

## Voraussetzungen:

- $X$  und  $Y$  sind zwei Bernoulli-Größen mit

$$p_X = P(X = 1)$$

$$p_Y = P(Y = 1)$$

- $(X_1, Y_1), \dots, (X_n, Y_n)$  **abhängige, verbundene** Stichproben
- Absolute Häufigkeiten werden in einer Kontingenztafel festgehalten

	Y=0	Y=1
X=0	$n_{11}$	$n_{12}$
X=1	$n_{21}$	$n_{22}$

## Nichtparametrische Tests

- Bis auf den  $\chi^2$ -Unabhängigkeits-Test bauen alle Tests auf der (zumindestens approximativen Gültigkeit der) Normalverteilungsannahme auf.
- Problematisch, z.B.
  - bei kleinen Stichprobenumfängen (z.B. in der Vorbereitung von strukturierten Beobachtungen, bei nicht reaktiven Verfahren oder in der Psychologie und Medizin)
  - oder bei ordinalen Daten mit wenigen unterschiedlichen Ausprägungen.
- Hier kann die unreflektierte Anwendung der Standardtests zu Fehlergebnissen führen.
- Ein wichtiger Ausweg: nichtparametrische Tests = Verteilungsfreie Verfahren
- Hier wird die Information in den Beobachtungen auf Ränge, bzw. größer/kleiner Vergleiche reduziert.
- Bekannteste Beispiele: Wilcoxon-Test, Vorzeichenstest.

## Voraussetzungen:

- $(X_1, Y_1), \dots, (X_n, Y_n)$  **abhängige, verbundene** binäre Zufallsvariable
- Absolute Häufigkeiten werden in einer Kontingenztafel festgehalten

	Y=0	Y=1
X=0	$n_{11}$	$n_{12}$
X=1	$n_{21}$	$n_{22}$

Nullhypothese  $H_0: P(X = 1) = P(Y = 1)$

Die beiden Zellen  $n_{11}$  und  $n_{22}$  liefern keine Information zum Unterschied der beiden Wahrscheinlichkeiten  $P(X=1)$  und  $P(Y=1)$ . Betrachte die beiden Zellen der Wechsler:  $n_{12}$  und  $n_{21}$

Unter der Nullhypothese sollte  $n_{12} = n_{21}$  gelten.

Daher ist unter  $H_0$ :

$$n_{12} \sim B(n_{12} + n_{21}, 0.5)$$

Man führt also einen Binomialtest mit  $\pi = 0.5$  und  $n = n_{12} + n_{21}$  durch.

## Der Wilcoxon Test für unabhängige Stichproben

## Voraussetzungen:

- $X$  und  $Y$  sind zwei Größen mit Medianen  $med_X$  und  $med_Y$
- $X_1, \dots, X_m$  und  $Y_1, \dots, Y_n$  **unabhängige** Stichproben
- $H_0: med_X = med_Y$  vs.  $H_1: med_X \neq med_Y$

**Grundidee:** Betrachte die Ränge aus allen Beobachtungen  $X_i$  und  $Y_j$  und bezeichne diese mit  $rg(X_i)$  und  $rg(Y_j)$ , z.B.

$X_1 = 3, X_2 = 5, Y_1 = 6, Y_2 = 1, Y_3 = 4 \Rightarrow$

$rg(X_1) = 2, rg(X_2) = 4, rg(Y_1) = 5, rg(Y_2) = 1, rg(Y_3) = 3$

## Testgröße:

$$T = \sum_{i=1}^m rg(X_i)$$

Die exakte Verteilung von  $T$  kann berechnet werden. Für hinreichend große  $n$  und  $m$  kann sie durch eine NV approximiert werden. Ablehnung von  $H_0$  falls große und kleine  $T$ .

- Gegeben sei ein rein zufälliger Datensatz mit 50 Variablen ohne irgendeinen Zusammenhang.
  - Testen aller Variablenpaare auf einen Zusammenhang (1225 Tests)  
Bei vorgegebener Irrtumswahrscheinlichkeit von 5% gilt für die Anzahl fälschlich verworfener Nullhypothesen  $X \sim B(1225, 0.05)$  und somit  $E(X) = 61.25$ .  
Im Durchschnitt wird also mehr als 61 mal die Nullhypothese, dass kein Zusammenhang besteht, verworfen.
- ⇒ wenige, sinnvolle Hypothesen *vorher inhaltlich* überlegen. In den Daten entdeckte „Zusammenhänge“ als statistisch signifikant nachzuweisen, ist (fast) zirkulär.
- Es gibt Ansätze, wie man bei großen Hypothesensystemen diesem Problem entkommt.
- ⇒ Theorie des multiplen Testens
- Z.B. Adjustierung des Irrtumswahrscheinlichkeit: Statt  $\alpha$  betrachte man  $\alpha/($ Anzahl der Tests). Diese spezielle Korrektur ist aber meist überkonservativ und kann durch bessere Korrekturen ersetzt werden.

