

Exakte Methoden bei kleinen Stichproben

[Signifikanztests]

Uwe Menzel, 22.01.10

Nebenwirkung von Arzneimitteln

- "Zerodin": 40% der Patienten mit Nebenwirkungen
- "Novodin"-Reklame: "deutlich weniger Nebenwirkungen"
- Stichprobe unter "Novodin"-Patienten:
 - 20 Patienten, zufällig ausgewählt
 - 3 Patienten mit Nebenwirkungen



Schätzung: $3/20 = 15\%$ (!)

Ist die Beobachtung (veränderte Proportion) statistisch signifikant?

Verteilung der Teststatistik

- X = Anzahl der Patienten in der Stichprobe mit Nebenwirkungen
- X kann als Ergebnis einer Folge von identischen und unabhängigen Einzelversuchen angesehen werden
- Einzelversuch = Befragung eines Patienten
 - 2 alternative Ereignisse
 - Wahrscheinlichkeit von Nebenwirkungen: p

$$X \in \text{Bin}(n, p)$$

$$p_X(x_1) = \binom{n}{x_1} \cdot p_1^{x_1} \cdot (1-p_1)^{n-x_1} = \frac{n!}{x_1! \cdot x_2!} \cdot p_1^{x_1} \cdot p_2^{x_2}$$

Signifikanztest: Hypothesen

- Nullhypothese (H_0): $p=0.4$
 - Novodin hat ebenfalls eine Nebenwirkungs-Rate von 40%
- Alternative Hypothese (H_a): $p \neq 0.4$
 - Novodin hat tatsächlich eine andere Nebenwirkungs-Rate



Signifikanztest: p-Wert


"Wahrscheinlichkeit, bei Gültigkeit der Nullhypothese ein mindestens so extremes Ereignis zu erhalten wie das beobachtete"

- Nullhypothese: $X \in \text{Bin}(20, 0.4)$
- Gesucht: $P(X=3 \text{ oder extremer/ebenso extrem})$

Graph in Minitab



Verteilung von X "unter H_0 "



$$p\text{-value} = 0,0160 + 0,00647 = 0,02247$$

Signifikanztest: Entscheidung

- Signifikanzniveau α (üblich 0,05 oder 0,01):
- **p-value = 0,022 < α**
 - H_0 wird verworfen
 - Novodin hat eine *veränderte* Nebenwirkungsrate!

analytisch 

Binomial Distribution: cdf

k	n = 20						
	0.01	0.05	0.1	0.2	0.3	<u>0.4</u>	0.5
0	0.818	0.358	0.122	0.012	0.001	0.000	0.000
1	0.983	0.736	0.392	0.069	0.008	0.001	0.000
2	0.999	0.925	0.677	0.208	0.035	0.004	0.000
<u>3</u>	1.000	0.984	0.867	0.411	0.107	<u>0.016</u>	0.001
4		0.997	0.957	0.630	0.238	0.051	0.006
5		1.000	0.989	0.804	0.416	0.126	0.021
6			0.998	0.913	0.608	0.250	0.058
7			1.000	0.968	0.772	0.416	0.132
8				0.990	0.887	0.596	0.252
9				0.997	0.952	0.755	0.412
10				0.999	0.983	0.872	0.588
11				1.000	0.995	0.943	0.748
12					0.999	0.979	0.868
<u>13</u>					1.000	<u>0.994</u>	0.942
14						0.998	0.979
15						1.000	0.994

Exakter Binomialtest



$$X \in \text{Bin}(n, p) \quad n = 20 \quad p = 0.4 \quad x_{\text{obs}} = 3$$

$$p = P(X \leq 3 \cup X \geq 14) = P(X \leq 3) + P(X \geq 14)$$

$$= P(X \leq 3) + 1 - P(X \leq 13)$$

$$= F_X(3) + 1 - F_X(13) \quad \text{Verteilungsfunktion}$$

$$= 0.016 + 1 - 0.994$$

$$= \underline{0.022}$$

Exakter Binomialtest

$$p = P(X \leq 3) + 1 - P(X \leq 13) = F_X(3) + 1 - F_X(13)$$

```
> p.value <- pbinom(3,20,0.4) + 1 - pbinom(13,20,0.4)
> p.value
[1] 0.02242704
```



Exakter Binomialtest 

Exakter Binomialtest



Sample	X	N	Sample p	95% CI	P-Value
1	3	20	0,150000	(0,032071; 0,378927)	0,022

Exakter Binomialtest in R, SAS, SPSS

```
> binom.test(3,20,p=0.4)


Exact binomial test

data: 3 and 20
number of successes = 3, number of trials = 20, p-value = 0.02243
alternative hypothesis: true probability of success is not equal to 0.4
95 percent confidence interval:
 0.03207094 0.37892683
sample estimates:
probability of success
 0.15
```

SAS, SPSS: $p_2 = 2 * p_1$??




Exakter Binomialtest



Obs.

