



Kategorielle Daten

Phase 3 Studie: Wirksamer als Placebo ?

	Medikament	Placebo	Total
Geheilt	15	9	24
Nicht geheilt	10	11	21
Total	25	20	45

Grundfrage: Sind "Heilung" und "Medikamentengabe" unabhängig ?

Statistische Tests für Tabellen

- **Fisher's Exact Test:** 2 x 2 Tabellen
Verteilung der Teststatistik **exakt**
- **Chi-Quadrat Test:** m x n Tabellen
Verteilung der Teststatistik **asymptotisch** bekannt
- **Logistische Regression:** 2 x m Tabellen;
auch Mix aus mehreren kontinuierlichen und kategoriellen erklärenden Variablen möglich
Verteilung der Teststatistik **asymptotisch** bekannt
Multiple oder einfache ?

Wdh: Hypergeometrische Verteilung

- Situation: Urne mit N Kugeln; m sind markiert; ziehen n Kugeln ohne Zurücklegen; wie viele markierte Kugeln?
- ZV X : Anzahl markierter gezogener Kugeln

- $X \sim \text{Hyper}(N, n, m)$



“ X ist hypergeometrisch verteilt mit Parametern N , n und m ”

- $P(X = x) = \frac{\binom{m}{x} \binom{N-m}{n-x}}{\binom{N}{n}}$ ← ‘günstig’, $x \in \{0, 1, \dots, \min(n, m)\}$
 ← ‘möglich’

- $E(X) = \frac{n \cdot m}{N}$, $Var(X)$ kompliziert; siehe z.B. Wikipedia

Hyper(15,10,10)

Hyper(15,10,10)



Bsp: Phase 3 Studie – Wirksamer als Placebo?

- Doppel-blinde, randomisierte Studie

Gezogene und markierte Bälle

	Medikament	Placebo	Total
Geheilt	15	9	24
Nicht geheilt	10	11	21
Total	25	20	45

Gezogene Bälle (n)

Markierte Bälle (m)

Bälle in Urne (N)

- Falls Medikament keine Wirkung hat: Es gibt 24 Personen, bei denen unabhängig von der Gruppenteilung fest steht, dass sie gesund werden

➔ Urnenmodell

Fisher's Exact Test: Spalten und Zeilen unabhängig ?

	Medikament	Placebo	Total
Geheilt	15	9	24
Nicht geheilt	10	11	21
Total	25	20	45

- ZV X : Anzahl geheilter Patienten in Medikamenten-Gruppe
- Falls Medikament keine Wirkung hat:

$$X \sim \text{Hyper}(N = 45, m = 24, n = 25)$$

- Ist es dann plausibel in der Medikamenten-Gruppe 15 oder mehr geheilte Patienten zu beobachten?
- $P(X \geq 15) = 1 - P(X \leq 14) = 1 - 0.76 = 0.24$ P-Wert
- Falls das Medikament nicht wirkt, ist es durchaus plausibel 15 oder mehr geheilte Patienten in der Medikamentengruppe zu beobachten

R: phyper(14,24,21,25)

Wdh: Odds und Odds-Ratio

	Medikament	Placebo	Total
Geheilt	15	9	24
Nicht geheilt	10	11	21
Total	25	20	45

Alternative Beschreibung von Wahrscheinlichkeiten

- $\text{Odds}(A) = P(A) / (1 - P(A))$
- $P(A) = \text{Odds}(A) / (1 + \text{Odds}(A))$
- $\text{Log-Odds}(A) = \log(\text{Odds}(A))$

Wirksamkeit von Medikament
kann mit Odds-ratio
ausgedrückt werden

$$\text{Odds}(\text{Geheilt}) = (24/45) / (21/45) = 24/21 = 1.14$$

$$\text{Odds}(\text{Geheilt mit Medi}) = (15/25) / (10/25) = 15/10 = 1.5$$

$$\text{Odds}(\text{Geheilt ohne Medi}) = (9/20) / (11/20) = 9/11 = 0.82$$

$$\text{Odds-ratio: Odds}(\text{Geheilt mit Medi}) / \text{Odds}(\text{Geheilt ohne Medi}) = 1.5 / 0.82 = 1.83$$



