

# Grundlagen der Mathematischen Statistik

## Testen von Hypothesen Teil I: Einführung

Uwe Menzel, 2018  
uwe.menzel@matstat.org  
[www.matstat.org](http://www.matstat.org)

## Die "Philosophie" der Hypothesentests Nullhypothese und alternative Hypothese

- **Ziel eines (parametrischen) Tests** ist es zu entscheiden, ob ein **Verteilungsparameter** ( $\mu, \Delta\mu, \sigma, \lambda, \dots$ ) einen vermuteten (hypothetischen) Wert haben könnte.
  - Wir könnten z. B. vermuten, dass der Erwartungswert einer normalverteilten Population  $\mu = 20$  ist.
- Die Hypothese bezüglich des Parameters wird **Nullhypothese** ( $H_0$ ) genannt.
  - Die Nullhypothese könnte also z. B.  **$H_0: \mu = 20$**  lauten.
- Der Nullhypothese wird eine sogenannte **alternative Hypothese** ( $H_a$ ) für den Parameter gegenübergestellt.
  - Die alternative Hypothese könnte z. B.  **$H_a: \mu > 20$**  lauten.

[www.matstat.org](http://www.matstat.org)

## Die "Philosophie" der Hypothesentests

### Beispiele für Hypothesen

- $X \sim N(\mu, \sigma)$  (es sei bekannt, dass **Normalverteilung** vorliegt)
  - Nullhypothese  $H_0: \mu = 20$  (der Erwartungswert ist 20)
  - alternative Hypothese  $H_a: \mu \neq 20$  (der Erwartungswert ist **nicht** 20)
- $X \sim N(\mu, \sigma)$ 
  - Nullhypothese  $H_0: \mu = 20$  (der Erwartungswert ist 20)
  - alternative Hypothese  $H_a: \mu > 20$  (der Erwartungswert ist **größer** als 20)
- $X \sim N(\mu, \sigma)$ 
  - Nullhypothese  $H_0: \mu = 20$  (der Erwartungswert ist 20)
  - alternative Hypothese  $H_a: \mu < 20$  (der Erwartungswert ist **kleiner** als 20)
- $X \sim \text{Bin}(n, p)$  (es sei bekannt, dass **Binomialverteilung** vorliegt)
  - Nullhypothese  $H_0: p = 1/2$  (die "Erfolgs"wahrscheinlichkeit ist  $1/2$ )
  - alternative Hypothese  $H_a: p > 1/2$  (die Erfolgswahrscheinlichkeit ist **größer** als  $1/2$ )

www.matstat.org

## Die "Philosophie" der Hypothesentests

### Stichprobe und Teststatistik

- Um zu entscheiden, welche der beiden Hypothesen zutrifft, wird eine zufällige **Stichprobe** aus der Population entnommen.
- Aus der Stichprobe wird ein einzelner numerischer Wert extrahiert, welcher eine Observation (Beobachtung) einer **Teststatistik** darstellt.
  - Teststatistiken können z. B. sein: der (standardisierte) **Mittelwert der Messungen** oder die Anzahl der "erfolgreichen" Bernoulli-Versuche (bei Binomialverteilung) - i. A. ein Schätzer für den Parameter oder eine vom Schätzer abgeleitete Größe.
- Es wird nun festgestellt, ob der beobachtete Wert der Teststatistik im Widerspruch zur Nullhypothese steht. Wenn dies der Fall ist, wird die **Nullhypothese verworfen** und die alternative Hypothese akzeptiert.
  - Ein Widerspruch liegt z. B. vor, wenn der sog. **p-Wert** klein ist oder wenn die Teststatistik einen **kritischen Wert** überschreitet. Mehr dazu weiter unten ...
- Die Ablehnung der Nullhypothese ist i. A. ein gewünschtes Resultat.
  - Dementsprechend wird i. A. auch die Nullhypothese gewählt. Will man z. B. nachweisen, dass zwei Populationen unterschiedliche Erwartungswerte haben, würde man  $H_0: \Delta\mu = \mu_1 - \mu_2 = 0$  wählen und versuchen, dies zu widerlegen.

www.matstat.org

## Die "Philosophie" der Hypothesentests

### Verwerfen der Nullhypothese

Es gibt verschiedene Methoden um zu prüfen, ob die Nullhypothese verworfen werden sollte.

#### 1. Vergleich der Teststatistik mit einem **kritischen Wert**:

- Die Nullhypothese wird verworfen, wenn die Teststatistik einen kritischen Wert in Richtung der alternativen Hypothese überschreitet.

#### 2. Vergleich der Teststatistik mit einem **Konfidenzintervall**:

- Die Nullhypothese wird verworfen, wenn der hypothetische Wert des Parameters nicht im berechneten Konfidenzintervall für den Parameter liegt.

#### 3. Vergleich des **p-Wertes** mit dem Signifikanzniveau

- Die Nullhypothese wird verworfen, wenn der  $p$ -Wert kleiner ein zuvor festgelegter Wert – das sogenannte Signifikanzniveau – ist.

Alle drei Methoden führen zu den gleichen Schlussfolgerungen.

www.matstat.org

## 1. Vergleich der Teststatistik mit dem kritischen Wert

**Beispiel** "Trockenzeit":

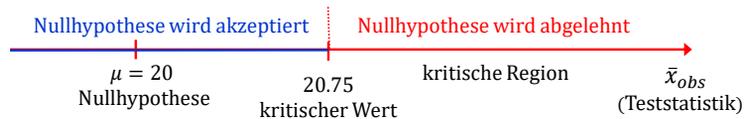
- Ein Unternehmen stellt Farbe her und behauptet, dass die durchschnittliche Trockenzeit nur 20 Minuten beträgt.
- Eine Verbraucherorganisation misstraut dieser Behauptung und vermutet, dass die tatsächliche Trockenzeit größer sein könnte.
- Es wird angenommen, dass die Trockenzeit normalverteilt ist:  $X \sim N(\mu, \sigma)$ 
  - Nullhypothese  $H_0: \mu = 20$
  - Alternative Hypothese:  $H_a: \mu > 20$
- Eine **Stichprobe** soll die Behauptung des Unternehmens testen:
  - es werden 36 Probenflächen bemalt ( $n = 36$ )
  - die Trockenzeiten werden gemessen (Trockenzeiten = Zufallsvariablen  $X_i$ )
  - **Teststatistik**:  $\bar{X}_{obs} = 1/36 \cdot \sum_{i=1}^{36} X_i$  (durchschnittliche Trockenzeit in der Stichprobe = **Schätzer für  $\mu$** )
- Für welchen Wert der Teststatistik ( $\bar{X}_{obs}$ ) wird  $H_0$  verworfen?
  - → **kritischer Wert** muss festgelegt werden



www.matstat.org

## Wahl des kritischen Wertes

- Die Nullhypothese soll verworfen werden für  $\bar{x}_{obs} \geq \omega_{krit} = 20.75$  - ein solches Resultat unterstützt die alternative Hypothese  $H_a: \mu > 20$
- Die Wahl des kritischen Wertes erscheint willkürlich – wir werden später sehen, wie  $\omega_{krit}$  aus anderen Forderungen hergeleitet werden kann.
- Der kritische Wert  $\omega_{krit}$  definiert den Ablehnungsbereich von  $H_0$  (die **kritische Region**)