Asymptotischer Test: $X \in \text{Bin}(n, p)$ $E(X) = n \cdot p$ $V(X) = n \cdot p \cdot (1-p)$
 $X \in N(n \cdot p, \sqrt{n \cdot p \cdot (1-p)})$ $n \cdot p \cdot (1-p) \geq 10$


Verteilung von X "unter H₀"



Ergebnis "4 von 20" wäre nicht signifikant, bei einem Schätzwert von 20% – **kleine Stichprobe !!**

Anpassungs-Test

- "Goodness-of-Fit Test"
 - Passt ein Modell zu einer Beobachtung (Stichprobe)?



Mendelsche Experimente

Kreuzungs-Experiment bei Blütenpflanzen

	A	B
A	AA	AB
B	AB	BB



Erwartetes Farbverhältnis: **1 : 2 : 1**

Modell vs. Beobachtung

"observed"	5	2	1
"expected"	2	4	2

} $n = 8, k = 3$
(kleine Stichprobe)

- Nullhypothese (H_0):
 - Farbverhältnis 1:2:1 (Modell wird *nicht* verworfen)
- Alternative Hypothese (H_a):
 - Farbverhältnis *nicht* 1:2:1 (Modell wird verworfen)

p-Wert

"Wahrscheinlichkeit, bei Gültigkeit der Nullhypothese ein mindestens so extremes Ereignis zu erhalten wie das beobachtete"

→ Wir müssen:

1. die Wahrscheinlichkeiten der Ereignisse unter H_0 berechnen
2. herausfinden, was "extrem" ist



1 Wahrscheinlichkeit der Beobachtung "unter H₀"

$$P(x_1, x_2) = \frac{n!}{x_1! \cdot x_2!} \cdot p_1^{x_1} \cdot p_2^{x_2} \quad x_1 + x_2 = n \quad p_1 + p_2 = 1 \quad \text{Binomialverteilung}$$

$$P(x_1, x_2, x_3) = \frac{n!}{x_1! \cdot x_2! \cdot x_3!} \cdot p_1^{x_1} \cdot p_2^{x_2} \cdot p_3^{x_3} \quad \sum x_i = n \quad \sum p_i = 1 \quad \text{Multinomialvert.}$$

$$P(x_{\text{obs}} | H_0) = P(x_1 = 5, x_2 = 2, x_3 = 1) = \frac{8!}{5! \cdot 2! \cdot 1!} \cdot 0.25^5 \cdot 0.5^2 \cdot 0.25^1 = 0.01025$$

```
> x = c(5, 2, 1)
> size = 8
> prob = c(0.25, 0.5, 0.25)
> dmultinom(x, size, prob)
[1] 0.01025391
```

Nullhypothese

"dmultinom"

2 Welche Ereignisse sind extrem?

"observed"	5	2	1
"expected"	2	4	2

$$\chi^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i} = \frac{(5-2)^2}{2} + \frac{(2-4)^2}{4} + \frac{(1-2)^2}{2} = 6$$

Ereignis *i* ist mindestens so extrem wie die Beobachtung wenn $\chi^2 \geq 6$

Die Statistik χ^2 ist bei kleinen Stichproben jedoch **nicht** χ^2 -verteilt !!

Exakter Multinomialtest

1. Finde alle möglichen Zahlentripel $\mathbf{x}=(x_1, x_2, x_3)$ und berechne deren Wahrscheinlichkeiten unter Annahme der Nullhypothese.
2. Finde alle Zahlentripel, die unter H_0 mindestens ebenso extrem wie die Beobachtung $\mathbf{x}=(5,2,1)$ sind und addiere deren Wahrscheinlichkeiten

→ "p-Wert"

$$M = \binom{n+k-1}{k-1} \quad \text{Kombinationen} \quad k = \text{Anzahl der Kategorien}$$

$M = 45$ bei $n=8$ und $k=3$


ExactMultinomialTest-Chisquare.R

Exakter Multinomialtest

```
prob <- c(0.25, 0.5, 0.25) # prob. to draw an element from group 1, 2, or 3 (H0)
chi2_observed = (5-2)^2/2 + (2-4)^2/4 + (1-2)^2/2 # 6

for (x1 in (0:8)) {
  for (x2 in 0:(8-x1)) {
    x3 = 8 - x1 - x2
    counter <- counter + 1
  }
  x <- c(x1, x2, x3)
  p[counter] = dmultinom(x, 8, prob)
  chiswei[counter] = (x1-2)^2/2 + (x2-4)^2/4 + (x3-2)^2/2
  if (chiswei[counter] >= chi2_observed) p.value = p.value + p[counter]
}
```

"ExactMultinomialTest-Chisquare.R"



Mendelsche Experimente

	A	B
A	AA	AB
B	AB	BB



Erwartetes Farbverhältnis: **2 : 4 : 2**
 Beobachtetes Farbverhältnis: **5 : 2 : 1**

Anpassungstest: $p\text{-value} = 0.06 > 0.05$

→ Nullhypothese wird nicht verworfen

... obwohl Beobachtung große Abweichung vom Modell suggeriert

Kleine Stichprobe!