Fisher's Exact Test in R

```
> m <- matrix(c(15,10,9,11),2,2)
> m
      [,1] [,2]
[1,]   15   9
[2,]   10  11
> fisher.test(m, alternative = "greater")
```

Einseitige Alternative:
Grössere Macht ein wirksames
Medikament zu finden
Blind für unwirksame Medikamente

Fisher's Exact Test for Count Data

```
data: m
p-value = 0.2416
alternative hypothesis: true odds ratio is greater than 1
95 percent confidence interval:
 0.5753718      Inf
sample estimates:
odds ratio
 1.808415
```

P-Wert

Einseitiges 95%-Vertrauensintervall
für Odds-ratio

Odds-ratio

R verwendet spezielle numerische Methoden um das Odds ratio zu bestimmen;
es kann daher leichte Unstimmigkeiten zur Berechnung von Hand geben

Statistische Tests für Tabellen

- **Fisher's Exact Test:** 2 x 2 Tabellen
Verteilung der Teststatistik **exakt**
- **Chi-Quadrat Test:** m x n Tabellen
Verteilung der Teststatistik **asymptotisch**
- **Logistische Regression:** 2 x m Tabellen;
auch Mix aus mehreren kontinuierlichen und kategoriellen erklärenden Variablen möglich
Verteilung der Teststatistik **asymptotisch**
Multiple oder einfache ?


Chi-Quadrat Test: Spalten und Zeilen unabhängig?

- Haar- und Augenfarbe (R: ?HairEyeColor)

Hair / Eye	Brown	Blue	Hazel	Green	Total
Black	68	20	15	5	108
Brown	119	84	54	29	286
Red	26	17	14	14	71
Blond	7	94	10	16	127
Total	220	215	93	64	592

- Mögliche Fragen:
 - Visualisierung (v.a. wenn mehr als 2 Kategorien)
 - Abhängigkeit? Wo?

Visualisierung kategorischer Daten: Mosaic Plot



Hair / Eye	Brown	Blue	Hazel	Green	Total
Black	68	20	15	5	108
Brown	119	84	54	29	286
Red	26	17	14	14	71
Blond	7	94	10	16	127

Fläche proportional
zu Tabelleneintrag

Chi-Quadrat Test

“observed values”

$$O_{ij} = n_{ij}$$

	A=1	...	A=n	Total
B=1	n_{11}		n_{1n}	n_{1*}
...				
B=m	n_{m1}		n_{mn}	n_{m*}
Total	n_{*1}		n_{*n}	n

H_0 : A, B sind **unabhängig**

$$P(A = i \cap B = j) = P(A = i) * P(B = j) \approx \hat{P}(A = i) * \hat{P}(B = j) = \frac{n_{*i}}{n} * \frac{n_{j*}}{n}$$

Erwartungswert der Zelle falls H_0 stimmt: $E_{ij} = n * \frac{n_{*i}}{n} * \frac{n_{j*}}{n} = \frac{n_{*i} n_{j*}}{n}$

Chi-Quadrat Test

	A=1	...	A=n	Total
B=1	n_{11}		n_{1n}	n_{1*}
...				
B=m	n_{m1}		n_{mn}	n_{m*}
Total	n_{*1}		n_{*n}	n

Wie verschieden sind beobachtete und erwartete Werte?

Verbreitet: **Pearson Chi-Quadrat Statistik**

$$X^2 = \sum_{i=1}^n \sum_{j=1}^m \frac{(O_{ij} - E_{ij})^2}{E_{ij}} = \sum_{i=1}^n \sum_{j=1}^m R_{ij}^2$$

Falls H_0 stimmt, folgt X^2 einer Chi-Quadrat Verteilung mit $(I-1)(J-1)$ Freiheitsgraden (falls n gross – s. nächste slide).

→ p-Werte

Pearson Residuen

$$R_{ij} = \frac{O_{ij} - E_{ij}}{\sqrt{E_{ij}}}$$

Beitrag jeder Zelle zur Modellabweichung




Wie gross ist E_{11} ?

	A=1	A=2	Total
B=1	4	8	12
B=2	6	3	9
Total	10	11	21

1. $E_{11} = 5.7$
2. $E_{11} = 4$
3. $E_{11} = 0.4$
4. $E_{11} = 0.33$
5. $E_{11} = 0.19$

Chi-Quadrat Test: Wann ist Approximation gut ?

