

Binomialtest

Mathematik IV: Statistik
für D-UWIS, D-ERDW, D-USYS und D-HEST – SS15



Helfen Sie uns jetzt, das Leben an der ETH zu verbessern!

- Auf diese E-Mail mit Link achten: *studierendenbefragung@ethz.ch*
- Online-Fragebogen ausfüllen.
- Es geht es um Ihre Zufriedenheit an der ETH!

Vielen Dank für Ihre Mithilfe,
Sarah Springmann

Die Umfrage läuft vom 16. März bis zum 6. April 2015
Ausführliche Informationen unter www.ethz.ch/studierendenbefragung



Lernziele heute

- Binomialtest
- Fehler 1. und 2. Art
- Sensitivität und Spezifität

Hausaufgaben

- Skript: Kapitel 3.2.2 lesen
- Serie 5 lösen
- Quiz 5 bearbeiten
- bis etutoR 6 anschauen





Bauchgefühl und Hypothesen

- Komplette Box → wenige doppelte Sticker
- Einzelne Blister an verschiedenen Kiosks → viele doppelte
- «Nullhypothese»: «Null», weil kein System hinter dem Verpacken steckt
 - Sticker werden **zufällig** in Boxen gepackt
- Alternativhypothese:
 - Sticker werden **systematisch** in Boxen gepackt, sodass es weniger doppelte gibt

Wie könnte man zwischen diesen beiden Hypothesen unterscheiden?



Hypothesentest

- Ich habe eine Box mit 350 Stickern gekauft und konnte in ein leeres Album (600 mögliche Bilder) 339 Sticker einkleben.
- Angenommen die Nullhypothese \mathcal{H}_0 stimmt:
 - Ist es plausibel, dass ich dann 339 Bilder einkleben kann?
- Passen die Nullhypothese \mathcal{H}_0 : «zufällig verpackt» und die Beobachtung «339 Bilder eingeklebt» zusammen?



Problem: Was ist «normal»?

- Wenn wir viel mehr Bilder als «normal» einkleben konnten, dann wurden die Bilder wohl nicht zufällig verpackt.
- Angenommen die Nullhypothese stimmt (d.h. \mathcal{H}_0 : «*die Bilder sind zufällig verpackt worden*»):
 - Wie viele Bilder kann man normalerweise einkleben?
- **Signifikanzniveau α** : Wie «*abnormal*» muss eine Beobachtung sein, damit wir der Nullhypothese nicht mehr glauben?
 - z.B. $\alpha = 1/1'000'000 \rightarrow$ wir lehnen \mathcal{H}_0 ab, wenn wir etwas beobachten, das weniger wahrscheinlich als $1/1'000'000$ ist.