**Wichtig:** Die Formulierung "Nullhypothese akzeptiert" bedeutet **nicht**, dass diese damit bewiesen wäre. Es kann lediglich gesagt werden, dass die aus der aktuellen Stichprobe gewonnene Observation der Teststatistik **nicht gegen** die Nullhypothese spricht.

www.matstat.org

## Fehlertypen

**Fehlertypen:** Wenn ein kritischer Wert festgelegt wird, ist es unausweichlich, dass zwei Arten von Fehlern riskiert werden:

**Fehler vom Typ I:** es ist möglich, dass die Stichprobe  $\bar{x}_{obs} > 20.75$  ergibt, selbst wenn die Nullhypothese  $\mu = 20$  richtig ist:

→ die Nullhypothese wird verworfen, obwohl sie wahr ist

**Fehler vom Typ II:** es ist möglich, dass die Stichprobe  $\bar{x}_{obs} < 20.75$  ergibt, selbst wenn die Nullhypothese  $\mu = 20$  falsch ist:

→ die Nullhypothese wird akzeptiert, obwohl sie falsch ist

**Diese Fehler sind unausweichlich**, da wir unsere Schlussfolgerungen auf der Grundlage einer Stichprobe treffen, die vom Zufall beeinflusst wird.

	$H_0$ wird akzeptiert	$H_0$ wird verworfen
$H_0$ ist richtig	korrekt	<b>Fehler Typ I</b>
$H_0$ ist falsch	<b>Fehler Typ II</b>	korrekt

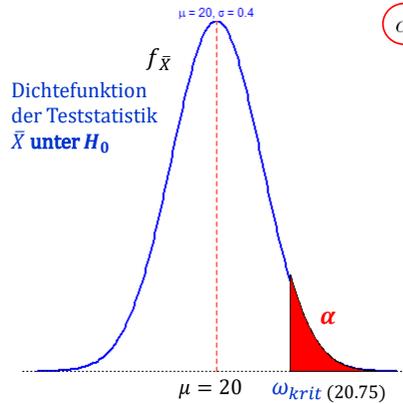
www.matstat.org

## Wahrscheinlichkeit für Fehler Typ I: $\alpha$

**Fehler Typ I:** Die Nullhypothese wird verworfen, obwohl sie wahr ist.

Annahmen: Normalverteilung,  $\sigma = 2.4$  bekannt. Unter  $H_0$  gilt  $\mu = 20$ .

$$X_i \sim N(\mu, \sigma) \Rightarrow \bar{X} \sim N\left(\mu, \frac{\sigma}{\sqrt{n}}\right) \Rightarrow \bar{X} \sim N(\underline{20}, 0.4) \quad (\text{wenn } H_0 \text{ wahr})$$



$$\begin{aligned} \alpha &= P(\text{Fehler Typ I}) \\ &= P(H_0 \text{ wird verworfen} \mid H_0 \text{ wahr}) \\ &= P(\bar{X} > 20.75 \mid \mu = 20) \\ &= 1 - P(\bar{X} \leq 20.75 \mid \mu = 20) \\ &= 1 - F_{\bar{X}}(20.75) \quad \text{für } \mu = 20 \\ &= 1 - \Phi\left(\frac{20.75 - 20}{0.4}\right) \\ &= 1 - \Phi(1.875) = 0.03 \end{aligned}$$

**3% Risiko für Fehler Typ I**  
Man kann  $\alpha$  verkleinern, indem man  $\omega_{krit}$  **vergrößert**.

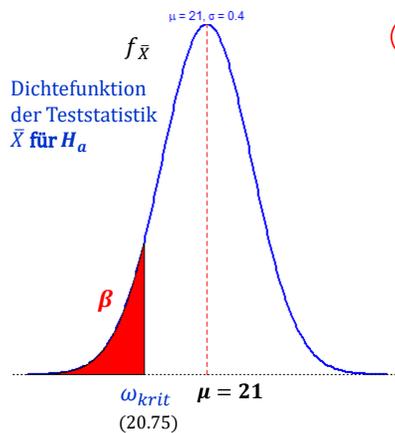
uwe.menzel@matstat.org

## Wahrscheinlichkeit für Fehler Typ II: $\beta$

**Fehler Typ II:** Die Nullhypothese wird akzeptiert, obwohl sie falsch ist

Annahme:  $\sigma = 2.4$  bekannt;  $H_0$  falsch, z. B.  $\mu = 21$

$$X_i \sim N(\mu, \sigma) \Rightarrow \bar{X} \sim N\left(\mu, \frac{\sigma}{\sqrt{n}}\right) \Rightarrow \bar{X} \sim N(\underline{21}, 0.4) \quad (H_0 \text{ falsch})$$



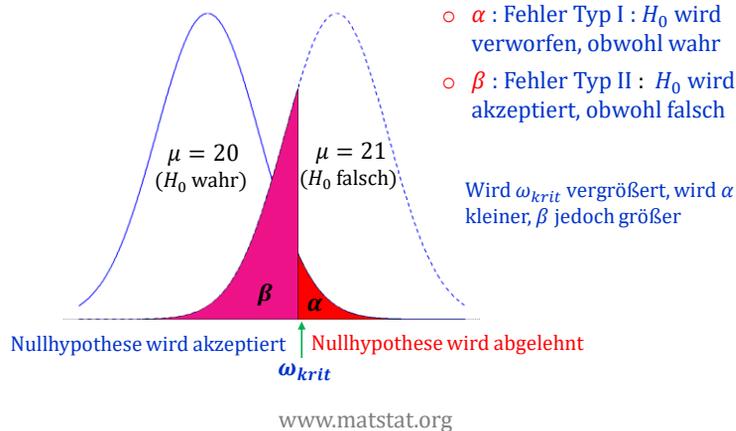
$$\begin{aligned} \beta &= P(\text{Fehler Typ II}) \\ &= P(H_0 \text{ wird akzeptiert} \mid H_0 \text{ falsch}) \\ &= P(\bar{X} \leq 20.75 \mid \mu = 21) \\ &= F_{\bar{X}}(20.75) \quad \text{für } \mu = 21 \\ &= \Phi\left(\frac{20.75 - 21}{0.4}\right) \\ &= \Phi(-0.625) \\ &= 1 - \Phi(0.625) = 0.266 \end{aligned}$$

**ca. 27% Risiko für Fehler Typ II**  
Man kann  $\beta$  verkleinern, indem man  $\omega_{krit}$  **verkleinert**.

uwe.menzel@matstat.org

## Kompromiss zwischen $\alpha$ und $\beta$

- Man kann  $\alpha$  (Fehler Typ I) verkleinern, indem man  $\omega_{krit}$  **vergrößert**.
- Man kann  $\beta$  (Fehler Typ II) verkleinern, indem man  $\omega_{krit}$  **verkleinert**.
- → Kompromiss zwischen  $\alpha$  und  $\beta$  notwendig!