Monte-Carlo-Simulation



- Wahrscheinlichkeiten der Ereignisse unter H_0 "experimentell" ermitteln
 - Viele Stichproben mit $n=8$ Kugeln aus einer Urne mit Kugeln im Farb-Verhältnis 1:2:1
 - Wie häufig kommen $x=(5,2,1)$ oder noch extremere/ebenso extreme Beobachtungen vor?
- p-Wert

	A	B
A	AA	AB
B	AB	BB

RandMultinomialTest-Chisquare.R"



"RandMultinomialTest-Chisquare.R"

MC-Methode




```

chi2g_obs = (5-2)^2/2 + (2-4)^2/4 + (1-2)^2/2 # 6
h0 <- c("red", "red", "brown", "brown", "brown", "brown", "green", "green") # H0
loops = 10000
for (n in 1:loops) {
  stichprobe <- sample(h0, size = 8, replace = TRUE) # sample with replacement H0
  x1 = sum(stichprobe == "red")
  x2 = sum(stichprobe == "brown")
  x3 = sum(stichprobe == "green")
  # zähle Häufigkeit jeder der 45 Kombinationen von x1, x2 und x3
  counter_array[x1+1,x2+1,x3+1] = counter_array[x1+1,x2+1,x3+1] + 1
}
# Summiere die Häufigkeiten aller x-Tripel, zu denen ein chi2 >= 6 gehört: (chi2_observed = 6)


```

Ohne Benutzung der Multinomialverteilung für die x_i !


1.000 simulierte Stichproben




10.000 simulierte Stichproben



100.000 simulierte Stichproben



1.000.000 simulierte Stichproben



Leicht auf höherdimensionale Probleme erweiterbar!

SAS - Code

```
data snapdragons;
  input color $ observed;
  cards;
red 5
pink 2
white 1
;
proc freq data=snapdragons order=data;
  weight observed;
  tables color / chisq testp=(25 50 25);
  exact chisq / mc n=100000;
run;
```

Monte Carlo

SAS - Results

Chi-Square Test
for Specified Proportions

Chi-Square	6.0000	asymptotisch
DF	2	
Asymptotic Pr > ChiSq	0.0498	Chi-square P-value


Monte Carlo Estimate for the Exact Test

Pr >= ChiSq	0.0594	Randomization P-value
99% Lower Conf Limit	0.0575	
99% Upper Conf Limit	0.0613	
Number of Samples	100000	Monte-Carlo




Anpassungstest

Exakter Multinomialtest



Monte-Carlo-Verfahren



$$\chi^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i}$$

$$\chi^2 \in \chi^2(k-1) \quad n \geq 6 \cdot r \cdot c$$

[Pause]



Zwei Therapieformen: Untersuchung

	Patienten
Kontrollgruppe	5
Neue Therapie	7
Gesamt	12



Zwei Therapieformen: Resultat

	gesund	krank	Σ
Kontrollgruppe	2	3	5
Neue Therapie	6	1	7
Σ	8	4	12

- 40% Gesunde in Kontrollgruppe
- 85% Gesunde mit neuer Therapie
- 67% Gesunde insgesamt

Ist der beobachtete Unterschied in den Proportionen
statistisch signifikant ?



Fishers Exakter Test auf Unabhängigkeit




- Nullhypothese: $p_1 = p_2 = p$
 - Die Wahrscheinlichkeit, gesund zu werden ist gleich groß für beide Therapieformen.
 - Gesundheitszustand und Therapieform sind **unabhängig**.
- Alternative Hypothese: $p_1 \neq p_2$
 - Gesundheitszustand und Therapieform sind **abhängig**.

p-Wert

“Wahrscheinlichkeit, bei Gültigkeit der Nullhypothese ein mindestens so extremes Ereignis zu erhalten wie das beobachtete”

→ Wir müssen:

1. die Wahrscheinlichkeiten der Ereignisse unter H_0 berechnen
2. entscheiden, was “extrem” ist



	gesund	krank	
Kontr.	2	3	5
Ther.	6	1	7
	8	4	12

Wahrscheinlichkeit dieser Beobachtung “unter H_0 ”

- H_0 : Wahrscheinlichkeit der Genesung $p = 2/3$ (8 von den 12), unabhängig von Therapieform
- H_0 : Die beobachteten Proportionen kommen durch puren Zufall zustande