Lösung: Computersimulation

1



264

2



259

⋮

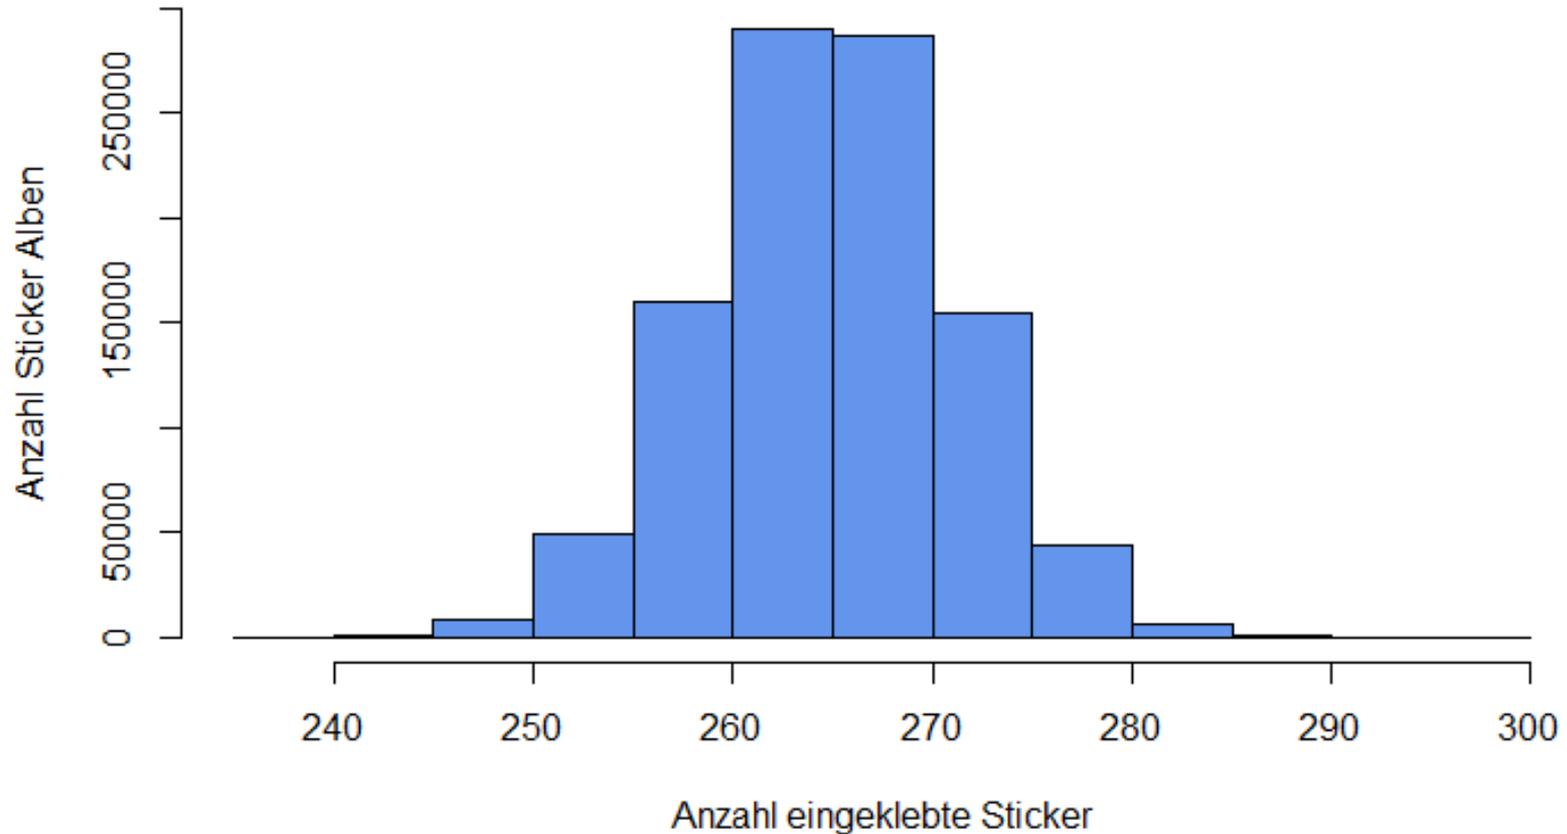
⋮

1 Mio



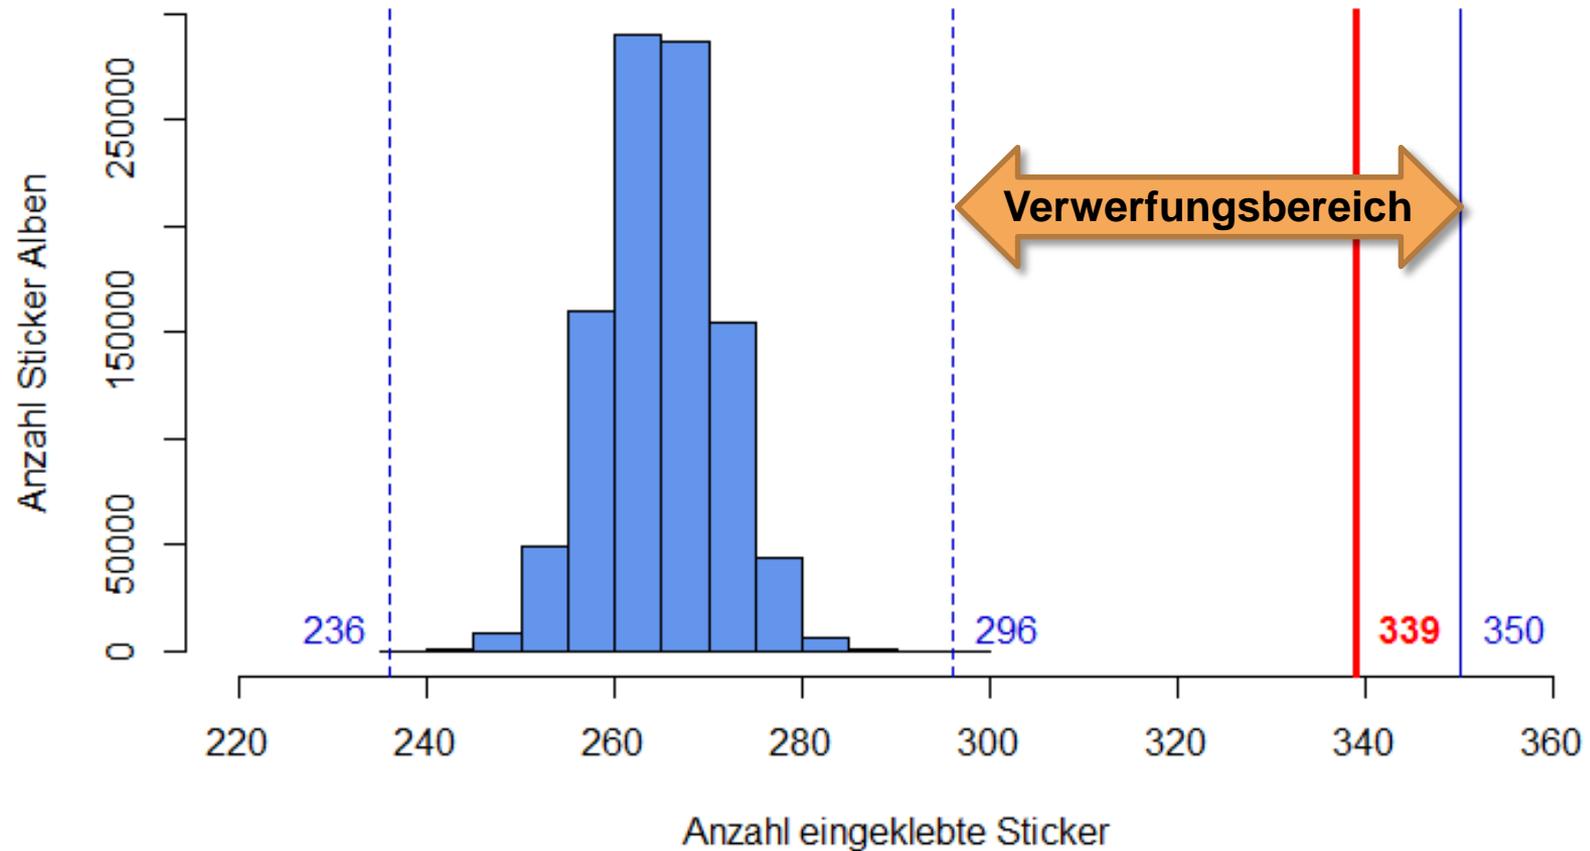
271

Resultat der Computersimulation



→ Den R Code für diese Grafiken können Sie von der Homepage herunterladen

Wie «*abnormal*» ist unsere Beobachtung nun?



Schlussfolgerung

- Angenommen, die Sticker werden zufällig verpackt:
 - Die W'keit 339 oder mehr Sticker einkleben zu können wäre kleiner als ein Millionstel!
 - Unsere Beobachtung und die Simulation passen nicht zu einander!



Zusammenfassung: Hypothesentest

1. **Modell:** Ziehe 350 Sticker mit Zurücklegen aus 600 möglichen Stickern
2. **Nullhypothese \mathcal{H}_0 :** «die Sticker sind **zufällig** verpackt worden»
Alternative \mathcal{H}_A : «**systematisch** verpackt, sodass weniger Doppelte»
3. **Teststatistik:** Anzahl der Sticker, die man in ein leeres Album einkleben kann, wenn man eine Box mit 350 Stickern kauft.
Verteilung der *Teststatistik*, wenn die *Nullhypothese* stimmt:
Computersimulation
4. **Signifikanzniveau** $\alpha = 1/1'000'000$
5. **Verwerfungsbereich** der *Teststatistik*:
Computer beobachtet bei 1 Mio. Simulationen nie mehr als 296 eingeklebte Sticker \rightarrow *Verwerfungsbereich*: $K = \{297, 298, \dots, 350\}$
6. **Testentscheid:** Der beobachtete Wert (339) liegt im *Verwerfungsbereich* der *Teststatistik*. Daher wird die *Nullhypothese* auf dem *Signifikanzniveau* α verworfen.