## Justierung der Wahrscheinlichkeit des Fehlers vom Typ I ( $\alpha$ )

- In der Praxis **wird  $\alpha$  vor dem Test festgelegt**.
- Dadurch entscheidet der Anwender, wie groß der Fehler vom Typ I sein soll.
- Der festgelegte Wert von  $\alpha$  wird **Signifikanzniveau** genannt.
- Oft wird  $\alpha = 0.05$  oder  $\alpha = 0.01$  gewählt.
- Nach **Festlegung von  $\alpha$**  kann  $\omega_{krit}$  nun wie folgt berechnet werden:

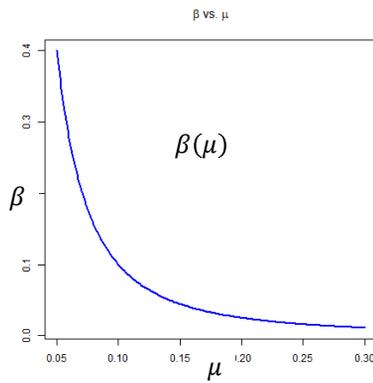
$$\begin{aligned}
 \alpha &= P(H_0 \text{ wird verworfen} \mid H_0 \text{ wahr}) \quad \text{Fehler vom Typ I} \\
 &= P(\bar{X} > \omega_{krit} \mid \mu = 20) \quad \omega_{krit} \text{ muss bestimmt werden} \\
 &= 1 - P(\bar{X} \leq \omega_{krit} \mid \mu = 20) \quad \text{immer unter } H_0: \mu = 20 \\
 &= 1 - F_{\bar{X}}(\omega_{krit}) \quad F_{\bar{X}} = \text{Verteilungsfunktion von } \bar{X} \\
 &= 1 - \Phi\left(\frac{\omega_{krit} - 20}{0.4}\right) \quad \text{Bestimmungsgleichung für } \omega_{krit} \text{ für vorgegebenes } \alpha \text{ (Tabelle für } \Phi \text{ nutzen)}
 \end{aligned}$$

$$\bar{X} \sim N\left(\mu, \frac{\sigma}{\sqrt{n}}\right)$$

uwe.menzel@matstat.org

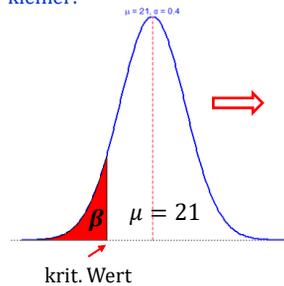
## Justierung der Wahrscheinlichkeit des Fehlers vom Typ II ( $\beta$ ) ?

- Der Fehler Typ II ( $\beta$ ) kann nicht auf diese Weise justiert werden.
- Im Beispiel wurde für  $H_a$  mit  $\mu = 21$  gerechnet. Diesen Wert kennen wir jedoch nicht (die alternative Hypothese war  $H_a: \mu > 20$ ).
- Man kann eine Funktion  $\beta(\mu)$  in einem gewissen Intervall berechnen:



www.matstat.org

Wenn  $\mu$  größer wird, wird die Dichtefunktion nach rechts verschoben. Bei gleichem kritischen Wert wird damit  $\beta$  kleiner:



## Wahl des Signifikanzniveaus $\alpha$

- In der Praxis wird das **Signifikanzniveau  $\alpha$**  vor dem Test festgelegt.
- Der kritische Wert  $\omega_{krit}$  wird dann unter  $H_0$  berechnet
- Oft werden  $\alpha = 0.05$  oder  $\alpha = 0.01$  gewählt.
  - $\alpha = 0.05$  : "auf lange Sicht" wird  $H_0$  in 1 von 20 Tests fälschlich verworfen
  - $\alpha = 0.01$  : "auf lange Sicht" wird  $H_0$  in 1 von 100 Tests fälschlich verworfen

### Konsequenzen der Wahl von $\alpha$ :

... für das Beispiel "Trockenzeit":

Ein **kleineres  $\alpha$** , z. B.  $\alpha = 0.01$  hat folgende Konsequenzen:

- $\omega_{krit}$  wird zu höheren Werten verschoben (20.75  $\rightarrow$  **20.93**, siehe unten)
- Es wird unwahrscheinlicher, dass die Nullhypothese verworfen wird
- besser für Unternehmen - eventuell schlechter für Konsumenten

$$\alpha = 0.01 = 1 - \Phi\left(\frac{\omega_{krit} - 20}{0.4}\right) = 1 - \Phi(x)$$

$$x = \Phi^{-1}(0.99) = 2.326$$

$$\omega_{krit} = x \cdot 0.4 + 20 = \underline{\underline{20.93}}$$

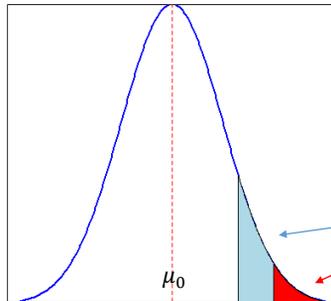
uwe.menzel@matstat.org

## Wahl des Signifikanzniveaus $\alpha$

### Ein kleineres $\alpha$ bedeutet:

- Das Risiko für den Fehler Typ I wird vermindert, das Risiko für den Fehler Typ II ( $\beta$ ) erhöht sich.
- Man kann sicherer sein, dass  $H_0$  wirklich falsch ist, wenn  $H_0$  verworfen wird.

### Dichtefunktion der Teststatistik $\bar{X}$ unter $H_0$



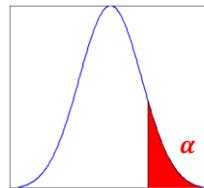
wenn  $\alpha = \alpha_2$  wird  $H_0$  erst verworfen, wenn  $\bar{x}_{obs}$  noch weiter von  $\mu_0$  abweicht (in Richtung  $H_a$ ).

www.matstat.org

## Verschiedene alternative Hypothesen ( $H_a$ )

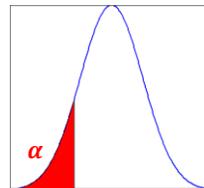
$H_0$	$H_a$	Test
$\mu = \mu_0$	$\mu > \mu_0$	einseitig

$\omega_\alpha =$  kritischer Wert



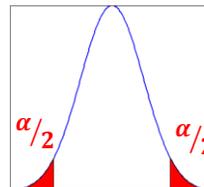
verwerfe  $H_0$  für  $\bar{x}_{obs} > \omega_\alpha$

$H_0$	$H_a$	Test
$\mu = \mu_0$	$\mu < \mu_0$	einseitig



verwerfe  $H_0$  für  $\bar{x}_{obs} < \omega_\alpha$

$H_0$	$H_a$	Test
$\mu = \mu_0$	$\mu \neq \mu_0$	zweiseitig



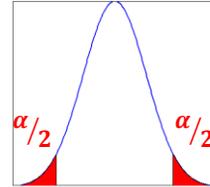
verwerfe  $H_0$  für  $\bar{x}_{obs} < -\omega_{\alpha/2}$  oder  $\bar{x}_{obs} > +\omega_{\alpha/2}$  (für symmetrische Dichtefunktion)

www.matstat.org

## Verschiedene alternative Hypotesen

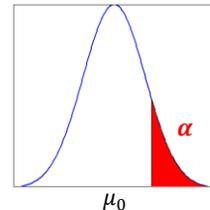
### Beispiel, zweiseitiger Test:

- Ein Bauelement muss einen Durchmesser von 30 cm haben, dieser darf weder zu groß noch zu klein sein
- $H_0: \mu = 30$  ; verwerfe  $H_0$  wenn
  - $\bar{x}_{obs} > 30.5$  oder
  - $\bar{x}_{obs} < 29.5$