$w = 8$
 $s = 4$

$N = 12$ $n = 5$

$$P(w=2) = \frac{\binom{8}{2} \cdot \binom{4}{3}}{\binom{12}{5}}$$

Kontrollgruppe

Wahrscheinlichkeit, dass unter den 5 Ausgewählten genau 2 Weiße sind

Wahrscheinlichkeit “der Tabelle” bei Annahme der Nullhypothese

	gesund	krank		gesund	krank	
Kontr.	2	3	5	a_{11}	a_{12}	Z_1
Ther.	6	1	7	a_{21}	a_{22}	Z_2
	8	4	12	S_1	S_2	N

$$P(a_{11} = 2) = \frac{\binom{8}{2} \cdot \binom{4}{3}}{\binom{12}{5}}$$

$= P(\text{“Tabelle”}) \quad f = 1$

$$P(\text{“Tabelle”}) = \frac{\binom{S_1}{a_{11}} \cdot \binom{S_2}{a_{12}}}{\binom{N}{Z_1}} = \frac{S_1! \cdot S_2! \cdot Z_1! \cdot Z_2!}{N! \cdot a_{11}! \cdot a_{12}! \cdot a_{21}! \cdot a_{22}!}$$


Auch für größere Tabellen !!

“Wahrscheinlichkeit der beobachteten Tabelle” unter der Nullhypothese

	
...	2	3	5
...	6	1	7
	8	4	12

$$P(\text{“Tabelle”}) = \frac{S_1! \cdot S_2! \cdot Z_1! \cdot Z_2!}{N! \cdot a_{11}! \cdot a_{12}! \cdot a_{21}! \cdot a_{22}!} = \frac{8! \cdot 4! \cdot 5! \cdot 7!}{12! \cdot 2! \cdot 3! \cdot 6! \cdot 1!} = \frac{14}{99} = 0.141414$$

Hypergeometrische Verteilung



Calc / Probability Distributions

Hypergeometric with N = 12, M = 8, and n = 5

x	P(X = x)
2	0.141414


Fisher's Exakter Test: p-value

1. Finde alle "möglichen" Tabellen und berechne deren Wahrscheinlichkeiten unter Annahme der Nullhypothese.
 2. Addiere die Wahrscheinlichkeiten der Tabellen, die mindestens so extrem von der Nullhypothese abweichen wie die beobachtete Tabelle.
- "p-Wert"

	
...	2	3	5
...	6	1	7
	8	4	12

a_{12} kann zwischen 0 und 4 variieren → 5 mögliche Tabellen

Berechnung der χ^2 -Statistik für alle Tabellen



Chi2_Fisher.MPJ

χ^2 , Δp und p für alle Tabellen

Tabelle	χ^2	Δp	P									
<table border="1"><tr><td>5</td><td>0</td><td>5</td></tr><tr><td>3</td><td>4</td><td>7</td></tr><tr><td>8</td><td>4</td><td>12</td></tr></table>	5	0	5	3	4	7	8	4	12	4,286	33%	0,070707
5	0	5										
3	4	7										
8	4	12										
<table border="1"><tr><td>4</td><td>1</td><td>5</td></tr><tr><td>4</td><td>3</td><td>7</td></tr><tr><td>8</td><td>4</td><td>12</td></tr></table>	4	1	5	4	3	7	8	4	12	0,686	13%	0,353535
4	1	5										
4	3	7										
8	4	12										
<table border="1"><tr><td>3</td><td>2</td><td>5</td></tr><tr><td>5</td><td>2</td><td>7</td></tr><tr><td>8</td><td>4</td><td>12</td></tr></table>	3	2	5	5	2	7	8	4	12	0,171	-7%	0,424242
3	2	5										
5	2	7										
8	4	12										
<table border="1"><tr><td>2</td><td>3</td><td>5</td></tr><tr><td>6</td><td>1</td><td>7</td></tr><tr><td>8</td><td>4</td><td>12</td></tr></table>	2	3	5	6	1	7	8	4	12	2,743	-27%	0,141414
2	3	5										
6	1	7										
8	4	12										
<table border="1"><tr><td>1</td><td>4</td><td>5</td></tr><tr><td>7</td><td>0</td><td>7</td></tr><tr><td>8</td><td>4</td><td>12</td></tr></table>	1	4	5	7	0	7	8	4	12	8,4	-47%	0,010101
1	4	5										
7	0	7										
8	4	12										

$$\chi^2 = \sum_{i,j=1}^2 \frac{(O_{ij} - E_{ij})^2}{E_{ij}}$$

$$E_{ij} = \frac{S_i \cdot Z_j}{n}$$

$$\Delta p = p_{obs} - p_{exp}$$

$$= p_{obs} - 0,67$$

$$P(\text{"table"}) = \frac{S_1! \cdot S_2! \cdot Z_1! \cdot Z_2!}{N! \cdot a_{11}! \cdot a_{12}! \cdot a_{21}! \cdot a_{22}!}$$