Binomialtest





Binomialtest – Beispiel Würfel

- **Modell:** X = Anzahl 6er bei 50 Würfeln;
- **Nullhypothese** \mathcal{H}_0 : $\pi = \frac{1}{6}$
- **Alternative** \mathcal{H}_A : $\pi > \frac{1}{6}$ (einseitig)
- **Teststatistik:** T = Anzahl 6er bei 50 Würfeln
- **Verteilung** der Teststatistik, wenn \mathcal{H}_0 stimmt:
$$T \sim \text{Bin}\left(50, \frac{1}{6}\right)$$
- **Signifikanzniveau** $\alpha = 0.05$ («Konvention»)



Binomialtest – Beispiel Würfel

- **Teststatistik:** $T =$ Anzahl 6er bei 50 Würfeln
- **Verwerfungsbereich** der Teststatistik:

t	...	13	14	15	...
$P[T \geq t]$...	0.06	0.03	0.01	...

Grenze des Verwerfungsbereiches: Kleinste Zahl t , sodass $P[T \geq t] \leq \alpha$

- **Testentscheid:** Liegt die beobachtete Anzahl 6er bei 50 Würfeln im Verwerfungsbereich der Nullhypothese \mathcal{H}_0 ?
 - Falls **ja**: \mathcal{H}_0 wird auf dem 5% Niveau verworfen
 - Falls **nein**: \mathcal{H}_0 **kann** auf dem 5% Niveau **nicht** verworfen werden

Fehlertypen

		Wahrheit / Realität	
		Richtig (T)	Falsch (F)
Total (n)			
Testergebnis	\mathcal{H}_0 verwerfen (P, positiv)		
	\mathcal{H}_0 <u>nicht</u> verwerfen (N, negativ)		
		Sensitivität TP/P	Spezifizität TN/P

Was ist schlimmer? 1. Typ (FP) oder 2. Typ (FN)?

Feueralarm		Brennt es?	
		Ja	Nein
Alarm?	Alarm! (positiv)		
	Kein Alarm (negativ)		

Signifikanzlevel α vergrössern

- Fehler 2. Art viel schlimmer!
- Optimiere, indem man den Test auflockert (Test verwirft früher → mehr Fehler 1. Art)



Was ist schlimmer? 1. Typ (FP) oder 2. Typ (FN)?

Spamfilter		Spam?	
		Ja	Nein
Filter?	Entfernen (positiv)		
	Lassen (negativ)		

- Fehler 1. Art viel mühseliger!
- Optimiere, indem der Test strenger wird (Test verwirft viel später → mehr Fehler 2. Art)

Signifikanzlevel α verkleinern



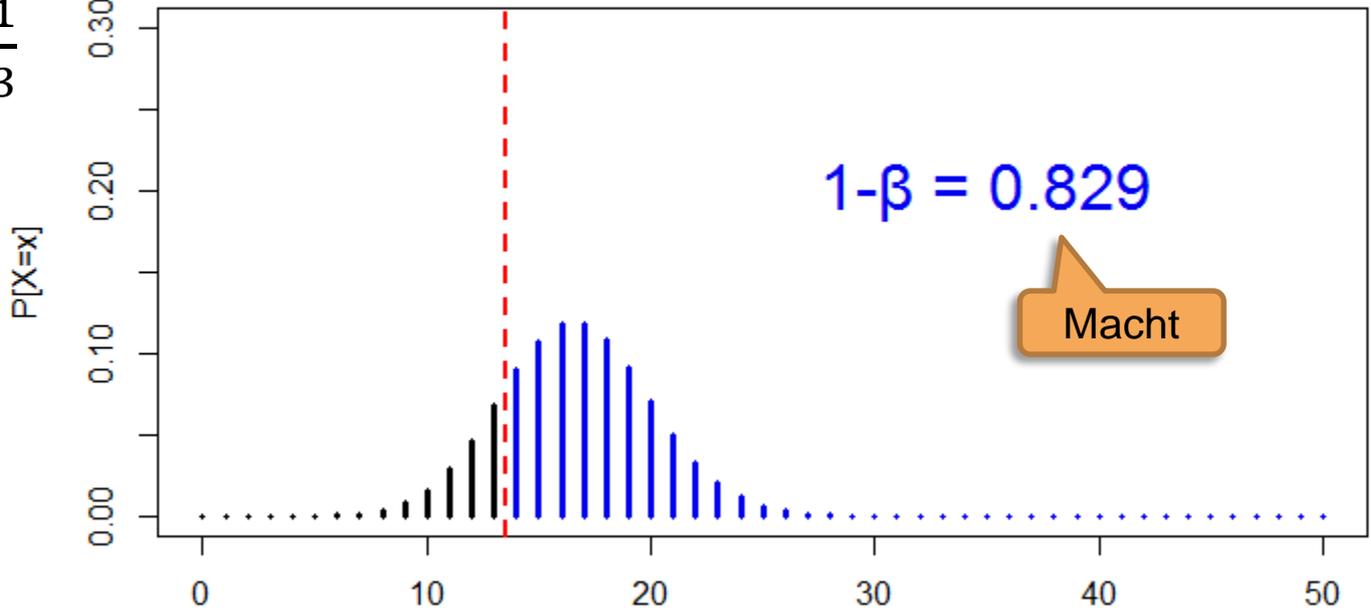
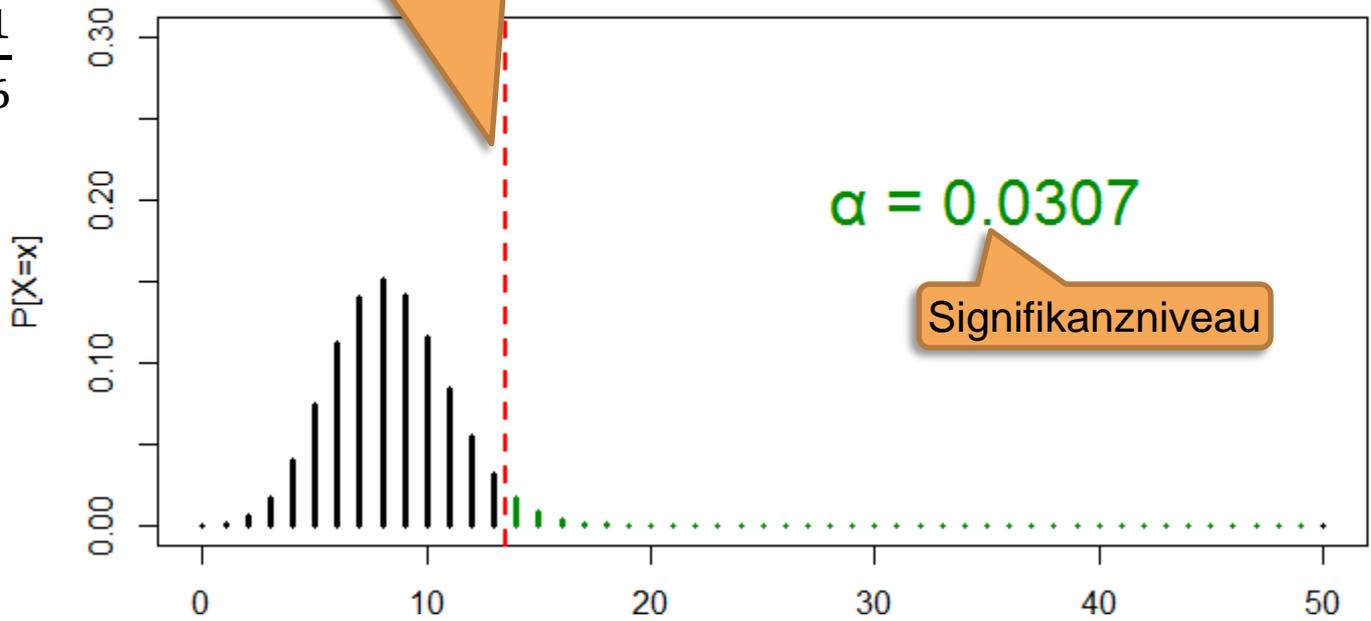
Beginn Verwerfungsbereich