### Beispiel, einseitiger Test:

- Eine alte Maschine produziert durchschnittlich 2500 Komponenten pro Tag:  $\mu_0 = 2500$  (normalverteilt).
- Neue, teurere Maschine kaufen ?
  - nur wenn  $\mu$  für die neue Maschine größer ist!
  - wähle  $H_a: \mu > \mu_0$
  - nur kaufen wenn  $H_0$  verworfen werden kann



www.matstat.org

## Berechnung des kritischen Wertes aus $\alpha$ wenn $\sigma$ unbekannt ist

Wenn die Nullhypothese  $\mu = \mu_0$  wahr ist, dann gilt  $X_i \sim N(\mu_0, \sigma)$  und daher

$$\bar{X} \sim N\left(\mu_0, \frac{\sigma}{\sqrt{n}}\right) \Rightarrow Z = \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \sim N(0, 1) \quad \text{eine } N(0,1)\text{-Variable wird oft mit } Z \text{ bezeichnet}$$

Die **Standardabweichung**  $\sigma$  ist jedoch **unbekannt**, deshalb kann  $Z$  nicht als Teststatistik benutzt werden. (Es kann kein numerischer Wert für eine Observation von  $Z$  berechnet werden). Wir wissen jedoch (Vorlesung **F9**), dass wir eine  $t$ -verteilte Variable erhalten, wenn  $\sigma$  im obigen Ausdruck durch den Schätzer  $S$  ersetzt wird:

$$T = \frac{\bar{X} - \mu_0}{S/\sqrt{n}} \sim t(n-1) \quad t(n-1): \text{Students } t\text{-Verteilung für } n-1 \text{ Freiheitsgrade}$$

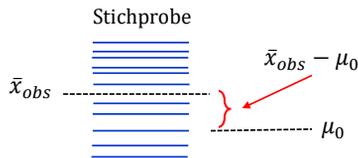
Die Teststatistik  $T$  ist indikativ für die Frage, ob der Erwartungswert einer Population den hypothetischen Wert  $\mu_0$  haben könnte. Weicht der beobachtete Mittelwert  $\bar{x}_{obs}$  stark von  $\mu_0$  ab und ist gleichzeitig die beobachtete Standardabweichung  $s$  der Stichprobe nicht allzu groß, nimmt eine Observation von  $T$  große positive oder negative Werte an. Liegen diese in Richtung der alternativen Hypothese sind wir geneigt, diese anzuerkennen.

uwe.menzel@matstat.org

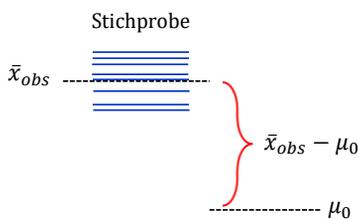
## Die Teststatistik $T$ ist indikativ für den Test

Eine Observation von  $T$  soll im Folgenden mit  $t_{obs}$  bezeichnet werden:

$$t_{obs} = \frac{\bar{x}_{obs} - \mu_0}{s/\sqrt{n}}$$



Der beobachtete Mittelwert  $\bar{x}_{obs}$  weicht nicht stark von  $\mu_0$  ab, außerdem ist die beobachtete Standardabweichung  $s$  der Stichprobe groß. Eine Observation von  $T$  nimmt nicht allzu große positive oder negative Werte an. Die Nullhypothese wird **nicht** verworfen.



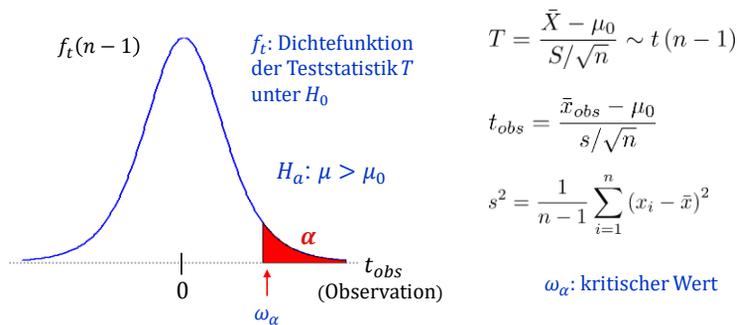
Der beobachtete Mittelwert  $\bar{x}_{obs}$  weicht stark von  $\mu_0$  ab, außerdem ist die beobachtete Standardabweichung  $s$  der Stichprobe klein. Eine Observation von  $T$  nimmt große positive oder negative Werte an. Wenn diese Werte in Richtung der alternativen Hypothese liegen, kann die Nullhypothese verworfen werden.

www.matstat.org

## Berechnung des kritischen Wertes aus $\alpha$

für  $H_a: \mu > \mu_0$

Die  $t$ -Verteilung ist symmetrisch um den Nullpunkt. Wenn die Nullhypothese wahr ist, sollte die Observation  $t_{obs}$  nicht zu weit vom Nullpunkt entfernt liegen, da dann  $\bar{x}_{obs} \approx \mu_0$ . Wir sind geneigt, z. B. die **alternative Hypothese**  $H_a: \mu > \mu_0$  anzunehmen, wenn  $\bar{x}_{obs} \gg \mu_0$  und wenn gleichzeitig  $s$  nicht allzu groß ist. In diesem Fall nimmt  $t_{obs}$  große positive Werte an. Wenn schließlich  $t_{obs} > \omega_\alpha$  wird  $H_0$  zugunsten der alternativen Hypothese verworfen.



$$T = \frac{\bar{X} - \mu_0}{S/\sqrt{n}} \sim t(n-1)$$

$$t_{obs} = \frac{\bar{x}_{obs} - \mu_0}{s/\sqrt{n}}$$

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

www.matstat.org

## Kritischer Wert für $H_a: \mu > \mu_0$

Für  $H_a: \mu > \mu_0$  und ein zuvor festgelegtes Signifikanzniveau  $\alpha$  kann der kritische Wert  $\omega_\alpha$  für die Teststatistik  $T$  aus der Forderung berechnet werden, dass die Wahrscheinlichkeit für den Fehler vom Typ I gleich  $\alpha$  sein soll:

$$P\left(\frac{\bar{X} - \mu_0}{S/\sqrt{n}} > \omega_\alpha \mid H_0 \text{ wahr}\right) = \alpha$$

$H_0$  wird verworfen

Fehler Typ I

Bestimmungsgleichung für  $\omega_\alpha$  für vorgegebenes  $\alpha$  (= Wahrscheinlichkeit für Fehler Typ I)

Unter  $H_0$  ist der linke Term in der Klammer  $t(n-1)$ -verteilt, wir können also schreiben (womit die Bedingung " $H_0$  wahr" verarbeitet ist):

(Der Ausdruck ist dann und nur dann  $t$ -verteilt, wenn  $H_0$  wahr ist, also wenn  $\mu = \mu_0$ )

$$P(T > \omega_\alpha) = \alpha \quad \text{mit} \quad T \sim t(n-1)$$

Allgemein gilt:  $P(T > t_\alpha(n-1)) = \alpha$   $t_\alpha(n-1)$  = Quantil für  $t$ -Verteilung mit  $f = n-1$  und Signifikanzniveau  $\alpha$

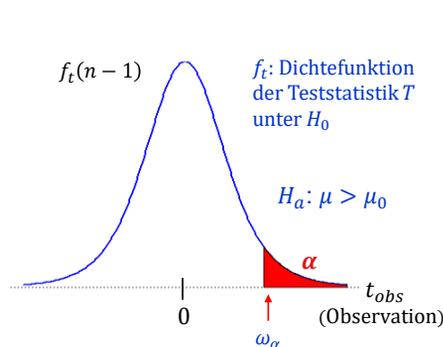
Durch Vergleich der beiden letzten Beziehungen erhalten wir für den kritischen Wert  $\omega_\alpha = t_\alpha(n-1)$ .  $H_0$  wird also verworfen, wenn eine Observation von  $T$  größer als  $t_\alpha(n-1)$  wird.

www.matstat.org

## Kritischer Wert für $H_a: \mu > \mu_0$

Die Nullhypothese wird verworfen, wenn  $t_{obs} > t_\alpha(n-1)$ . Diese Werte bilden die kritische Region für  $t_{obs}$  zum Signifikanzniveau  $\alpha$ . Die kritische Region wird mit  $\Omega_\alpha$  bezeichnet:

$$\Omega_\alpha = \{t_{obs} > t_\alpha(n-1)\}$$



$$T = \frac{\bar{X} - \mu_0}{S/\sqrt{n}} \sim t(n-1)$$

$$t_{obs} = \frac{\bar{x}_{obs} - \mu_0}{s/\sqrt{n}}$$

$H_0$  wird verworfen, wenn die Observation  $t_{obs}$  in der kritischen Region (rot) landet.