- Faustregel:



$E_{ij} < 1$ für mind. ein Tabellenfeld → ungenügend

$E_{ij} > 1$ für alle Tabellenfelder i,j → gerade noch OK

$E_{ij} > 5$ für alle Tabellenfelder i,j → sehr gut

- Falls Faustregel nicht erfüllt:
 - Kategorien zusammenfassen
 - anderen Test verwenden (z.B. Fisher-Test mit Simulation)



Chi-Quadrat Test in R

```
> chisq.test(tab)
```

```
Pearson's Chi-squared test
```

```
data: tab
```

```
X-squared = 138.2898, df = 9, p-value < 2.2e-16
```

$$1 - pchisq(q = 138.2898, df = 9)$$


$$\sum_{i=1}^n \sum_{j=1}^m R_{ij}^2$$

$$(4 - 1) * (4 - 1) = 9$$



Mosaic plot mit Shading: Integrierter Chi-Quadrat Test


Sehr grosser
Tabelleneintrag



Sehr kleiner
Tabelleneintrag

Farbe falls
Pearson Residuen
ausserhalb $[-2, 2]$

Pearson
residuals:



p-value =
< 2.22e-16

p-Wert des
Chi-Quadrat
Tests

Statistische Tests für Tabellen



- **Fisher's Exact Test:** 2 x 2 Tabellen
Verteilung der Teststatistik **exakt**
- **Chi-Quadrat Test:** m x n Tabellen
Verteilung der Teststatistik **asymptotisch**
- **Logistische Regression:** 2 x m Tabellen;
auch Mix aus mehreren kontinuierlichen und kategoriellen erklärenden Variablen möglich
Verteilung der Teststatistik **asymptotisch**
Multiple oder einfache ?

Logistische Regression

- $Y \sim \text{Bin}(n, p(x))$

$$\log\left(\frac{p(x)}{1-p(x)}\right) = \beta_0 + \beta_1 x$$

- Bsp: Dosis 0, 1, 2, ..., 9, 10; je 30 kranke Tiere
Y: Anzahl genesener Tiere



```
glm(cbind(y, n-y) ~ dosis, data = dat, family = binomial)
```

Dosis=0 → log-odds = $\beta_0 = -4.29$

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-4.29356	0.46067	-9.320	<2e-16
dosis	0.74103	0.07601	9.749	<2e-16

Wenn man Dosis um eine Einheit erhöht,
erhöhen sich die log-odds um $\beta_1 = 0.74$
95%-VI: $0.74 \pm 2 \cdot 0.076$

Logistische Regression: Interpretation

- Wenn man Dosis um eine Einheit erhöht, erhöhen sich die log-odds um $\beta_1 = 0.74$
95%-VI: $0.74 \pm 2 \cdot 0.076$, d.h. $[0.588; 0.892]$

oder äquivalent

- Wenn man Dosis um eine Einheit erhöht, erhöhen sich die odds um den Faktor $\exp(\beta_1) = 2.10$
95%-VI: $[\exp(0.588); \exp(0.892)] = [1.80; 2.44]$

Genesungswahrscheinlichkeit

Wie gross ist die Genesungswa., wenn die Dosis 10 ist ?

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-4.29356	0.46067	-9.320	<2e-16
dosis	0.74103	0.07601	9.749	<2e-16

- | | |
|----|------|
| 1. | 0.96 |
| 2. | 0.04 |
| 3. | 0.37 |
| 4. | 0.63 |

Einfache oder Multiple Regression

(Gilt für alle GLMs; hier am Bsp der linearen Regression)

- Einfache Regression:
“Totaler Effekt”
 $y \sim x \rightarrow$ “Wenn sich x um eine Einheit erhöht, erhöht sich y um β_1 ”
- Multiple Regression
“Bereinigter Effekt”
 $y \sim x_1 + x_2 \rightarrow$ “Wenn sich x_1 um eine Einheit erhöht **und x_2 konstant bleibt**, erhöht sich y um β_1 .”
- Kein “richtig” oder “falsch”; eher zwei verschiedene Sichtweisen auf das gleiche Problem

Vorteil von Multipler Regression

- Andere Einflüsse werden ausgeschaltet

Bsp: Diskriminierung

- Einfache Regression:
Zulassung \sim Geschlecht
- Multiple Regression:
Zulassung \sim Geschlecht + Job

Berühmtes Beispiel: Simpson's Paradox

Simpson's Paradox

(Bsp: Aufgenommene Studenten an der UC Berkeley in 1973; nur 6 grösste Departemente)

	Angenommen	Abgelehnt
Männer	1198	1493
Frauen	557	1278

Werden Frauen benachteiligt?