χ^2 -Berechnung: Erwartete Frequenzen bei Unabhängigkeit

	gesund	krank	
Kontr.	E_{11}	...	5
Ther.	E_{21}	...	7
	8	4	12

	gesund	krank	
Kontr.	E_{11}	E_{12}	Z_1
Ther.	E_{21}	E_{22}	Z_2
	S_1	S_2	n

$$\frac{E_{11}}{5} = \frac{8}{12}$$

$$\frac{E_{11}}{Z_1} = \frac{S_1}{n} \Rightarrow E_{11} = \frac{S_1 \cdot Z_1}{n}$$

$$\frac{E_{21}}{7} = \frac{8}{12}$$

$$E_{ij} = \frac{S_i \cdot Z_j}{n}$$

"Wahrscheinlichkeit aller Tabellen" unter H_0

$$P(\text{"Tabelle"}) = \frac{S_1! \cdot S_2! \cdot Z_1! \cdot Z_2!}{N! \cdot a_{11}! \cdot a_{12}! \cdot a_{21}! \cdot a_{22}!}$$

5	0	5
3	4	7
8	4	12

P = 0,070707

4	1	5
4	3	7
8	4	12

P = 0,353535

3	2	5
5	2	7
8	4	12

P = 0,424242

2	3	5
6	1	7
8	4	12


P = 0,141414

1	4	5
7	0	7
8	4	12

P = 0,010101

$$p\text{-Wert} = 0,141 + 0,071 + 0,01 = 0,222$$

Schlechte Versuchsplanung ?




Hypergeometric with N = 12, M = 4, and n = 5

x	P(X = x)
0	0,070707
1	0,353535
2	0,424242
3	0,141414
4	0,010101



Fishers Exakter Test



Test for difference = 0 (vs not = 0): $Z = -1,79$ P-Value $\approx 0,074$
 Fisher's exact test: P-Value = 0,222
 * NOTE * The normal approximation may be inaccurate for small samples.

Fishers Exakter Test



```

C:\Users\Uwe\Desktop\Magdeburg_Talk\FisherExact.R - R Editor

Kreuztabelle <- matrix(c(2, 3, 6, 1), byrow = TRUE, nrow = 2, dimnames = list
# > Kreuztabelle
#           Behandlung
# Zustand  Kontroll Therapie
# gesund   2      6
# krank    3      1

fisher.test(Kreuztabelle, alternative = "two.sided", conf.int = TRUE, conf.l
    
```

Fisher's Exact Test for Count Data
 data: Kreuztabelle
 p-value = 0.2222

"FisherExact.R"

Vergleich zweier Therapieformen

	gesund	krank	
Kontrollgruppe	2	3	5
Neue Therapie	6	1	7
	8	4	12



p-value = 0,222

- 40% Gesunde in Kontrollgruppe
- 85% Gesunde mit neuer Therapie

- Die Nullhypothese wird **nicht** verworfen.
- **Unterschied** zwischen den Genesungsraten in beiden Gruppen **nicht statistisch signifikant** ... trotz der "überzeugenden" Prozentangaben
- **Kleine Stichprobe !**

Fisher Exact

Kleine / große Stichprobe

	gesund	krank	
Kontr.	2	3	5
Neu	6	1	7
	8	4	12

	gesund	krank	
Kontr.	200	300	500
Neu	600	100	700
	800	400	1200

- 40% Gesunde in Kontrollgruppe
- 85% Gesunde mit neuer Therapie

p-value = 0,222

p-value = 0,000

Signifikanztests bei kleinen Stichproben

- Intuition oft kein guter Ratgeber
 - Prozent- oder andere Angaben können irreführend sein
- Sorgfältige Versuchsplanung: - "Size does matter"

Vorsicht Falle!



Anhang

1. Sign-Test (Wollen Mäuse einen eigenen Spiegel?)
2. Chisquare-Test
3. Binomialtest und Fishers Exakter Test in SAS, SPSS
4. Methoden zum Testen von Hypothesen
5. Normalapproximation für den binomischen Test
6. p-Wert: Welche Werte sind extremer als die Beobachtung?

Sign-Test



John Arbuthnot
Born: April 1667 in
Inverbervie, Kincardine,
Scotland

Arbuthnot continued his scientific work submitting a paper to the Royal Society in 1710 discussing the **slight excess of male births over female births** in the years from 1629 to 1710. This paper, published in the *Philosophical Transactions*, is perhaps the first application of probability to social statistics and includes the **first formal test of significance**. In this paper Arbuthnot claims to demonstrate that divine providence, not chance, governs the sex ratio at birth.

Wollen Mäuse einen eigenen Spiegel?

- 16 Mäuse, alle Käfige mit 2 Räumern: einen mit Spiegel und einen ohne Spiegel
- **Beobachtung:** In welchem Raum hält sich die Maus am meisten auf?



Maus	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
mit		x					x				x					
ohne	x		x	x	x	x		x	x	x		x	x	x	x	x

Sherwin, C.M. 2004. Mirrors as potential environmental enrichment for individually housed laboratory mice. Appl. Anim. Behav. Sci. 87: 95-103.