$t_\alpha(n-1)$  = Quantil für  $t$ -Verteilung mit  $f = n-1$  für Signifikanzniveau  $\alpha$

www.matstat.org

## Kritischer Wert für $\bar{X}$ für $H_a: \mu > \mu_0$

Es ist üblich, den Test mit der Teststatistik  $T$  durchzuführen. Aus dem oben berechneten kritischen Wert für  $t_{obs}$  lässt sich aber auch leicht ein kritischer Wert für  $\bar{x}_{obs}$  herleiten. Wir hatten festgestellt, dass die Nullhypothese verworfen wird, wenn  $t_{obs} > t_\alpha(n-1)$  also wenn

$$t_{obs} = \frac{\bar{x}_{obs} - \mu_0}{s/\sqrt{n}} > t_\alpha(n-1)$$

$$H_0 \text{ wird dann verworfen wenn } \bar{x}_{obs} > \mu_0 + t_\alpha(n-1) \cdot \frac{s}{\sqrt{n}}$$

Der auf  $\bar{X}$  bezogene kritische Wert ist daher

$$\omega_{\bar{X}} = \mu_0 + t_\alpha(n-1) \cdot \frac{s}{\sqrt{n}}$$

Die Nullhypothese wird also verworfen für  $\bar{x}_{obs} > \omega_{\bar{X}}$ .

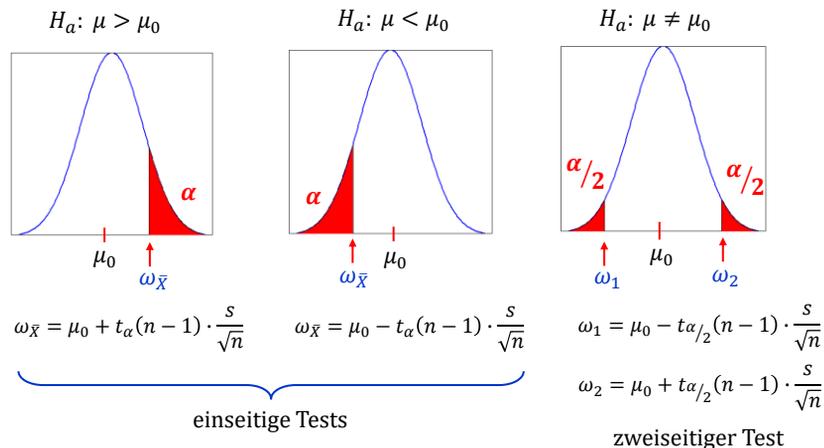
Die kritischen Werte für  $t_{obs}$  bzw.  $\bar{x}_{obs}$  für die anderen alternativen Hypothesen können analog hergeleitet werden (siehe Vorlesung **F12**). Im Folgenden werden die kritischen Regionen für  $\bar{x}_{obs}$  gelistet:



[www.matstat.org](http://www.matstat.org)

## Kritische Werte für $\bar{x}_{obs}$ für verschiedene alternative Hypothesen

Die Lokalisation der **kritischen Region (rot)** für  $\bar{x}_{obs}$  hängt von der Wahl der alternativen Hypothese ab.



[uwe.menzel@matstat.org](mailto:uwe.menzel@matstat.org)

## Zusammenfassung

### Vergleich der Teststatistik mit einem kritischen Wert

1. Definiere die Nullhypothese ( $H_0$ ) und die alternative Hypothese ( $H_a$ )
2. Setze das Signifikanzniveau fest:  $\alpha = P(\text{Fehler Typ I} \mid H_0)$
3. Berechne den kritischen Wert  $\omega_{krit}$  der Teststatistik. Die Verteilung der Teststatistik unter  $H_0$  muss bekannt sein.
4. Berechne die Stichproben-Teststatistik  $(\bar{x}_{obs}, t_{obs}, \dots)$ .
5. Verwerfe  $H_0$  auf Signifikanzniveau  $\alpha$  wenn die Stichproben-Teststatistik in der kritischen Region liegt, sonst "akzeptiere"  $H_0$

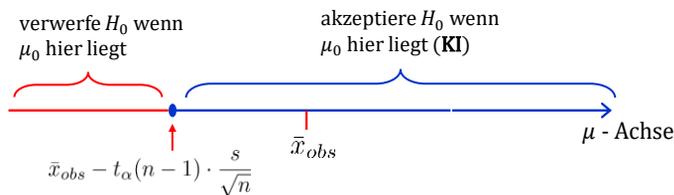
www.matstat.org

## 2. Vergleich Teststatistik $\Leftrightarrow$ Konfidenzintervall

**Einseitiger Test**  $H_0: \mu = \mu_0$   $H_a: \mu > \mu_0$

Wir hatten: verwerfe  $H_0$  wenn  $\bar{x}_{obs} > \mu_0 + t_\alpha(n-1) \cdot \frac{s}{\sqrt{n}}$

Das bedeutet: verwerfe  $H_0$  wenn  $\mu_0 < \bar{x}_{obs} - t_\alpha(n-1) \cdot \frac{s}{\sqrt{n}}$



**Zur Erinnerung:** einseitiges Konfidenzintervall für  $\mu$  (Vorlesung F9):

$$I_\mu = \left( \bar{x}_{obs} - t_\alpha(n-1) \cdot \frac{s}{\sqrt{n}} ; +\infty \right) \quad \text{dies ist genau der oben blau markierte Bereich}$$

Die Nullhypothese wird **nicht** verworfen ("akzeptiert"), wenn der hypothetische Parameter innerhalb des Konfidenzintervalles liegt.