\mathcal{H}_0 richtig: $p_0 = \frac{1}{6}$

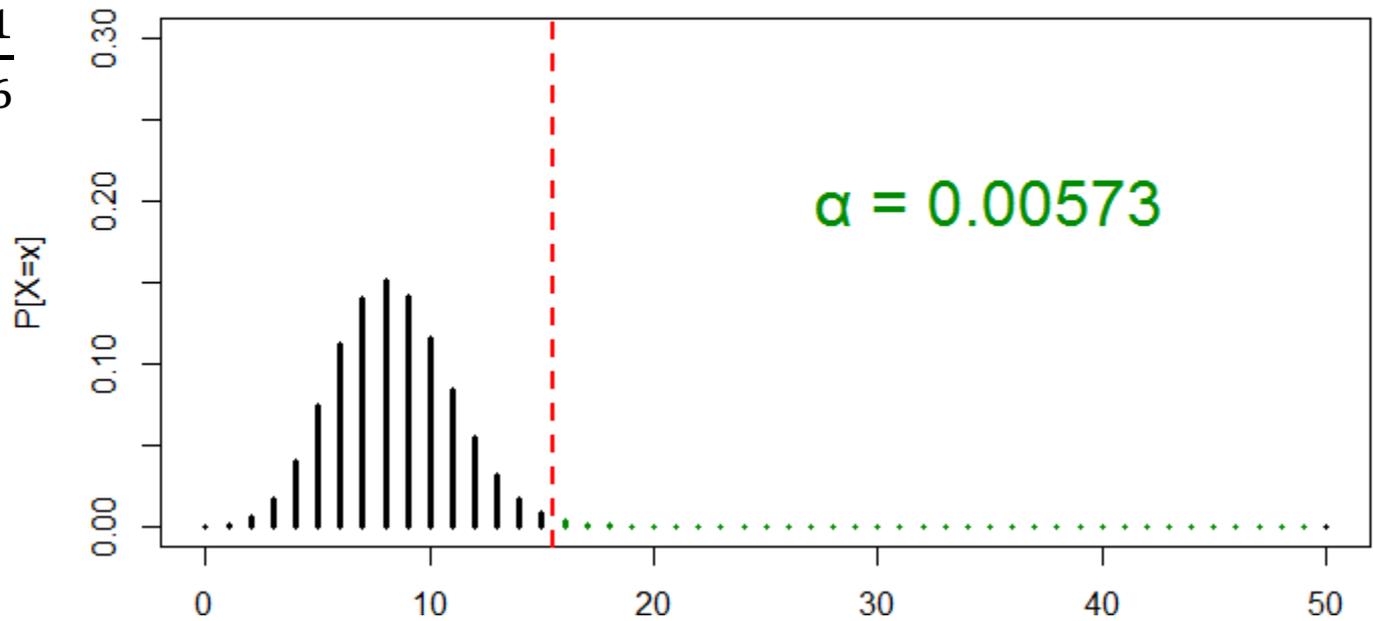
Fairer Würfel

Falscher Würfel

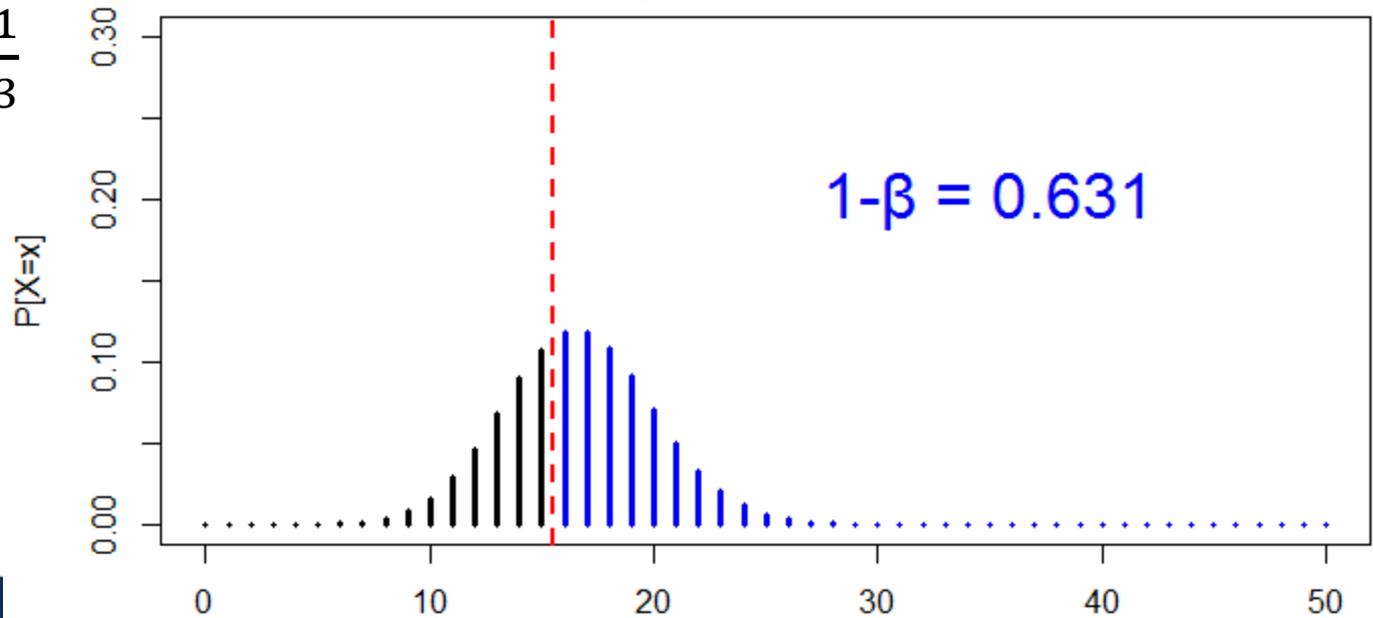
\mathcal{H}_A richtig: $p_A = \frac{1}{3}$



