzen

Räuber



Beute



Bachstelze (White Wagtail)
Motacilla alba alba

image (c) by Artur Mikolajewski

Gelbe Dungfliege
Scatophaga stercoraria

image (c) by Viatour Luc


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.




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




93/112



Interpretation

Die Bachstelzen bevorzugen Dungflegen, 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.

94/112





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.

Kupfertolerantes Rotes Straußgras



Rotes Straußgras
Agrostis tenuis

image (c) Kristian Peters



Kupfer
Cuprum

Hendrick met de Bles



A.D. Bradshaw.

Population Differentiation in *agrostis tenuis Sibth.* III.
populations in varied environments.

New Phytologist, 59(1):92 – 103, 1960.



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 eingesätzt.
- Die Wurzellängen dieser "Wiesenpflanzen" werden gemessen.







Vom Sinn und Unsinn von Mittelwerten Beispiel: Kupfertoleranz beim Roten Straußgras


Fazit des Straußgras-Beispiels

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

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

110/112

Brown top Bent n=50+50



111/112

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!

112/112