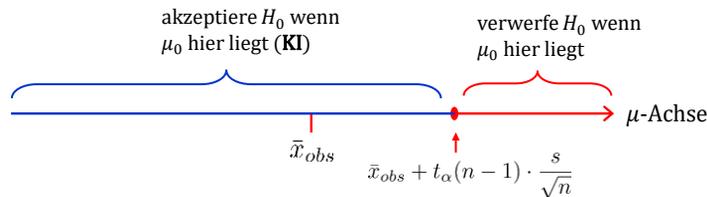
uwe.menzel@matstat.org

## Vergleich Teststatistik $\Leftrightarrow$ Konfidenzintervall

**Einseitiger Test**  $H_0: \mu = \mu_0$   $H_a: \mu < \mu_0$

Wir hatten: verwerfe  $H_0$  wenn  $\bar{x}_{obs} < \mu_0 - t_\alpha(n-1) \cdot \frac{s}{\sqrt{n}}$

Das bedeutet: verwerfe  $H_0$  wenn  $\mu_0 > \bar{x}_{obs} + t_\alpha(n-1) \cdot \frac{s}{\sqrt{n}}$



**Zur Erinnerung:** einseitiges Konfidenzintervall für  $\mu$  (Vorlesung F9):

$$I_\mu = \left( -\infty ; \bar{x}_{obs} + t_\alpha(n-1) \cdot \frac{s}{\sqrt{n}} \right) \quad \text{dies ist genau der oben blau markierte Bereich}$$

Die Nullhypothese wird **nicht** verworfen ("akzeptiert"), wenn der hypothetische Parameter innerhalb des Konfidenzintervalles liegt.

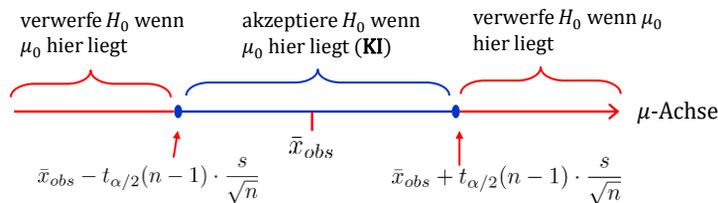
uwe.menzel@matstat.org

## Vergleich Teststatistik $\Leftrightarrow$ Konfidenzintervall

**Zweiseitiger Test**  $H_0: \mu = \mu_0$   $H_a: \mu \neq \mu_0$

Verwerfe  $H_0$  wenn  $\bar{x}_{obs} < \mu_0 - t_{\alpha/2}(n-1) \cdot \frac{s}{\sqrt{n}}$  oder  $\bar{x}_{obs} > \mu_0 + t_{\alpha/2}(n-1) \cdot \frac{s}{\sqrt{n}}$

$\rightarrow$  verwerfe  $H_0$  wenn  $\mu_0 > \bar{x}_{obs} + t_{\alpha/2}(n-1) \cdot \frac{s}{\sqrt{n}}$  oder  $\mu_0 < \bar{x}_{obs} - t_{\alpha/2}(n-1) \cdot \frac{s}{\sqrt{n}}$



**Zur Erinnerung:** zweiseitiges Konfidenzintervall für  $\mu$  (Vorlesung F9):

$$I_\mu = \bar{x}_{obs} \pm t_{\alpha/2}(n-1) \cdot \frac{s}{\sqrt{n}} \quad \text{dies ist genau der oben blau markierte Bereich}$$

Die Nullhypothese wird **nicht** verworfen ("akzeptiert"), wenn der hypothetische Parameter innerhalb des Konfidenzintervalles liegt.

uwe.menzel@matstat.org

## Zusammenfassung

### Vergleich der Teststatistik mit dem Konfidenzintervall

1. Auf der Grundlage einer Stichprobe wird ein Konfidenzintervall mit dem Konfidenzniveau  $1 - \alpha$  für den zu testenden Parameter  $\theta$  berechnet.
  2. Akzeptiere  $H_0: \theta = \theta_0$  auf dem Signifikanzniveau  $\alpha$  wenn der hypothetische Parameter  $\theta_0$  innerhalb des berechneten Konfidenzintervalles liegt.
  3. Verwerfe  $H_0: \theta = \theta_0$  auf dem Signifikanzniveau  $\alpha$  wenn der hypothetische Parameter  $\theta_0$  außerhalb des berechneten Konfidenzintervalles liegt.
- Die Methode des kritischen Wertes und die Konfidenzmethode führen zu den gleichen Schlussfolgerungen.

www.matstat.org

## 3. Vergleich $p$ -Wert $\Leftrightarrow$ Signifikanzniveau

**Definition  $p$ -Wert:** Der  $p$ -Wert ist die Wahrscheinlichkeit für mindestens so extreme Testresultate wie das aktuell beobachtete, berechnet unter der Annahme dass die Nullhypothese wahr ist.

Das Testresultat ist hier der erhaltene Wert der Teststatistik. Werte der Teststatistik werden als "extremer" angesehen, wenn sie noch weiter von der Nullhypothese entfernt in Richtung der alternativen Hypothese liegen als der beobachtete Wert; sie sind unter  $H_0$  noch unwahrscheinlicher als der beobachtete Wert.



Zur Berechnung der obigen Wahrscheinlichkeit muss man eine Teststatistik wählen, deren Verteilung unter  $H_0$  bekannt ist - den Schätzer für den Parameter oder eine vom Schätzer abgeleitete Größe, z. B. den standardisierten Schätzer.

www.matstat.org

## $p$ -Wert für Normalverteilung

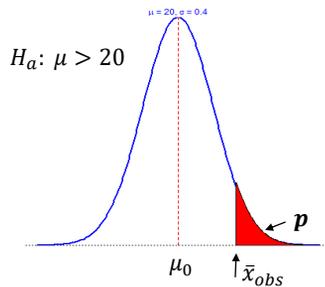
**Beispiel 1:** Es soll getestet werden, ob der Erwartungswert einer normalverteilten Population  $\mu = 20$  oder größer ist:

**Hypothesen:**  $H_0: \mu = \mu_0 = 20$  ;  $H_a: \mu > 20$

**Teststatistik:** Schätzer für  $\mu$ , also Mittelwert  $\bar{X}$

**Verteilung der Teststatistik "unter  $H_0$ ":**  $X_i \sim N(\mu_0, \sigma) \Rightarrow \bar{X} \sim N\left(\mu_0, \frac{\sigma}{\sqrt{n}}\right)$

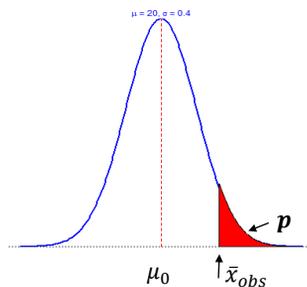
Wir nehmen hier der Einfachheit halber an, dass die Standardabweichung  $\sigma$  bekannt ist. Dann ist die Verteilung von  $\bar{X}$  unter  $H_0$  vollständig bekannt.



Die blaue Kurve sei die Dichtefunktion für  $\bar{X}$  unter der Annahme, dass die Nullhypothese wahr ist:  $f_{\bar{X}}(x | H_0)$ . Der beobachtete Wert der Teststatistik sei  $\bar{x}_{obs}$ . Dann entspricht die Fläche des rot markierten Bereiches dem  $p$ -Wert = Wahrscheinlichkeit der Beobachtung  $\bar{x}_{obs}$  oder noch extremerer Werte in Richtung der alternativen Hypothese.

www.matstat.org

## $p$ -Wert für Normalverteilung



Die blaue Kurve sei die Dichtefunktion für  $\bar{X}$  unter der Annahme, dass die Nullhypothese wahr ist:  $f_{\bar{X}}(x | H_0)$ . Der beobachtete Wert der Teststatistik sei  $\bar{x}_{obs}$ . Dann entspricht die Fläche des rot markierten Bereiches dem  $p$ -Wert.

$$P_{wert} = \int_{\bar{x}_{obs}}^{\infty} f_{\bar{X}}(x | H_0) dx$$

für  $H_a: \mu > 20$

Da das Integral nicht immer leicht zu berechnen ist, ist es günstiger, den standardisierten Mittelwert als Testvariable zu wählen, dazu mehr später ...