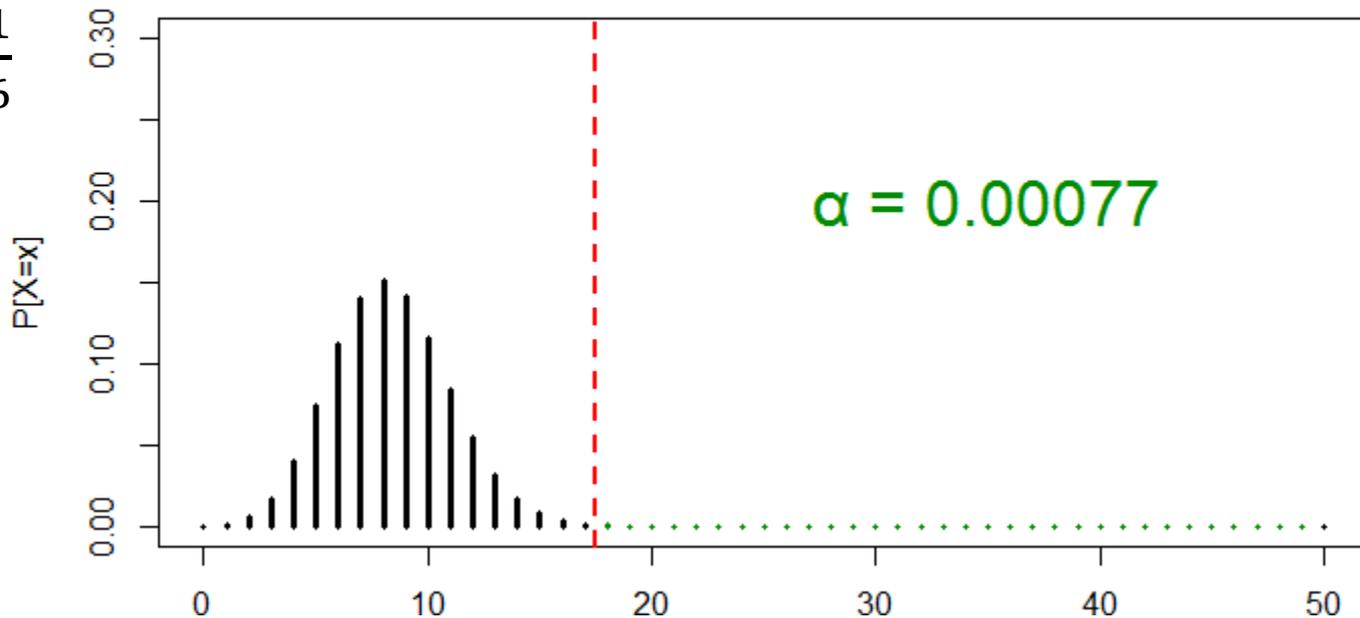
\mathcal{H}_0 richtig: $p_0 = \frac{1}{6}$



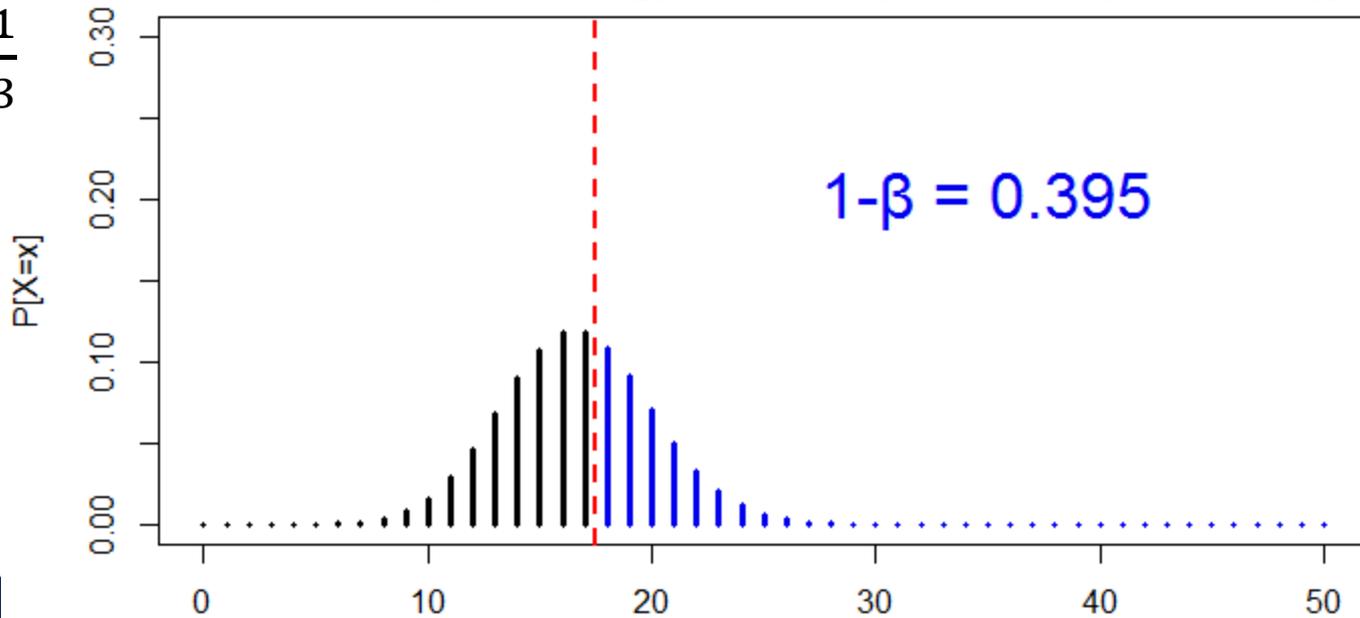
\mathcal{H}_A richtig: $p_A = \frac{1}{3}$



\mathcal{H}_0 richtig: $p_0 = \frac{1}{6}$



\mathcal{H}_A richtig: $p_A = \frac{1}{3}$



Animation zur Macht

- <http://stat.ethz.ch/~kalisch/teaching/animations/binTestPower/>
- Mehr Beobachtungen und Fehler 1. Art fix
 - Macht nimmt zu!

