

Vorlesung 12a

Kann das Zufall sein?

Beispiele von statistischen Tests

Beispiel 1:

“Passen die Verhältnisse in den Rahmen?”

Fishers exakter Test
(vgl. Buch S. 130/131)



Sir Ronald Fisher

1890-1962

Aus einer Urne mit 80 roten und 87 blauen Kugeln wurden 113 Kugeln entnommen.

Aus einer Urne mit 80 roten und 87 blauen Kugeln
wurden 113 Kugeln entnommen.

40 davon waren rot, und 73 waren blau.

Aus einer Urne mit 80 roten und 87 blauen Kugeln
wurden 113 Kugeln entnommen.

40 davon waren rot, und 73 waren blau.

Passt das zur Hypothese, dass die Kugeln
rein zufällig gezogen wurden?

Aus einer Urne mit 80 roten und 87 blauen Kugeln
wurden 113 Kugeln entnommen.

40 davon waren rot, und 73 waren blau.

Passt das zur Hypothese, dass die Kugeln
rein zufällig gezogen wurden?

Stimmen die Verhältnisse einigermaßen,
oder fallen sie aus dem Rahmen?

	gezogen	nicht gezogen	Summe
rot	40	40	80
blau	73	14	87
Summe	113	54	167

	gezogen	nicht gezogen	Summe
rot	40	40	80
blau	73	14	87
Summe	113	54	167

	gezogen	nicht gezogen	Summe
rot	40	40	80
blau	73	14	87
Summe	113	54	167

	gezogen	nicht gezogen	Summe
rot	40	40	80
blau	73	14	87
Summe	113	54	167

Unter den 113 gezogenen Kugeln erwartet man das
Verhältnis 80:87 für rot zu blau

	gezogen	nicht gezogen	Summe
rot	40	40	80
blau	73	14	87
Summe	113	54	167

Unter den 113 gezogenen Kugeln erwartet man das
Verhältnis 80:87 für rot zu blau

Tatsächlich ist das Verhältnis 40:73 viel günstiger für blau!

	gezogen	nicht gezogen	Summe
rot	40	40	80
blau	73	14	87
Summe	113	54	167

Unter den 113 gezogenen Kugeln erwartet man das
Verhältnis 80:87 für rot zu blau

Tatsächlich ist das Verhältnis 40:73 viel günstiger für blau!

Wie lässt sich das quantifizieren?

	gezogen	nicht gezogen	Summe
rot	40	40	80
blau	73	14	87
Summe	113	54	167

Unter der Hypothese des rein zufälligen Ziehens
ist die Anzahl X der gezogenen roten Kugeln
hypergeometrisch verteilt
mit Parametern $n = 113$, $g = 167$, $r = 80$.

	gezogen	nicht gezogen	Summe
rot	40	40	80
blau	73	14	87
Summe	113	54	167

Unter der Hypothese des rein zufälligen Ziehens
ist die Anzahl X der gezogenen roten Kugeln
hypergeometrisch verteilt
mit Parametern $n = 113$, $g = 167$, $r = 80$.

Dafür ergibt sich:

$$\mathbf{E}[X] = n \cdot \frac{r}{g} = 54.1 .$$

	gezogen	nicht gezogen	Summe
rot	40	40	80
blau	73	14	87
Summe	113	54	167

Unter der Hypothese des rein zufälligen Ziehens ist die Anzahl X der gezogenen roten Kugeln hypergeometrisch verteilt mit Parametern $n = 113$, $g = 167$, $r = 80$.

Dafür ergibt sich:

$$\mathbf{E}[X] = n \cdot \frac{r}{g} = 54.1 .$$

$$g = 167, r = 80, n = 113$$

X ist $\text{Hyp}(n, g, r)$ -verteilt

$$\mathbf{E}[X] = n \cdot \frac{r}{g} = 54.1 .$$

$$g = 167, r = 80, n = 113$$

X ist $\text{Hyp}(n, g, r)$ -verteilt

$$\mathbf{E}[X] = n \cdot \frac{r}{g} = 54.1 .$$

Zur Erinnerung:

$$\mathbf{P}(X = k) = \frac{\binom{r}{k} \binom{g-r}{n-k}}{\binom{g}{n}}, \quad k = 0, 1, \dots, n .$$