Wollen Mäuse einen eigenen Spiegel?

$$H_0: p = 0.5 \quad H_a: p \neq 0.5$$

Stichprobe: $M = 3$

$$M \in \text{Bin}(16, 0.5) \quad \text{unter } H_0$$

$$p = P(M \leq 3) + P(M \geq 13) \quad \text{symmetrisch } (p = 0.5)$$

$$= P(M \leq 3) + 1 - P(M \leq 12)$$

$$= 0.0106 + 1 - 0.9894 = 0.0212$$

Die Nullhypothese (kein Raum bevorzugt, $p=0.5$) wird verworfen. Mäuse bevorzugen ... keinen Spiegel zu haben.

Sign-Test: Vergleich

Maus	Zeit mit Spiegel	ohne Spiegel
1	3	21
2	8	16
3	9	15
...

Bei Vorliegen konkreter Daten und unter der Voraussetzung, dass diese **normalverteilt** sind, ist der **t-Test** für gepaarte Stichproben besser.

Maus	Zeit mit Spiegel	ohne Spiegel
1	3	21
2	8	16
3	9	15
...

Bei Vorliegen konkreter Daten ist der verteilungsfreie **Rangsummentest** für gepaarte Stichproben besser.

Chisquare-Test

"observed"	5	2	1
"expected"	2	4	2



Unsere Stichprobe ist zu klein!

$$\chi^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i} = \frac{(5-2)^2}{2} + \frac{(2-4)^2}{4} + \frac{(1-2)^2}{2} = 6$$


$$\chi^2 \in \chi^2(f) \quad \text{mit } f = k - 1 \quad \text{wenn } E_i \geq 5$$

Nicht anwendbar! (würde $p = 0.0498$ liefern)


$$\Omega_{krit} = \{ \chi^2 > \chi_{0.05}^2(2) \} = \{ \chi^2 > 5.99 \}$$

Minitab, Stat / Tables / Chi-square Goodness of Fit

Chisquare Goodness-of-Fit



Chisquare Goodness-of-Fit



Minitab: Stat / Tables / Chi-square Goodness of Fit

Chisquare Goodness-of-Fit


Chi-Square Goodness-of-Fit Test for Observed Counts in Variable: OBS

Category	Historical Observed	Test Counts	Proportion	Contribution	Expected
1	5	2	0,25	2	4,5
2	2	4	0,50	4	1,0
3	1	2	0,25	2	0,5

N DF Chi-Sq P-Value
8 2 6 0,050

3 cell(s) (100,00%) with expected value(s) less than 5.

Chisquare Goodness-of-Fit



SAS: Exact binomial test

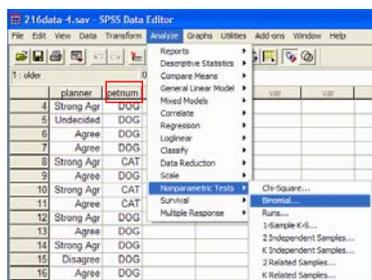
```
proc freq data = "C:\Users\Uwe\btst ";
tables female / binomial (p=.5) ;
exact binomial;
run;
```

Null hypotheses

Test whether the proportions of females ("female") differs significantly from 50%

id	female	race	ses	schtyp	prog
1	70	0	4	1	1
2	121	1	4	2	1
3	86	0	4	3	1
4	141	0	4	3	1
5	172	0	4	2	1
6	113	0	4	2	1
7	50	0	3	2	1
8	11	0	1	2	1
9	84	0	4	2	1
10	48	0	3	2	1

SPSS: Exact binomial test



Preferred Pet	Group	Category	N	Observed Prop.	Test Prop.	Asymp. Sig. (2-tailed)
Group 1	DOG		38	.83	.50	.000*
Group 2	CAT		8	.17		
Total			46	1.00		

$np(1-p)=11,5$

Fishers Exakter Test in SAS

SAS automatically does Fisher's exact test for 2x2 tables. For greater numbers of rows or columns, you add a line saying exact chisq;. Here is an example using the data on heron and egret substrate use from above:

```
data birds;
input bird $ substrate $ count;
cards;
heron vegetation 15
heron shoreline 20
heron water 14
heron structures 6
egret vegetation 8
egret shoreline 5
egret water 7
egret structures 1
;
proc freq data=birds;
weight count / zeros;
tables bird*substrate / chisq;
exact chisq;
run;
```

$2 \times 4 \rightarrow f = 3$

The results of the exact test are labelled "Exact Pr >= ChiSq"; in this case, P=0.5357.