**Ein sehr kleiner  $p$ -Wert bedeutet:**

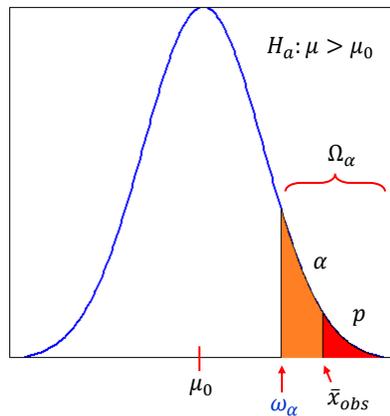
- Der beobachtete Wert der Teststatistik (= "Observation") ist sehr unwahrscheinlich, wenn man annimmt, dass die Nullhypothese  $H_0$  zutrifft.
- Die Nullhypothese wird daher verworfen.

www.matstat.org

## $p$ -Wert und kritische Region

- Wenn die Observation  $\bar{x}_{obs}$  in der kritischen Region für das Signifikanzniveau  $\alpha$  liegt, ist der  $p$ -Wert kleiner als  $\alpha$  und umgekehrt.
- Die Nullhypothese wird also für  $p < \alpha$  zurückgewiesen (auf Signifikanzniveau  $\alpha$ ).

Dichtefunktion der Teststatistik  $\bar{X}$  unter  $H_0$



$\alpha = P(\text{Fehler Typ I})$

$\Omega_\alpha =$  kritische Region

$\omega_\alpha =$  kritischer Wert

rote Fläche =  $p$ -Wert

$H_0$  wird verworfen, wenn  $p < \alpha$

www.matstat.org

## $p$ -Wert für Binomialverteilung

**Beispiel 2:** Wir haben einen Behälter mit mehreren Würfeln, von denen die meisten faire Würfel sind, einige jedoch gefälscht sind und mehr als eine Sechs enthalten. Wir ziehen zufällig einen der Würfel und sollen nun anhand der Ergebnisse von 10 Würfeln – ohne den Würfel selbst zu untersuchen! – feststellen, ob wir einen der gefälschten Würfel gezogen haben.

**Zufallsvariable  $X$ :** Augenzahl bei einem Wurf. Sei  $p = P(X = 6)$ .

**Hypothesen:**  $H_0: p = 1/6$ ;  $H_a: p > 1/6$  (Nullhypothese = fairer Würfel)

**Teststatistik ( $T$ ):** Anzahl der gewürfelten Sechsen bei insgesamt 10 Würfeln. Unter  $H_0$  ist  $T$  binomialverteilt mit  $T \sim \text{Bin}(10, 1/6)$ , denn für einen fairen Würfel beträgt die Wahrscheinlichkeit, eine Sechs zu würfeln gerade  $1/6$ .

**Stichprobe:** Wir nehmen an, dass die Sechsen 9 Mal gewürfelt wurde, d.h.  $T = 9$

**$p$ -Wert:** Die Observation ist  $T = 9$ . Noch extremer in Richtung von  $H_a$  wäre  $T = 10$ . Der  $p$ -Wert ist also laut der Definition die Summe der Wahrscheinlichkeiten für  $T = 9$  und  $T = 10$ .

www.matstat.org



## p-Wert für Binomialverteilung

**Hypothesen:**  $H_0: p = 1/6$ ;  $H_a: p > 1/6$  (Nullhypothese = fairer Würfel)

**Teststatistik (T):**  $T \sim \text{Bin}(10, 1/6)$  unter  $H_0$

**Stichprobe:**  $T = 9$

**p-Wert:**  $P_{\text{Wert}} = P(T \geq 9 | H_0)$

Zur Erinnerung:  $P(T = k) = \binom{n}{k} \cdot p^k \cdot (1-p)^{n-k}$  wenn  $T \sim \text{Bin}(n, p)$

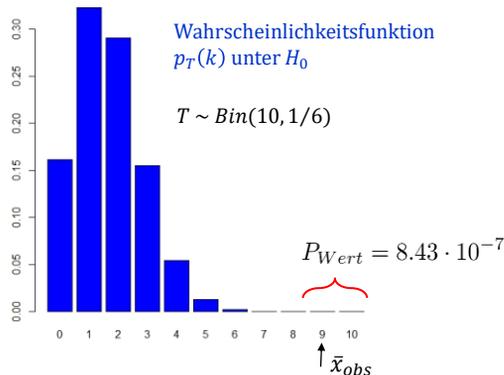
$$\begin{aligned} P_{\text{Wert}} &= P(T \geq 9 | H_0) = P(T = 9 | H_0) + P(T = 10 | H_0) \\ &= \binom{10}{9} \cdot (1/6)^9 \cdot (5/6)^1 + \binom{10}{10} \cdot (1/6)^{10} \cdot (5/6)^0 \\ &= 8.27 \cdot 10^{-7} + 1.65 \cdot 10^{-8} = \underline{\underline{8.43 \cdot 10^{-7}}} \end{aligned}$$

**Ergebnis:** Der p-Wert ist sehr klein. Die erhaltene Beobachtung ist also sehr unwahrscheinlich, wenn man annimmt, dass die Nullhypothese zutrifft. Die Nullhypothese (fairer Würfel) wird daher – sogar auf **Signifikanzniveau  $\alpha = 10^{-6}$**  – verworfen! (Das Signifikanzniveau muss **vor** dem Test festgelegt werden!)

**Anmerkung:** Bei Vorliegen eines solchen Testergebnisses hätte wohl auch der "gesunde Menschenverstand" die Hypothese des fairen Würfels zurückgewiesen.

www.matstat.org

## p-Wert für Binomialverteilung



**Ergebnis:**  $p_{\text{wert}} < \alpha = 10^{-6}$ . Die Nullhypothese kann also sogar auf Signifikanzniveau  $\alpha = 10^{-6}$  verworfen werden. Die Wahrscheinlichkeit, einen Fehler vom Typ I zu begehen ist sehr klein.

www.matstat.org

## p-Wert für Normalverteilung

**Beispiel 3:** Oberflächen von bestimmten elektronischen Komponenten müssen eine 30  $\mu\text{m}$  dicke Kupferschicht haben. Die Schicht darf weder zu dünn noch zu dick sein. Die Oberflächen von  $n = 10$  Komponenten wurden gemessen, der Mittelwert der Messungen war  $\bar{x}_{obs} = 30.91$ . Aus langer Erfahrung ist außerdem bekannt, dass die Dicke normalverteilt mit  $\sigma = 0.788$  ist. (Wir werden später Probleme mit unbekanntem  $\sigma$  rechnen ...).