	gezogen	nicht gezogen	Summe
rot	40	40	80
blau	73	14	87
Summe	113	54	167

	gezogen	nicht gezogen	Summe
rot	40	40	80
blau	73	14	87
Summe	113	54	167

Die Wahrscheinlichkeit, ein Ergebnis zu erhalten,
das mindestens so weit von 54 weg ist
wie der beobachtete Wert 40, ist

	gezogen	nicht gezogen	Summe
rot	40	40	80
blau	73	14	87
Summe	113	54	167

Die Wahrscheinlichkeit, ein Ergebnis zu erhalten,
das mindestens so weit von 54 weg ist
wie der beobachtete Wert 40, ist

$$\mathbf{P}(|X - 54| \geq |40 - 54|)$$

	gezogen	nicht gezogen	Summe
rot	40	40	80
blau	73	14	87
Summe	113	54	167

Die Wahrscheinlichkeit, ein Ergebnis zu erhalten,
das mindestens so weit von 54 weg ist
wie der beobachtete Wert 40, ist

$$\begin{aligned}
& \mathbf{P}(|X - 54| \geq |40 - 54|) \\
& = \mathbf{P}(X \leq 40) + \mathbf{P}(X \geq 68)
\end{aligned}$$

	gezogen	nicht gezogen	Summe
rot	40	40	80
blau	73	14	87
Summe	113	54	167

Die Wahrscheinlichkeit, ein Ergebnis zu erhalten,
das mindestens so weit von 54 weg ist
wie der beobachtete Wert 40, ist

$$\begin{aligned}
 & \mathbf{P}(|X - 54| \geq |40 - 54|) \\
 &= \mathbf{P}(X \leq 40) + \mathbf{P}(X \geq 68) \\
 &= 5.57 \cdot 10^{-6} .
 \end{aligned}$$

$$\mathbf{P}(|X - 54| \geq |40 - 54|) = 5.6 \cdot 10^{-6}$$

Was bedeutet das?

$$\mathbf{P}(|X - 54| \geq |40 - 54|) = 5.6 \cdot 10^{-6}$$

Was bedeutet das?

Fazit: Angenommen die Hypothese trifft zu.
Dann tritt ein Ergebnis, das so extrem ist wie das beobachtete, gerade 6 mal in einer Million auf.
Damit wird die Hypothese mehr als fragwürdig.

Man nennt die berechnete Wahrscheinlichkeit
den zu den Daten gehörigen p -Wert

Man nennt die berechnete Wahrscheinlichkeit
den zu den Daten gehörigen p-Wert
oder auch das *beobachtete Signifikanzniveau*,
zu dem die Hypothese abgelehnt wird.

Wie passt unser Urnen-Beispiel in die Welt?

Es geht um die Fragestellung

“Passen die Proportionen

– oder werden die Chancen beeinflusst?”

Zwei Verpackungen einer Botschaft – und eine Frage dazu:

A. Die “sanfte” Therapiemethode T1 brachte
in nicht weniger als 30% der Fälle keinen Heilungserfolg,
wohingegen die harte Therapiemethode T2
in immerhin 80 % der Fälle erfolgreich war.

Zwei Verpackungen einer Botschaft – und eine Frage dazu:

A. Die “sanfte” Therapiemethode T1 brachte in nicht weniger als 30% der Fälle keinen Heilungserfolg, wohingegen die harte Therapiemethode T2 in immerhin 80 % der Fälle erfolgreich war.

B. Sogar die harte Therapiemethode T2 brachte in nicht weniger als 20% der Fälle keinen Heilungserfolg, wohingegen die sanfte Therapiemethode T1 in immerhin 70 % der Fälle erfolgreich war.

Zwei Verpackungen einer Botschaft – und eine Frage dazu:

A. Die “sanfte” Therapiemethode T1 brachte
in nicht weniger als 30% der Fälle keinen Heilungserfolg,
wohingegen die harte Therapiemethode T2
in immerhin 80 % der Fälle erfolgreich war.

B. Sogar die harte Therapiemethode T2 brachte
in nicht weniger als 20% der Fälle keinen Heilungserfolg,
wohingegen die sanfte Therapiemethode T1
in immerhin 70 % der Fälle erfolgreich war.

Welche Therapiemethode würden Sie (als Arzt) bevorzugen?