Poweranalyse

- Gegeben:
 - $\mathcal{H}_0, \mathcal{H}_A, \alpha$, z.B. $\mathcal{H}_0: \pi = \frac{1}{6}, \mathcal{H}_A: \pi > \frac{1}{6}, \alpha = 0.05$
 - Wert unter \mathcal{H}_A , den man mit Macht $1 - \beta$ entdecken will, z.B. $\pi = \frac{1}{3}$ soll mit einer Macht von 90% entdeckt werden.
- Gesucht:
 - Stichprobengrösse, d.h. wie gross muss meine Stichprobe sein, dass ich die obigen Voraussetzungen/Bedingungen erfüllen kann?
- Lösung:
 - Paper von A'Hern (auf Website)
 - Computer (z.B. mit R package clinfun)

Bsp. Lösung mit Paper von A'hern

Table I. Sample sizes and cut-offs for exact single-stage phase II trials.

p_0	p_1	$\alpha = 0.05; 1 - \beta = 0.8$	$\alpha = 0.05; 1 - \beta = 0.9$	$\alpha = 0.01; 1 - \beta = 0.8$	$\alpha = 0.01; 1 - \beta = 0.9$
0.15	0.20	65/355	89/500	106/568	135/742
	0.25	22/101	28/136	35/157	44/206
	0.30	12/48	15/64	19/73	24/98
	0.35	8/28	10/38	14/47	16/58
	0.40	7/21	8/27	10/30	12/39
	0.45	5/14	7/21	8/21	10/29
	0.50	4/10	5/14	7/17	8/21
	0.55	4/9	5/13	6/13	7/17
	0.60	3/6	4/9	5/10	6/13
	0.65	3/6	4/9	5/9	5/10
	0.70	3/5	3/6	5/8	5/9
	0.75	3/5	3/6	4/6	5/9
	0.80	3/4	3/5	4/6	4/6

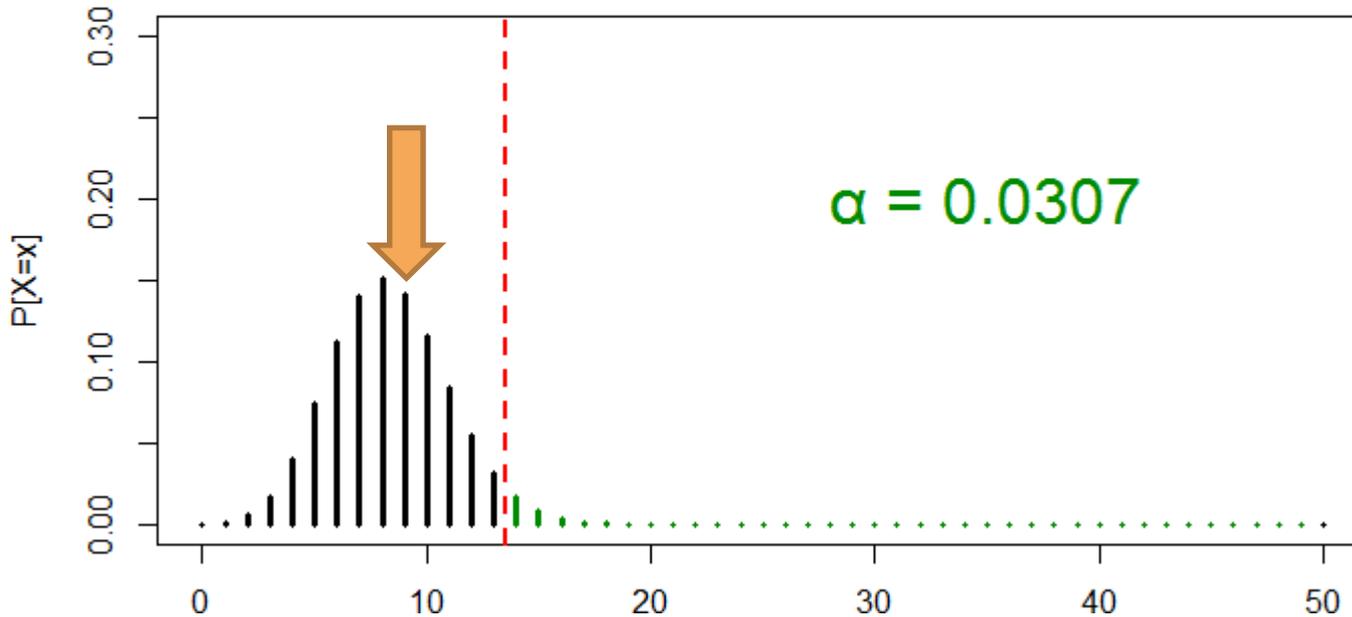
$\approx \frac{1}{6}$

$\approx \frac{1}{3}$

- Stichprobengrösse $n = 38$
- Verwerfungsbereich $K = \{10, 11, 12, \dots, 38\}$