Pearson Chi-Square Test	
Chi-Square	2.2812
DF	3
Asymptotic Pr > ChiSq	0.5161
Exact Pr >= ChiSq	0.5357

A) Möglichkeiten zur Durchführung von Hypothesentests

- A-priori-Festlegung des Signifikanzniveaus
 - Verteilung der Teststatistik ("T") unter H_0 ermitteln (Parameter: μ_0)
 - Signifikanzniveau α festlegen ($5\% \rightarrow \alpha = 0.05$)
 - Ablehnungsbereich (kritischen Bereich) ermitteln
 - Stichprobe \rightarrow realisierten Wert der Teststatistik ("t") errechnen
 - Verwerfen der Nullhypothese wenn t im kritischen Bereich

$$\frac{\bar{X} - \mu_0}{s/\sqrt{n}} \in t(n-1)$$

$$\Omega_{krit} = \left\{ t : |t| \geq t_{\frac{\alpha}{2}}(n-1) \right\}$$




B) Möglichkeiten zur Durchführung von Hypothesentests

- Verwendung des p-Wertes
 - Verteilung der Teststatistik ("T") unter H_0 ermitteln (Parameter: μ_0)
 - Stichprobe
 - Berechnung des realisierten Wertes "t" der Teststatistik
 - Berechnung des p-Wertes auf Grundlage dieses Wertes
 - Verwerfen der Nullhypothese wenn p-Wert klein

$$\frac{\bar{X} - \mu_0}{s/\sqrt{n}} \in t(n-1)$$

$$t = \frac{\bar{x}_{obs} - \mu_0}{s/\sqrt{n}} \quad p = P(\text{abs}(T) \geq t \mid H_0)$$





C) Möglichkeiten zur Durchführung von Hypothesentests

- Konfidenzintervall benutzen
 - Nullhypothese: Parameter μ_0
 - Stichprobe
 - Schätzwert für wahren Verteilungsparameter und KI berechnen
 - H_0 wenn μ_0 außerhalb der Grenzen des KI liegt
 - (95% Konfidenzintervall entspricht 5% Signifikanzniveau)

$$P\left(-t_{\frac{\alpha}{2}}(n-1) < \frac{\bar{X} - \mu_0}{s/\sqrt{n}} \leq t_{\frac{\alpha}{2}}(n-1)\right) = 1 - \alpha$$


$$P\left(\bar{X} - t_{\frac{\alpha}{2}}(n-1) \cdot \frac{s}{\sqrt{n}} < \mu_0 \leq \bar{X} + t_{\frac{\alpha}{2}}(n-1) \cdot \frac{s}{\sqrt{n}}\right) = 1 - \alpha$$



Normalapproximation für den Exakten Binomialtest



Vergleich mit Normalapproximation




Zentraler Grenzwertsatz



[Moivre-Laplace]



$$Z = \frac{X - n \cdot p}{\sqrt{n \cdot p \cdot (1-p)}} \in N(0, 1)$$




$$p\text{-value} = 0,0112 + 0,0112 = 0,0224 < 0,05$$

Symmetrie ! (p=0,4)

Tabell 1. Standard normalfördelning

$\Phi(x) = P(X \leq x)$, där $X \in N(0, 1)$.
För negativa x , utnyttja att $\Phi(-x) = 1 - \Phi(x)$



x	.00	.01	.02	.03	.04	.05	.06	.07	.08
0.0	.5000	.5040	.5080	.5120	.5160	.5199	.5239	.5279	.5311
0.1	.5398	.5438	.5478	.5517	.5557	.5596	.5636	.5675	.5711
0.2	.5793	.5832	.5871	.5910	.5948	.5987	.6026	.6064	.6101
0.3	.6179	.6217	.6255	.6293	.6331	.6368	.6406	.6443	.648
0.4	.6554	.6591	.6628	.6664	.6700	.6736	.6772	.6808	.684
0.5	.6915	.6950	.6985	.7019	.7054	.7088	.7123	.7157	.719
0.6	.7257	.7291	.7324	.7357	.7389	.7422	.7454	.7486	.751
0.7	.7580	.7611	.7642	.7673	.7704	.7734	.7764	.7794	.782
0.8	.7881	.7910	.7939	.7967	.7995	.8023	.8051	.8078	.81
0.9	.8159	.8186	.8212	.8238	.8264	.8289	.8315	.8340	.83
1.0	.8413	.8438	.8461	.8485	.8508	.8531	.8554	.8577	.85
1.1	.8643	.8665	.8686	.8708	.8729	.8749	.8770	.8790	.88
1.2	.8849	.8869	.8888	.8907	.8925	.8944	.8962	.8980	.89
1.3	.9032	.9049	.9066	.9082	.9099	.9115	.9131	.9147	.91
1.4	.9192	.9207	.9222	.9236	.9251	.9265	.9279	.9292	.93
1.5	.9332	.9345	.9357	.9370	.9382	.9394	.9406	.9418	.94
1.6	.9452	.9463	.9474	.9484	.9495	.9505	.9515	.9525	.95
1.7	.9554	.9564	.9573	.9582	.9591	.9599	.9608	.9616	.96
1.8	.9641	.9649	.9656	.9664	.9671	.9678	.9686	.9693	.96
1.9	.9713	.9719	.9726	.9732	.9738	.9744	.9750	.9756	.97
2.0	.9772	.9778	.9783	.9788	.9793	.9798	.9803	.9807	.98
2.1	.9824	.9827	.9830	.9834	.9838	.9842	.9846	.9850	.98
2.2	.9861	.9864	.9867	.9871	.9874	.9878	.9880	.9884	.98
2.3	.9892	.9895	.9898	.9901	.9903	.9906	.9908	.9911	.99
2.4	.9918	.9920	.9922	.9924	.9925	.9926	.9928	.9930	.99
2.5	.9937	.9939	.9941	.9943	.9944	.9946	.9947	.9949	.99
2.6	.9953	.9954	.9956	.9957	.9958	.9959	.9960	.9961	.99