Von insgesamt 167 Ärzten
wurden rein zufällig 80 ausgewählt,
denen die Botschaft in der Form A vermittelt wurde,
die restlichen 87 bekamen die Botschaft in der Form B.

Von insgesamt 167 Ärzten
wurden rein zufällig 80 ausgewählt,
denen die Botschaft in der Form A vermittelt wurde,
die restlichen 87 bekamen die Botschaft in der Form B.
Jeder der Ärzte hatte sich daraufhin für die Bevorzugung
einer der beiden Therapiemethoden zu entscheiden.

Von insgesamt 167 Ärzten
wurden rein zufällig 80 ausgewählt,
denen die Botschaft in der Form A vermittelt wurde,
die restlichen 87 bekamen die Botschaft in der Form B.
Jeder der Ärzte hatte sich daraufhin für die Bevorzugung
einer der beiden Therapiemethoden zu entscheiden.

Das Ergebnis war:

Von insgesamt 167 Ärzten
wurden rein zufällig 80 ausgewählt,
denen die Botschaft in der Form A vermittelt wurde,
die restlichen 87 bekamen die Botschaft in der Form B.
Jeder der Ärzte hatte sich daraufhin für die Bevorzugung
einer der beiden Therapiemethoden zu entscheiden.

Das Ergebnis war:

	für Methode T1	für Methode T2	Summe
A	40	40	80
B	73	14	87
Summe	113	54	167

Für das Testen der Hypothese
“Die Verpackung der Botschaft
hat keinen Einfluss auf die Entscheidung”
eignet sich das eingangs besprochene Urnenmodell.

Für das Testen der Hypothese
“Die Verpackung der Botschaft
hat keinen Einfluss auf die Entscheidung”
eignet sich das eingangs besprochene Urnenmodell.

Unter dieser Hypothese
kommt die Aufteilung der 80 + 87 Formulare
auf die 113 Befürworter von T1
und die 54 Befürworter von T2
rein zufällig zustande.

So gesehen kann das Ergebnis “wohl kam Zufall sein”:

unter unserer Hypothese tritt ein Ausgang,
der so extrem ist wie der beobachtete,
gerade mal 6 mal in einer Million auf.

Eine weitere Möglichkeit zum Testen der Hypothese

“Zwei Verhältnisse sind gleich”

bietet die *Normalapproximation*.

Siehe Abschnitt 3 auf den *Folien 5* auf

<http://ismi.math.uni-frankfurt.de/wakolbinger/teaching/statbio10/statbio.html>

Beispiel 2:

“Kann *diese* Verschiebung des Mittelwertes Zufall sein?”

Der t-Test:

n Messwerte x_1, \dots, x_n haben den Mittelwert m
(alles gemessen auf einer bestimmten Skala.)

Denken wir an $n = 16$, $m = \mu_0 + 0.75$.

Dabei ist μ_0 ein vorgegebener “Sollwert”. Unterscheidet sich
der beobachtete Mittelwert m signifikant von μ_0 ?

Eine erste Auskunft gibt ein Vergleich
des Unterschiedes $|m - \mu_0|$ mit dem *Standardfehler*

$$f := s/\sqrt{n}.$$

Nehmen wir an: $s = 1.2$.

Dann ist $f = s/\sqrt{n} = 1.2/\sqrt{16} = 0.3$, und
 m unterscheidet sich “um 2.5 Standardfehler” von μ_0 .

Wenn wir die folgende Modellannahme treffen:

x_1, \dots, x_n sind Realisierungen von unabhängigen,
 $N(\mu, \sigma^2)$ verteilten Zufallsvariablen,

dann können wir die Aussage

“Wie signifikant unterscheidet sich m von μ_0 ?”

sogar exakt beantworten.

Unter der Hypothese “ $\mu = \mu_0$ ” kommt es zu einem Unterschied von \bar{X} und μ_0 , der mindestens so groß ist wie der beobachtete, mit der Wahrscheinlichkeit

$$\mathbf{P}(|T_{15}| \geq 2.5) = 0.025.$$

Unter der Hypothese “ $\mu = \mu_0$ ” kommt es zu einem Unterschied von \bar{X} und μ_0 , der mindestens so groß ist wie der beobachtete, mit der Wahrscheinlichkeit

$$\mathbf{P}(|T_{15}| \geq 2.5) = 0.025.$$

Denn dann ist $(\bar{X} - \mu_0)/(s/\sqrt{n})$
t-verteilt mit $n - 1$ Freiheitsgraden (siehe Vorlesung 11b).