**Hypothesen:**  $H_0: \mu = 30$ ;  $H_a: \mu \neq 30$

**Teststatistik:** Schätzer für  $\mu$ , also  $\bar{X}$

Wenn  $H_0$  wahr ist, gilt  $\mu = \mu_0 = 30$ , also:

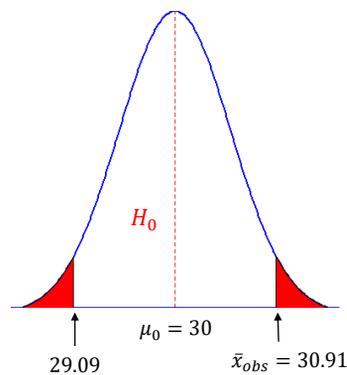
$$\bar{X} \sim N\left(30, \frac{0.788}{\sqrt{10}}\right) \Rightarrow \bar{X} \sim N(30, 0.249)$$

Die alternative Hypothese ist  $H_a: \mu \neq 30$ ,  $\mu$  darf weder zu groß noch zu klein sein. Die kritische Region liegt auf **beiden** Seiten der Dichtefunktion für die Nullhypothese.

www.matstat.org

## p-Wert für Normalverteilung

- Alternative Hypoth.:  $H_a: \mu \neq 30 \rightarrow \mu$  darf weder zu groß noch zu klein sein.
- Der  $p$ -Wert setzt sich nun aus zwei Flächen zusammen (die im Falle einer symmetrischen Dichtefunktion um  $\mu_0$  den gleichen Anstand von  $\mu_0$  haben).
- $\rightarrow$  **zweiseitiger Test**



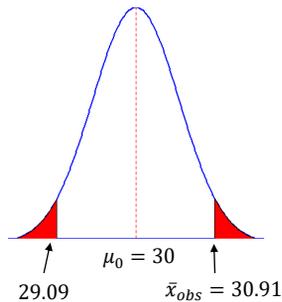
$H_0: \mu = 30$  ;  $H_a: \mu \neq 30$

**Zweiseitiger Test:** beide rot markierte Regionen sind extremer als  $\bar{x}_{obs}$  !

uwe.menzel@matstat.org

## $p$ -Wert für Normalverteilung

$H_0: \mu = 30$  ;  $H_a: \mu \neq 30$  (zweiseitiger Test)  $\bar{x}_{obs} = 30.91$



**Zweiseitiger Test:** beide markierte Regionen sind extremer als  $\bar{x}_{obs}$  !

Zur Berechnung des  $p$ -Wertes können wir die Symmetrie der Dichtefunktion ausnutzen – beide rot markierte Flächen sind gleich groß:

$$\begin{aligned}
 p &= 2 \cdot P(\bar{X} > \bar{x}_{obs} \mid H_0) \\
 &= 2 \cdot P(\bar{X} > 30.91 \mid H_0) \\
 &= 2 \cdot [1 - P(\bar{X} \leq 30.91)] \quad H_0 \\
 &= 2 \cdot [1 - F_{\bar{X}}(30.91)] \\
 &= 2 \cdot \left[1 - \Phi\left(\frac{30.91 - 30}{0.249}\right)\right] \\
 &= 2 \cdot [1 - \Phi(3.65)] \\
 &= 2 \cdot [1 - 0.99987] = \underline{\underline{2.6 \cdot 10^{-4}}}
 \end{aligned}$$

**Ergebnis:** Der  $p$ -Wert ist kleiner als  $10^{-3} \rightarrow H_0$  kann auf Signifikanzniveau  $\alpha = 10^{-3}$  verworfen werden. Die Abweichungen von der vorgeschriebenen Dicke sind zu groß.

www.matstat.org

## $p$ -Wert für Binomialverteilung

**Beispiel 4:** (Alm, Britton: **Stokastik**, Liber AB, Stockholm 2008)

Eine Person behauptet so fingerfertig zu sein, dass sie Einfluss darauf hat, welche Seite bei einem Münzwurf nach oben kommt, so dass sie "Zahl" öfter als "Wappen" werfen kann, d. h.  $p = P(\text{Zahl}) > 1/2$ . Wir sind skeptisch und glauben, dass  $p = 1/2$ . Um die Behauptung der Person zu testen, soll diese 10 Würfe machen. Wir sind bereit der Person zu glauben, wenn sie ausreichend oft "Zahl" werfen kann, genauer: wenn der  $p$ -Wert kleiner als  $\alpha = 0.01$  ist. (d.h. wir nehmen eine Wahrscheinlichkeit von 0.01 für einen **Fehler Typ I** in Kauf).

**Hypothesen:**  $H_0: p = 1/2$ ;  $H_a: p > 1/2$  (einseitiger Test)

**Teststatistik (T):** Anzahl geworfener "Zahl"  $T \sim \text{Bin}(10, 1/2)$  unter  $H_0$

**Stichprobe:**  $T = 8$  Es wurde acht Mal "Zahl" geworfen.

**$p$ -Wert:**  $P_{Wert} = P(T \geq 8 \mid H_0)$

**Signifikanzniveau:**  $\alpha = 0.01$



www.matstat.org

## p-Wert für Binomialverteilung

$T \sim \text{Bin}(10, 1/2)$  unter  $H_0$      **p-Wert:**      $P_{\text{Wert}} = P(T \geq 8 \mid H_0)$

$$\begin{aligned}
 P_{\text{wert}} &= P(X \geq 8 \mid H_0) = p_X(8) + p_X(9) + p_X(10) \\
 &= \binom{10}{8} (1/2)^{10} + \binom{10}{9} (1/2)^{10} + \binom{10}{10} (1/2)^{10} = \underline{\underline{0.0986}}
 \end{aligned}$$

Observation
extremer als Observation

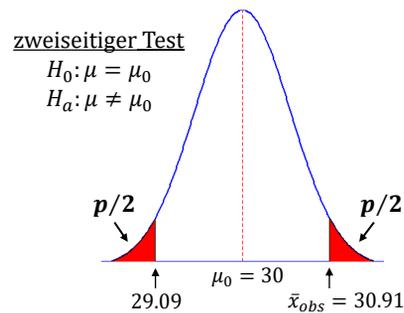
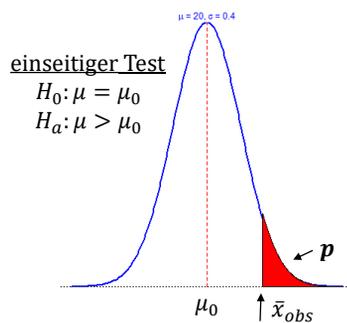
**Ergebnis:** Das Signifikanzniveau  $\alpha$  wurde mit 0.01 festgelegt. Der berechnete  $p$ -Wert ist jedoch größer:  $p > \alpha$ . Die Nullhypothese wird deshalb **nicht** verworfen ("auf Signifikanzniveau 0.01"). Wir dürfen also weiterhin zweifeln, dass diese Person außergewöhnlich geschickt ist, denn wir halten es nicht für so unwahrscheinlich, rein zufällig in 8 von 10 Würfeln "Zahl" zu bekommen.

**Anmerkung:** Damit ist die Nullhypothese jedoch **nicht** "bewiesen"! Vielleicht reichte einfach die Anzahl der Würfe nicht - hätte die Person 80 von 100 mal "Zahl" geworfen, sähe das Ergebnis ganz anders aus. Eine Nullhypothese kann abgelehnt, aber nicht "bewiesen" werden!

www.matstat.org

## Zusammenfassung: p-Wert-Methode

1. Definiere die Nullhypothese ( $H_0$ ) und die alternative Hypothese ( $H_a$ )
2. Setze das Signifikanzniveau fest:  $\alpha = P(\text{Fehler Typ I} \mid H_0)$
3. Lege die Teststatistik ( $\bar{X}_{\text{obs}}, T, \dots$ ) fest. Die Verteilung der Teststatistik unter  $H_0$  muss bekannt sein.
4. Berechne den  $p$  - Wert (laut Definition).
5. Verwerfe  $H_0$  auf Signifikanzniveau  $\alpha$  wenn  $p < \alpha$ , sonst "akzeptiere"  $H_0$



www.matstat.org