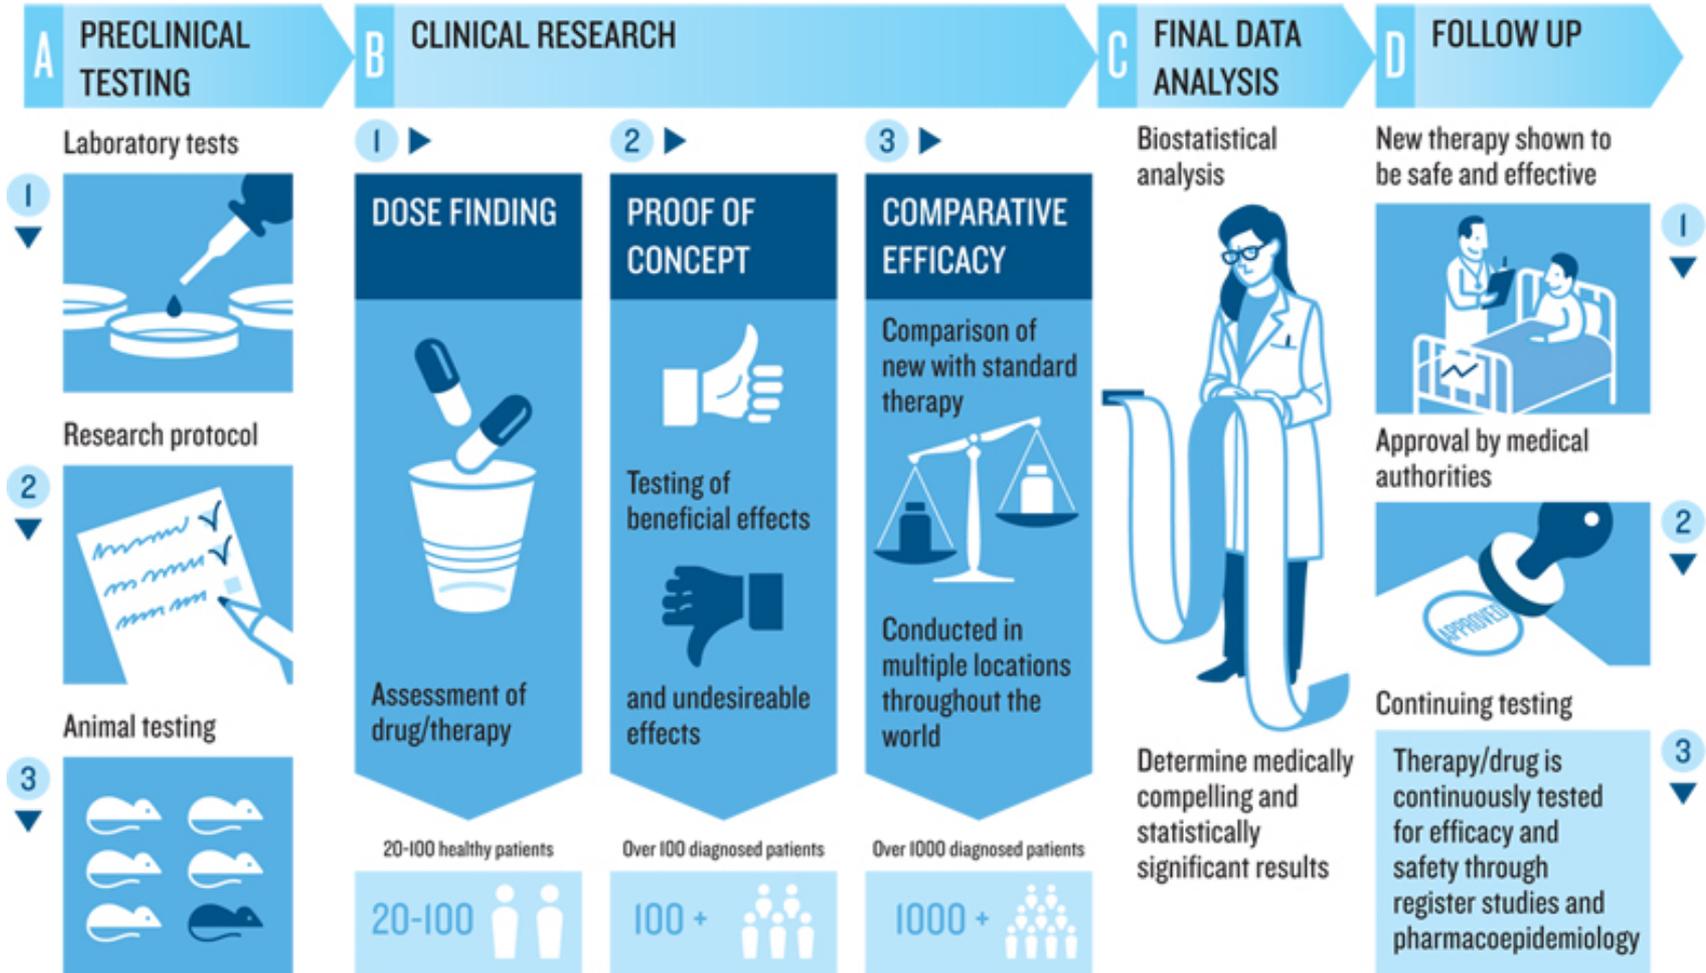


Nullhypothese nicht verwerfen...



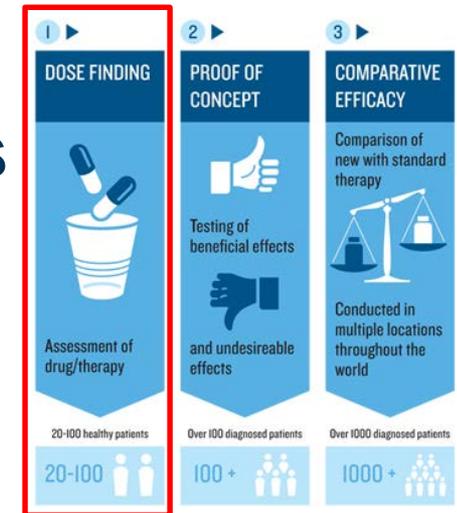
- Nullhypothese ist richtig.
- Sowohl Nullhypothese, als auch die Alternative sind möglich.
- Alternative ist falsch.

Klinische Studie revisited



Phase 1 – Maximal Tolerierbare Dosis

- Keine Statistik / fixe Regeln
- «3+3 Design» (single ascending dose)
 - 3 gesunde Probanden erhalten Startdosis
 - alle drei OK: 3 neue Patienten erhalten höhere Dosis
 - sonst: Abbruch (oder Konsolidierung)
- «Berüchtigte» Phase I Studie: TGN1412