Unter der Hypothese “ $\mu = \mu_0$ ” kommt es zu einem Unterschied von \bar{X} und μ_0 , der mindestens so groß ist wie der beobachtete, mit der Wahrscheinlichkeit

$$\mathbf{P}(|T_{15}| \geq 2.5) = 0.025.$$

Man spricht vom *p-Wert* für die Ablehnung der Hypothese $\mu = \mu_0$ zugunsten der Alternative $\mu \neq \mu_0$.

Oft gibt man sich ein *Signifikanzniveau* α vor.

Wenn der p -Wert kleiner als α ist, sagt man: Die Hypothese $\mu = \mu_0$ kann zugunsten der Alternative $\mu \neq \mu_0$ zum Niveau α abgelehnt werden.

Populär ist die Wahl $\alpha = 0.05$:

Wenn der p -Wert kleiner als 0.05 ist, sagt man auch kurz: m ist (nach dem t-Test) signifikant von μ_0 verschieden.

Beispiel 3:

“Unterscheiden sich zwei Mittelwerte signifikant?”

Beispiel 3:

“Unterscheiden sich zwei Mittelwerte signifikant?”

Der t-Test für ungepaarte Stichproben.

Siehe dazu auch: Folien 4 auf

<http://ismi.math.uni->

[frankfurt.de/wakolbinger/teaching/statbio10/statbio.html](http://ismi.math.uni-frankfurt.de/wakolbinger/teaching/statbio10/statbio.html)

Die Mittelwerte m_x und m_y
von zwei Stichproben des Umfangs $n_x = 9$ und $n_y = 16$
unterscheiden sich um 0.5 Einheiten: $|m_y - m_x| = 0.5$.

Die Mittelwerte m_x und m_y
von zwei Stichproben des Umfangs $n_x = 9$ und $n_y = 16$
unterscheiden sich um 0.5 Einheiten: $|m_y - m_x| = 0.5$.

Ist dieser Unterschied signifikant?

Nach bewährtem Rezept vergleichen wir $|m_x - m_y|$
mit “seinem Standardfehler” f .

Die Mittelwerte m_x und m_y
von zwei Stichproben des Umfangs $n_x = 9$ und $n_y = 16$
unterscheiden sich um 0.5 Einheiten: $|m_y - m_x| = 0.5$.

Ist dieser Unterschied signifikant?

Nach bewährtem Rezept vergleichen wir $|m_x - m_y|$
mit “seinem Standardfehler” f .

Weil wir an unabhängige Stichproben denken,
addieren sich die Varianzen:

$$f := \sqrt{f_x^2 + f_y^2}$$

Eine Maßzahl für den “relativen Unterschied” ist also

$$\frac{m_y - m_x}{f}.$$

Interpretiert man die x_i und die y_j
als Realisierungen von
unabhängigen $N(\mu_X, \sigma_X^2)$ - bzw. $N(\mu_Y, \sigma_Y^2)$ -verteilten
Zufallsvariablen,
dann stellt sich die Frage nach der Verteilung von

$$T := \frac{\bar{Y} - \bar{X}}{\sqrt{\frac{s_X^2}{n_x} + \frac{s_Y^2}{n_y}}}$$

Man kann zeigen, dass dieses T approximativ t -verteilt ist mit einer i.a. nicht ganzzahligen Anzahl von Freiheitsgraden.

Die Formel dafür (die man sich nicht merken muss) findet man auf http://en.wikipedia.org/wiki/Student's_t-test im Abschnitt "Unequal sample sizes, unequal variance"

Wichtig ist der praktische Umgang damit in R, zu dem man dort auf die Frage ?t.test Auskunft bekommt.