Methodenvergleich

- Fisher Test
- Chi-Quadrat Test (mit Mosaikplot)
- (einfache) Logistische Regression

```
> head(dfUCB)
  Admit Gender Dept Freq
1 Admitted Male   A  512
2 Rejected Male   A  313
3 Admitted Female A   89
4 Rejected Female A   19
5 Admitted Male   B  353
6 Rejected Male   B  207
...

```

```
> fm1 <- glm(Admit ~ Gender, weights = Freq, family = binomial, data = dfUCB)
> summary(fm1)

Call:
glm(formula = Admit ~ Gender, family = binomial, data = dfUCB,
     weights = Freq)

Deviance Residuals:
    Min       1Q   Median       3Q      Max
-28.787  -14.662   -1.781   15.244   20.336

Coefficients:
              Estimate Std. Error z value Pr(>|z|)
(Intercept)   0.22013    0.03879   5.675 1.38e-08 ***
GenderFemale  0.61035    0.06389   9.553 < 2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

> exp(confint(fm1))
              2.5 %    97.5 %
(Intercept)  1.155124  1.344836
GenderFemale  1.624956  2.087499

```

```
> exp(confint(fm1))
waiting for profiling to be done...
              2.5 %    97.5 %
(Intercept)  1.155124  1.344836
GenderFemale  1.624956  2.087499

```

Frauen benachteiligt ?

Simpson's Paradox

(Bsp: Aufgenommene Studenten an der UC Berkeley in 1973)

Dept	Männer		Frauen	
	Bew.	Akz.	Bew.	Akz.
A	825	62%	108	82%
B	560	63%	25	68%
C	325	37%	593	34%
D	417	33%	375	35%
E	191	28%	393	24%
F	373	6%	341	7%

Simpson's Paradox

(Bsp: Aufgenommene Studenten an der UC Berkeley in 1973)

Dept	Männer		Frauen	
	Bew.	Akz.	Bew.	Akz.
A	825	62%	108	82%
B	560	63%	25	68%
C	325	37%	593	34%
D	417	33%	375	35%
E	191	28%	393	24%
F	373	6%	341	7%

Simpson's Paradox

(Bsp: Aufgenommene Studenten an der UC Berkeley in 1973)

Dept	Männer		Frauen	
	Bew.	Akz.	Bew.	Akz.
A	825	62%	108	82%
B	560	63%	25	68%
C	325	37%	593	34%
D	417	33%	375	35%
E	191	28%	393	24%
F	373	6%	341	7%

Nein: Frauen bewerben sich mehr bei „schwierigen“ Departments!



Bereinigter Effekt: Logistische Regression

```
glm(formula = Admit ~ Gender + Dept, family = binomial, data = dfUCB,  
     weights = Freq)
```

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-0.58205	0.06899	-8.436	<2e-16
GenderFemale	-0.09987	0.08085	-1.235	0.217
DeptB	0.04340	0.10984	0.395	0.693
DeptC	1.26260	0.10663	11.841	<2e-16
DeptD	1.29461	0.10582	12.234	<2e-16
DeptE	1.73931	0.12611	13.792	<2e-16
DeptF	3.30648	0.16998	19.452	<2e-16

Der bereinigte Geschlechtereffekt ist nicht signifikant

Zusammenfassung: Statistische Tests für Tabellen

- **Fisher's Exact Test:** 2 x 2 Tabellen
Verteilung der Teststatistik **exakt**
- **Chi-Quadrat Test:** m x n Tabellen
Verteilung der Teststatistik **asymptotisch**
- **Logistische Regression:** 2 x m Tabellen;
auch Mix aus mehreren kontinuierlichen und kategoriellen erklärenden Variablen möglich
Verteilung der Teststatistik **asymptotisch**
Multiple oder einfache ?