<http://de.wikipedia.org/wiki/TGN1412>

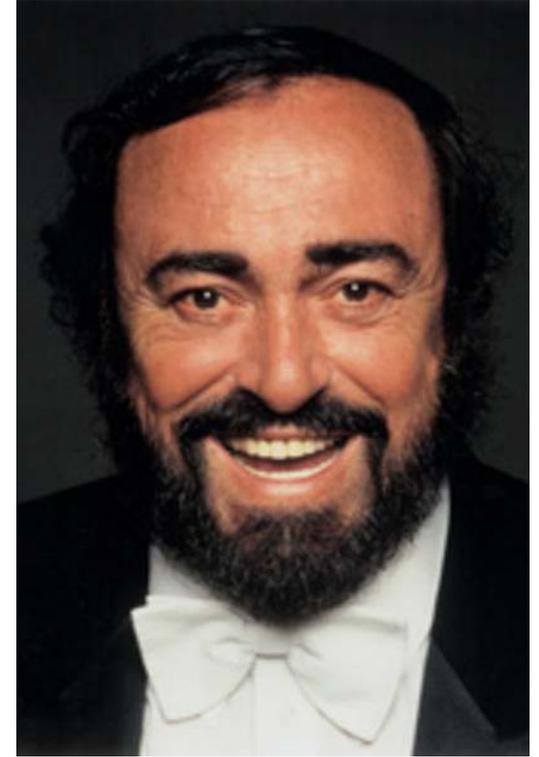
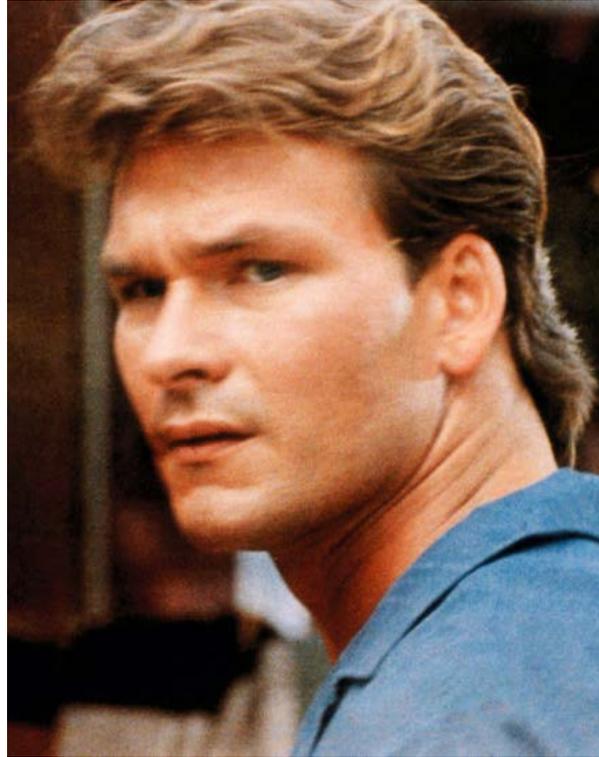
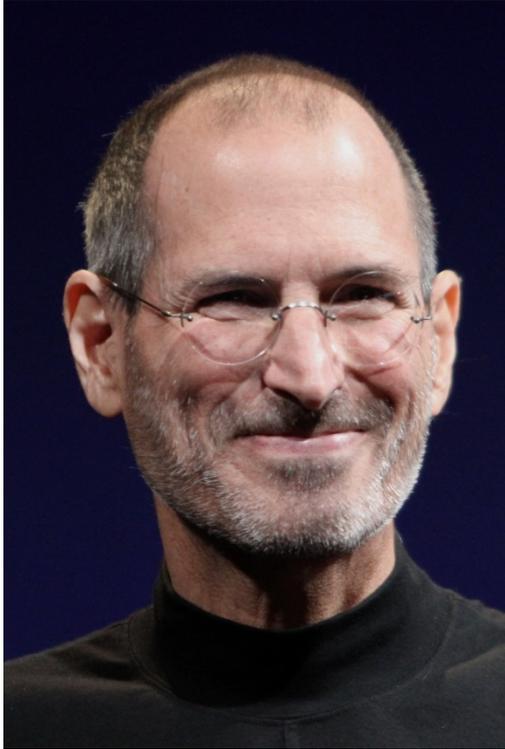
**Bleibende Schäden nach
Medikamententests**
Rätselraten in London über den exakten Wirkungsmechanismus
22.4.2006, 02:05 Uhr
Mindestens ein Proband des Londoner
wurde nicht völlig gesund war
offenen nun ihr
in davon

Phase 2 – Effektivität

- Ist das Medikament bei Menschen wirksam?
- Lohnt sich eine extrem teure Phase 3 Studie?
- Üblicherweise scheitert die Entwicklung eines neuen Medikaments in dieser Phase



Einseitiger Binomialtest



Bauchspeicheldrüsenkrebs
(*engl. pancreatic cancer*)

Phase 2 Studie

- Phase II trial of S-1 and concurrent radiotherapy in patients with locally advanced pancreatic cancer
 - Kim et.al., Cancer Chemotherapy and Pharmacology (2009); 63: 535 - 541

Phase 2 Studie – Bauchspeicheldrüsenkrebs

Statistical analysis

Recently, many studies of chemoradiotherapy for locally advanced pancreatic cancer have reported good response rates of up to 50% [24], and a phase I study of S-1 chemoradiotherapy by Sudo et al. [29] reported a response rate of 43.8%. Accordingly, we assumed that if the response rate was 30% or higher, the treatment would be beneficial. To test the alternative hypothesis that the minimum response rate was 30% with a null hypothesis that the response rate was 10% or lower, the required number of patients for a one-sided test was 25 with a type I error of 5%, and a power of 80%, according to single-stage phase II design [1]. If six or more patients were responsive, the treatment would be considered acceptable [1]. Tumor response and toxicity were evaluated with an intention-to-treat analysis, and patients who received at least a single dose of S-1 or a single fraction of radiotherapy were evaluated for tumor response and toxicity. The Kaplan–Meier method was used to estimate overall survival, time-to-progression and the 1-year survival rate. Statistical analysis was performed using SPSS version 11.0 for Windows.

Wunschliste

- $\alpha = 0.05$
- $1 - \beta = 0.8$ bei einer Effektgrösse von $\pi_A = 0.3$
- $\mathcal{H}_0: \pi = 0.1$
- $\mathcal{H}_A: \pi > 0.1$

aus der Poweranalyse folgt:

- $n = 25$
- $c = 6$

Einseitiger Binomialtest

1. Modell:

X : # Patienten mit *partial remission*, $X \sim \text{Bin}(25, \pi)$

2. $\mathcal{H}_0: \pi = 0.1$

$\mathcal{H}_A: \pi > 0.1$

3. Teststatistik T : gezählte # Patienten mit *partial remission*

Falls \mathcal{H}_0 stimmt: $T \sim \text{Bin}(25, 0.1)$

4. Signifikanzniveau: $\alpha = 0.05$

5. Verwerfungsbereich:

Verwerfungsbereich - Zwischenrechnung

- $P[T \geq 0] = 1$
- $P[T \geq 1] = 1 - P[T = 0] = 1 - \binom{25}{0} 0.1^0 0.9^{25}$
- $\approx 1 - 0.07 = 0.93$
- $P[T \geq 2] = 1 - P[T \leq 1] = 1 - (P[T = 0] -$

Einseitiger Binomialtest

1. Modell:

X : # Patienten mit *partial remission*, $X \sim \text{Bin}(25, \pi)$

2. $\mathcal{H}_0: \pi = 0.1$

$\mathcal{H}_A: \pi > 0.1$

3. Teststatistik T : gezählte # Patienten mit *partial remission*

Falls \mathcal{H}_0 stimmt: $T \sim \text{Bin}(25, 0.1)$

4. Signifikanzniveau: $\alpha = 0.05$

5. Verwerfungsbereich:

t	0	1	2	3	4	5	6	7
$P[T \geq t]$	1	0.93	0.73	0.46	0.24	0.10	0.03	0.002

6. Testentscheid: $t = 6, t \in K \Rightarrow \mathcal{H}_0$ wird verworfen

Zusammenfassung

- Binomialtest: Wann ist ein Medikament wirksam?
- Fehler 1. und 2. Art → Es brennt, kein Alarm?
- Spezifität (Macht) nimmt zu, wenn n grösser und α fix

Hausaufgaben

- Skript: Kapitel 3.2.2 lesen
- Serie 5 lösen
- Quiz 5 bearbeiten
- bis etutoR 6 anschauen