- Bestimmung mit Obergrenze für Fehler 2. Art ( $\beta$ -Fehler)
- $\beta = P(\text{Nullhypothese wird nicht abgelehnt} \mid H_1 \text{ wahr})$
- $1 - \beta$  wird auch als Power bezeichnet
- Üblicher Wert: Power = 0.8 bzw.  $\beta = 0.2$

## Fehler 2. Art im Binomialtest

Interessante Größen:

- $H_0: \pi = 0.5$  versus  $H_1: \pi > 0.5$
- $\beta$ :  $P(H_0 \text{ wird beibehalten} \mid H_1)$
- $\pi_w$ : wahre Erfolgswahrscheinlichkeit

Numerische Werte für  $n=10$  und  $c=7$

$$\pi_w = 0.6 \text{ und } \beta = 0.95$$

$$\pi_w = 0.7 \text{ und } \beta = 0.85$$

$$\pi_w = 0.8 \text{ und } \beta = 0.62$$

Numerische Werte für  $n=20$  und  $c=13$

$$\pi_w = 0.6 \text{ und } \beta = 0.87$$

$$\pi_w = 0.7 \text{ und } \beta = 0.58$$

$$\pi_w = 0.8 \text{ und } \beta = 0.02$$

Numerische Werte für  $n=100$  und  $c=57$

$$\pi_w = 0.6 \text{ und } \beta = 0.37$$

$$\pi_w = 0.7 \text{ und } \beta = 0.007$$

$$\pi_w = 0.8 \text{ und } \beta < 0.0001$$

## Fehler 2. Art im Beispiel des Binomialtests

Fehler 2. Art sinkt hier mit:

- Wachsender wahrer Erfolgswahrscheinlichkeit ( $\pi > 0.5$ )
- Wachsendem Stichprobenumfang

## • Festlegen von:

$\alpha, \beta$ , Effektgröße  $\pi_w$

## • Beispiel:

$\pi_w = 0.7$

$\Rightarrow n = 20 \Rightarrow \beta = 0.58$  zu klein

$\Rightarrow n = 100 \Rightarrow \beta = 0.07$  zu groß

## • Wähle kleinstes $n$ mit:

$\beta \leq 0.2$

## • Hier:

$n = 37, \beta = 0.19$

$n = 36, \beta = 0.26$

# Bestimmung des Stichprobenumfangs beim t-Test

Einige Werte für den Stichprobenumfang im Zwei-Stichproben t-Test

- unter  $\alpha = 0.05, \beta = 0.2$
- zweiseitige Fragestellung

**Beachte:** Es kommt nur auf das Verhältnis  $d/\sigma$  (Effektstärke) an.

$d/\sigma$	$n_1 = n_2$
2	5
1.33	10
1	17
0.66	37
0.58	50
0.29	100

## Vergleich zweier Gruppen

- Zielgröße:  $Y$
- Relevanter Unterschied:  $d$
- Annahme zur Streuung:  $\sigma$
- Signifikanzniveau:  $\alpha = 0.05$
- Fehler 2.Art:  $\beta = 0.2$

# Zusammenfassung Tests

## Statistischer Test

Ein statistischer Test ist eine Untersuchung, ob man eine Hypothese über die Grundgesamtheit mit Hilfe einer Stichprobe widerlegen kann

## Wichtige Tests

- einseitiger Test  $\leftrightarrow$  zweiseitiger Test
- Tests auf Anteile, Erwartungswerte und deren Differenzen
  - eine Stichprobe
  - zwei Stichproben  $\rightarrow$  verbunden oder unverbunden
- Test auf Unabhängigkeit:  $\chi^2$ -Unabhängigkeitstest

- Statistische Signifikanz bedeutet: Das Ergebnis ist nicht durch Zufall erklärbar.
- Statistische Signifikanz bedeutet nicht unbedingt, dass der Unterschied relevant ist.  
→ Daher immer die Größe des Effekts (Schätzung) angeben!
- Ein statistischer Test liefert aber allein noch keinen kausalen Zusammenhang.
- Bei nicht signifikantem Ergebnis immer Konfidenzintervalle der entsprechenden Parameter angeben. Sie geben eine Idee, wie groß der nicht nachgewiesene Effekt sein könnte.