

Vorlesung 13b

Statistische Tests

Zusammenfassung und weitere Beispiele

1. Die Grundidee

Die Daten werden aufgefasst als Realisierung
einer zufälligen Stichprobe

Man fragt:

Passt diese Realisierung zu einer bestimmten
Hypothese über ihre Verteilung
oder fällt sie diesbezüglich aus dem Rahmen?

Wie wahrscheinlich ist unter der Hypothese ein Ausgang,
der “mindestens so exotisch ist” wie der beobachtete?

Diese W'keit ist der **p-Wert**,
zu dem die Hypothese abgelehnt werden kann.

Die Weite des Rahmens, in dem die Daten

$$x = (x_1, \dots, x_n) \in S$$


in Bezug auf die Hypothese


(gerade noch bzw. gerade nicht mehr) liegen,

wird gemessen durch eine Teststatistik

$$d : S \rightarrow \mathbb{R}$$

Dabei ist S der *Datenraum* (“Stichprobenraum”)





2. Beispiele

Beispiel 1

$p :=$ Anteil eines Typs in der Gesamtpopulation

$h :=$ Anteil dieses Typs in der Stichprobe

Zwei Szenarien (i) und (ii) haben wir schon kennengelernt:

(i) Die reine Zufälligkeit des Ziehens ist unstrittig.

Hypothese: $p = p_0$

(ii) $p = p_0$ ist bekannt.

Hypothese: “rein zufälliges Ziehen”

Beidemale eignet sich die Teststatistik

$$d(X) := H - p_0$$

Beispiel 1

$p :=$ Anteil eines Typs in der Gesamtpopulation

$h :=$ Anteil dieses Typs in der Stichprobe

Zum Szenario (ii):

($p = p_0$ ist bekannt, Hypothese: “rein zufälliges Ziehen”):

Man erinnere sich an das Beispiel mit den 167 Formularen,

80 davon rot und 87 davon blau “verpackt”

(d.h. $p_0 = 80/167$ ist bekannt).

Aber wurde wirklich rein zufällig gezogen? ...

Beispiel 2

$x = (x_1, \dots, x_n)$ eine Stichprobe reellwertiger Daten

Modellannahme: Die x_i sind Realisierungen von unabhängigen, identisch verteilten Zufallsvariablen X_i mit Erwartungswert μ (und Standardabweichung σ)

Hypothese: $\mu = \mu_0$

Teststatistik:

$$T := \frac{\bar{X} - \mu_0}{S/\sqrt{n}}$$

Beobachter Wert der Teststatistik:

$$t := \frac{\bar{x} - \mu_0}{f} \quad \text{mit } f := s/\sqrt{n} \quad \text{“Standardfehler”}$$

Zu welchem p-Wert kann man Hypothese $\mu = \mu_0$ ablehnen?

Ist n groß, dann nimmt man $\mathbf{P}(|Z| \geq |t|)$
für ein standardnormalverteiltes Z (**z-Test**)

Ist n nicht groß (und die Verteilung von X_i annähernd normal)
dann nimmt man $\mathbf{P}(|T_{n-1}| \geq |t|)$
für T_{n-1} student-verteilt mit $n - 1$ Freiheitsgraden (**t-Test**)

Der theoretische Unterbau ist der

Satz (W. Gosset (alias “Student”, 1908), R. Fisher (1924))

Sind X_1, \dots, X_n unabhängig und $N(\mu, \sigma^2)$ -verteilt,

dann ist $T := \frac{\bar{X} - \mu}{S/\sqrt{n}}$ so verteilt wie


$$T_{n-1} := \frac{N_0}{\sqrt{\frac{1}{n-1} (N_1^2 + \dots + N_{n-1}^2)}}$$

mit unabhängigen und $N(0, 1)$ verteilten N_0, \dots, N_{n-1} .

Die Verteilung von T_{n-1} heißt

t -Verteilung (oder Student-Verteilung) mit $n - 1$ Freiheitsgraden.

Student's t: Dichtefunktionen



Dichten von T_{df}

3. Der t-Test für ungepaarte Stichproben.

“Unterscheiden sich zwei Mittelwerte signifikant?”

Beispiel: Die Mittelwerte m_x und m_y
von zwei Stichproben des Umfangs n_x und n_y
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 Zufallsvariablen X_i, Y_j ,
(mit (X_i) identisch verteilt, (Y_j) identisch verteilt)
dann stellt sich die Frage nach der Verteilung von

$$T := \frac{\bar{Y} - \bar{X}}{F} = \frac{\bar{Y} - \bar{X}}{\sqrt{\frac{S_X^2}{n_x} + \frac{S_Y^2}{n_y}}}$$

$$T := \frac{\bar{Y} - \bar{X}}{F} = \frac{\bar{Y} - \bar{X}}{\sqrt{\frac{S_X^2}{n_x} + \frac{S_Y^2}{n_y}}}$$

Für große n_x, n_y ist T annähernd $N(0, 1)$ -verteilt
(wegen des Zentralen Grenzwertsatzes (im Zähler) und
des Gesetzes der großen Zahlen (im Nenner)).

Was aber tun für kleine n_x, n_y ?

Hier kommt man zumindest unter der zusätzlichen Annahme
weiter, dass die X_i und Y_j normalverteilt sind.

Man kann zeigen, dass T dann annähernd 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.

4. Der Wilcoxon-Test.

Wie untypisch ist die Lage der Ränge?

Wie eben zuvor geht es um einen Test der Hypothese,
dass zwei Stichproben
aus derselben Verteilung (auf \mathbb{R}) 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,...).

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


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

Die Ränge der x_i und der y_j



Rangsumme der x_i = 104

Eine zufällige Permutation



Rangsumme der x_i in der Permutation = 158

Die “beobachtete” Rangsumme war 104.

Die minimale mögliche Rangsumme
einer “roten Teilstichprobe” ist $1 + \dots + 10 = 55$.


Ihre maximale mögliche Rangsumme ist

$$21 + \dots + 30 = 255.$$

Wir ziehen 10000 mal eine Stichprobe der Größe 10 (aus 30)
und notieren deren Rangsumme.

Der *stochastische p-Wert* ist die relative Häufigkeit
der Ergebnisse, für die sich eine Rangsumme
 ≤ 104 oder $\geq 255 - (104 - 55)$ ergibt.

Rangsummen aus 10000 Permutationen



Rangsummen aus 10000 Permutationen