$X \in Bin(n, p) \quad E(X) = n \cdot p = 8 \quad V(X) = n \cdot p \cdot (1 - p)$

$X \in N(n \cdot p, \sqrt{n \cdot p \cdot (1 - p)}) \quad n \cdot p \cdot (1 - p) > 10$



$p = 1 - P(3 < X \leq 13) = 1 - [F_x(13) - F_x(3)]$ F_x für N statt für Bin

$= 1 - \left[\Phi\left(\frac{13.5 - n \cdot p}{\sqrt{n \cdot p \cdot (1 - p)}}\right) - \Phi\left(\frac{3.5 - n \cdot p}{\sqrt{n \cdot p \cdot (1 - p)}}\right) \right]$ Kontinuumskorrektur

$= 1 - \left[\Phi\left(\frac{13.5 - 8}{2.191}\right) - \Phi\left(\frac{3.5 - 8}{2.191}\right) \right]$

$= 1 - [\Phi(2.51) - \Phi(-2.054)] = 1 - \Phi(2.51) + \Phi(-2.054)$ Φ(-a) = 1 - Φ(a)

$= 1 - \Phi(2.51) + 1 - \Phi(2.054)$

$= 2 - 0.99396 - 0.98 = 0.026$

Software



Test of p = 0.4 vs p not = 0.4

Sample	X	N	Sample p	95% CI	Z-Value	P-Value
1	3	20	0.150000	(0.000000; 0.306491)	-2.28	0.022

*Using the normal approximation.
The normal approximation may be inaccurate for small samples.*

p-Wert-Berechnung: Welche Werte sind extremer als die Beobachtung ?

1. x_i ist extremer als die Beobachtung x_{obs} , wenn:

$$p(x_i) \leq p_i(x_{obs})$$

ODER

2. x_i ist extremer als die Beobachtung x_{obs} , wenn:

$$\chi^2(x_i) \geq \chi^2(x_{obs})$$

p-Wert-Berechnung: Welche Werte sind extremer als die Beobachtung ?

1. Solche, die eine kleinere Wahrscheinlichkeit als die Beobachtung haben:

$$p\text{-value} = \sum_{p(x_i) \leq p_i(x_{obs})} p(x_i)$$

ODER


2. Solche, die einen größeren χ^2 -Wert als die Beobachtung haben:

$$p\text{-value} = \sum_{\chi^2(x_i) \geq \chi^2(x_{obs})} p(x_i)$$

Mit $\chi^2 > \chi^2_{observed}$

Exact Multinomial Test (χ^2)

$n = 8 \quad k = 3 \quad p\text{-value} = 0.0596$



p-Wert-Berechnung: Welche Werte sind extremer als die Beobachtung?
 Farbbeispiel 1:2:1

Beobachtung: (5,2,1) Expectation: (2,4,2)

$$p(x_i) \leq p_i(x_{obs}) \quad \text{Kriterium, als extrem angesehen zu werden}$$

$$p(5,2,1) = 0.01025 \quad p(4,1,3) = 0.008544 \quad p(3,1,4) = 0.008544$$


(4,1,3) und (3,1,4) sind extremer!!

ODER

$$\chi^2(x_i) \geq \chi^2(x_{obs}) \quad \text{Kriterium, als extrem angesehen zu werden}$$

$$\chi^2(5,2,1) = 6 \quad \chi^2(4,1,3) = 4.75 \quad \chi^2(3,1,4) = 4.75$$

→ (4,1,3) und (3,1,4) sind nicht extremer!!



Vergleich der Methoden

- "Kleine Wahrscheinlichkeiten": $p = 0.0767$
- "Chi-quadrat": $p = 0.05957$
- $0.05957 + 2 \cdot 0.008544 = 0.0767$
- Die beiden Punkte erklären den Unterschied

Anderes Kriterium: Abstände

$$A = |O_1 - E_1| + |O_2 - E_2| + |O_3 - E_3| \quad \text{"Abstand"}$$

$$A_{obs} = |5 - 2| + |2 - 4| + |1 - 2| = 6 \quad \text{Abstand der Beobachtung}$$

$$A_{4,1,3} = |4 - 2| + |1 - 4| + |3 - 2| = 6 \quad \text{Abstand von (4,1,3) und (3,1,4)}$$

Nach diesem Kriterium werden die beiden Punkte genauso extrem, und würden damit dem größeren p-Wert entsprechen.