Nimmt man überdies an (was nicht immer gerechtfertigt ist!) ,
dass die beiden Varianzen gleich sind ($\sigma_X^2 = \sigma_Y^2 =: \sigma^2$),
dann gibt es eine effizientere Art für die Schätzung von σ :

$$s_{X,Y} := \sqrt{\frac{1}{n_x + n_y - 2} \left((X_1 - \bar{X})^2 + \dots + (Y_{n_y} - \bar{Y})^2 \right)}$$

$$= \sqrt{\frac{(n_x - 1)s_X^2 + (n_y - 1)s_Y^2}{n_x + n_y - 2}}$$

Der Charme davon ist, dass die entsprechende t-Statistik nicht nur
approximativ, sondern exakt t-verteilt ist. Mit einem “Projektionsargument
à la Fisher” zeigt man wie im Satz von Gosset und Fisher:

$$\frac{(\bar{X} - \mu_X) - (\bar{Y} - \mu_Y)}{\sqrt{\frac{1}{n_x} + \frac{1}{n_y}} s_{X,Y}} \quad \text{ist } t(n_x + n_y - 2)\text{-verteilt.}$$

Beispiel 4

Wie untypisch ist die Lage der Ränge?

Der Wilcoxon-Test.

Wie eben zuvor geht es um einen Test der Hypothese,
dass zwei Stichproben (reeller Werte)
aus derselben Verteilung kommen,
gegen die Alternative, dass sich die beiden Verteilungen
durch eine Verschiebung unterscheiden.

Die folgende Idee kommt ganz
ohne spezielle Verteilungsannahme aus:
Man ordnet die $n_x + n_y$ Werte der Größe nach
und ersetzt sie durch ihre Ränge $R(x_i), R(y_j)$.

(der kleinste Wert bekommt den Rang 1, der zweitkleinste den Rang 2,...).

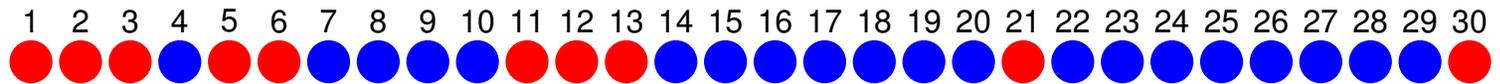
Die folgende Idee kommt ganz
ohne spezielle Verteilungsannahme aus:
Man ordnet die $n_x + n_y$ Werte der Größe nach
und ersetzt sie durch ihre Ränge $R(x_i), R(y_j)$.

(der kleinste Wert bekommt den Rang 1, der zweitkleinste den Rang 2,...).

Dann bildet man die *Rangsumme* $w := \sum_{i=1}^{n_x} R(x_i)$

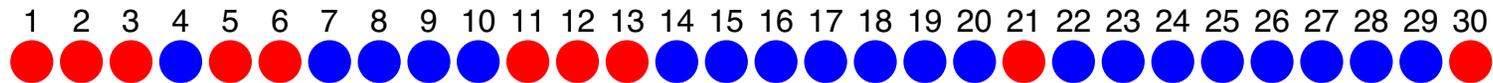
und fragt: Wie wahrscheinlich ist eine
mindestens so kleine oder mindestens so große Rangsumme
bei rein zufälliger Auswahl von n_x Elementen
aus der Menge $\{1, \dots, n_x + n_y\}$?

Die Raenge der x_i und der y_j



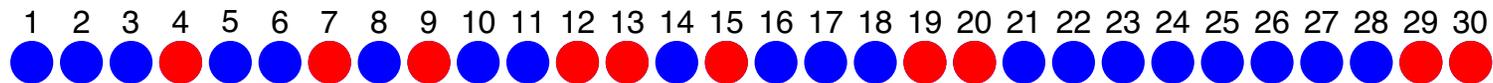
Rangsumme der $x_i = 104$

Die Raenge der x_i und der y_j



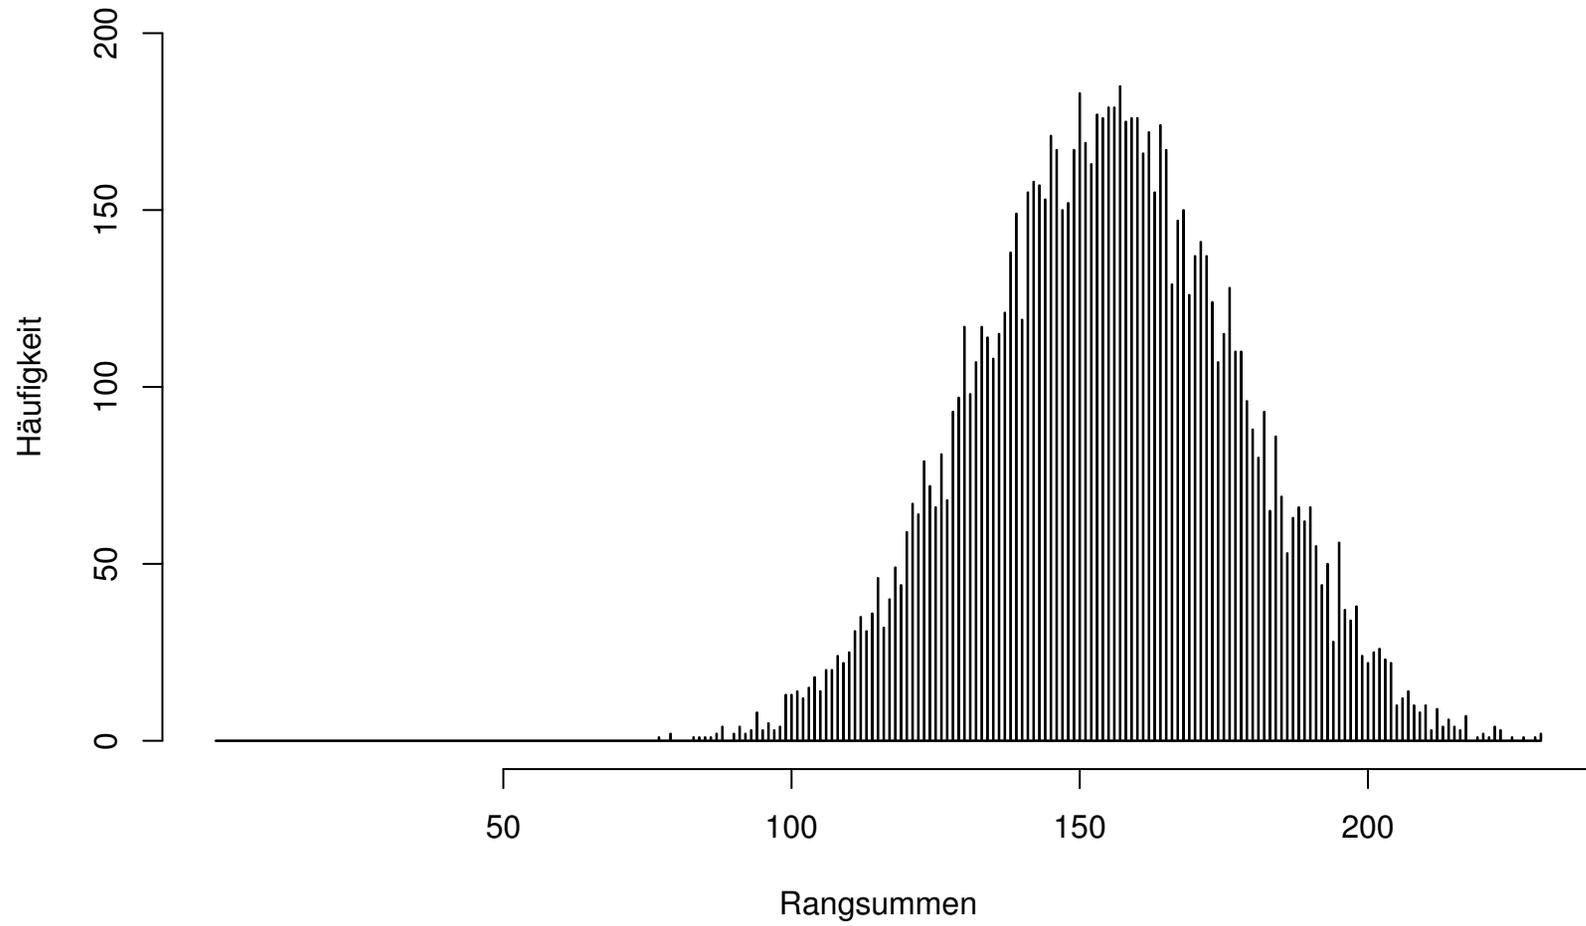
Rangsumme der $x_i = 104$

Eine zufaellige Permutation



Rangsumme der x_i in der Permutation = 158

Rangsummen aus 10000 Permutationen



Rangsummen aus 10000 Permutationen

