

## Signifikanztests

Mit einem Signifikanztest kann eine Vermutung (Hypothese) geprüft werden, die nicht direkt bewiesen werden kann.

Beispiele:

Ist ein neues Medikament wirksamer als Placebo (enthält keinen Wirkstoff)?  
Hat eine Lieferung die versprochene Qualität?


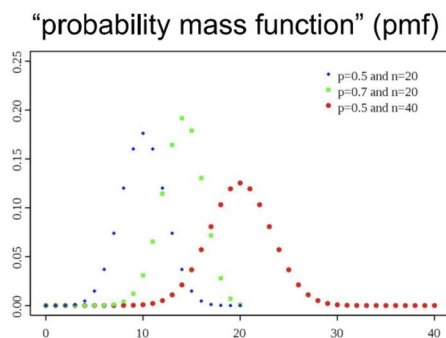
In den Beispielen kommt häufig die Binomialverteilung vor. Dazu eine kurze Zusammenfassung (Quelle: ETH Malthuis):

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

“X ist binomial-verteilt mit Parametern  $n$  und  $p$ ”

$$P(X = x) = \binom{n}{x} p^x (1 - p)^{n-x}, \quad x \in \{0, 1, \dots, n\}$$

$$E(X) = n \cdot p, \quad \text{Var}(X) = n \cdot p \cdot (1 - p)$$



## 1 Test für einen Anteilswert.

Das folgende Beispiel stammt von Sir Ronald Aylmer Fisher (1890-1962), der als Begründer der modernen mathematisch orientierten Statistik gilt. Es illustriert das Vorgehen:

### Die englische Lady

Die englische Lady trinkt ihren Tee stets mit einem Zusatz Milch. Eines Tages verblüfft sie ihre Teerunde mit der Behauptung, sie könne allein am Geschmack entscheiden, ob zuerst die Milch oder zuerst der Tee eingegossen worden sei. Sie behauptet, dass sie im Vergleich zum blinden Raten öfter die richtige Eingiess-Reihenfolge treffen würde. Wie könnte die Behauptung der Lady überprüft werden?

1.

**Alternativhypothese  $H_A$ :** Die Lady hat die behauptete Fähigkeit, d.h. ihre Trefferwahrscheinlichkeit  $p$  ist grösser als  $\frac{1}{2}$

Die Alternativhypothese  $H_A$  drückt eine Vermutung aus, die nicht direkt bewiesen werden kann. In den folgenden Beispielen betrifft die Vermutung den Parameter  $p$  der Binomialverteilung.

2.

Der Alternativhypothese  $H_A$  wird die Nullhypothese  $H_0$  gegenübergestellt:

Die Nullhypothese behauptet die Abwesenheit eines Effekts, den man eigentlich nachweisen möchte:

**Nullhypothese  $H_0$ :** Die Lady rät nur:  $p = \frac{1}{2}$

3.

### Planen eines Zufallsexperiments

Die Lady erhält  $n = 20$ -mal je 2 Tassen Tee überreicht, jeweils eine vom Typ Milch vor Tee, die andere vom Typ Tee vor Milch. Die Reihenfolge dieser beiden Tassen wird durch den Wurf einer Laplace-Münze festgelegt

4.

Es wird für die Zufallsvariable  $X$  (im Beispiel die Anzahl der richtigen Antworten) eine **Entscheidungsregel (Verwerfungsbereich  $V$ )** festgelegt oder das sogenannte **Signifikanzniveau** (meistens 5%) vorgegeben:

Entscheidungsregel:  $X$  sei die Anzahl der Treffer

$X \geq 15$	Entscheid für $H_A$
$X < 15$	Entscheid für $H_0$

5.

Das Zufallsexperiment wird durchgeführt und der Wert der Zufallsvariable bestimmt.

6.


**Fehlermöglichkeiten:**Fehler 1. Art  $\alpha$ :

$H_0$  wird verworfen, obwohl sie richtig ist (d.h. man attestiert der Dame eine Fähigkeit, die nicht vorhanden ist (die Dame erzielt also mindestens 14 Treffer durch Raten))

Fehler 2. Art.

$H_0$  wird beibehalten, obwohl  $H_A$  richtig ist. Die Dame hat tatsächlich die behauptete Begabung, erzielt aber weniger als 14 Treffer.

Die Entscheidungsregel 4. wird oft so gewählt, dass die Wahrscheinlichkeit  $\alpha$  des Fehlers erster Art kleiner als 0.05 ist. Ein solcher Test heisst Signifikanztest zum **Signifikanzniveau  $\alpha = 5\%$** . Bei dieser Vorgehensweise wird der Fehler 1. Art im Vergleich zum Fehler 2. Art als schwerwiegender erachtet. Die meisten Tests werden in der Hoffnung auf eine signifikante Ablehnung der Nullhypothese angelegt.



## Ein weiteres Beispiel:

### ESP: Extra Sensory Perception, Parapsychologie

Gibt es Menschen, die über eine Begabung verfügen, die sich naturwissenschaftlich nicht erklären lässt?

1.

**Alternativhypothese  $H_A$ :** Die Person verfügt über eine besondere Begabung:  $p > \frac{1}{5}$

2.


**Nullhypothese  $H_0$ :** Die Person hat keine besondere Begabung, rät nur:  $p > \frac{1}{5}$

3.

#### Planen eines Zufallsexperiments

Der amerikanische Parapsychologe B. Rhine (1895 bis 1980) hat folgendes Experiment vorgeschlagen:

Die Testperson muss versuchen, aus den 5 Karten in der Abbildung eine ausgewählte Karte zu identifizieren, ohne sie gesehen zu haben. Es werden  $n = 20$  Versuche durchgeführt.



4.

Testgröße  $X$ : Anzahl der richtig geratenen Karten ist binomialverteilt.

**Entscheidungsregel:**  $X$  sei die Anzahl der Treffer

$X > 8$       Entscheid für  $H_A$

$X \leq 8$       Entscheid für  $H_0$

5.

Das Zufallsexperiment wird durchgeführt und der Wert der Zufallsvariable bestimmt.

6.

**Fehlermöglichkeiten:**

Fehler 1. Art:

Die Wahrscheinlichkeit  $\alpha$ , dass einer "normalen" Person irrtümlich besondere Begabung zugeschrieben wird ( $p = 0.2$ , aber  $X > 8$ ) die ist 3.2%

Je grösser der Grad aussersinnlicher Begabung ist (das heisst, je grösser  $p$  ist), umso kleiner ist die Wahrscheinlichkeit, diese besondere Begabung nicht anzuerkennen.

Fehler 2. Art:

Es handelt sich um die Wahrscheinlichkeit  $\beta$ . Bei einer Testperson wird eine besondere Begabung nicht anerkannt.

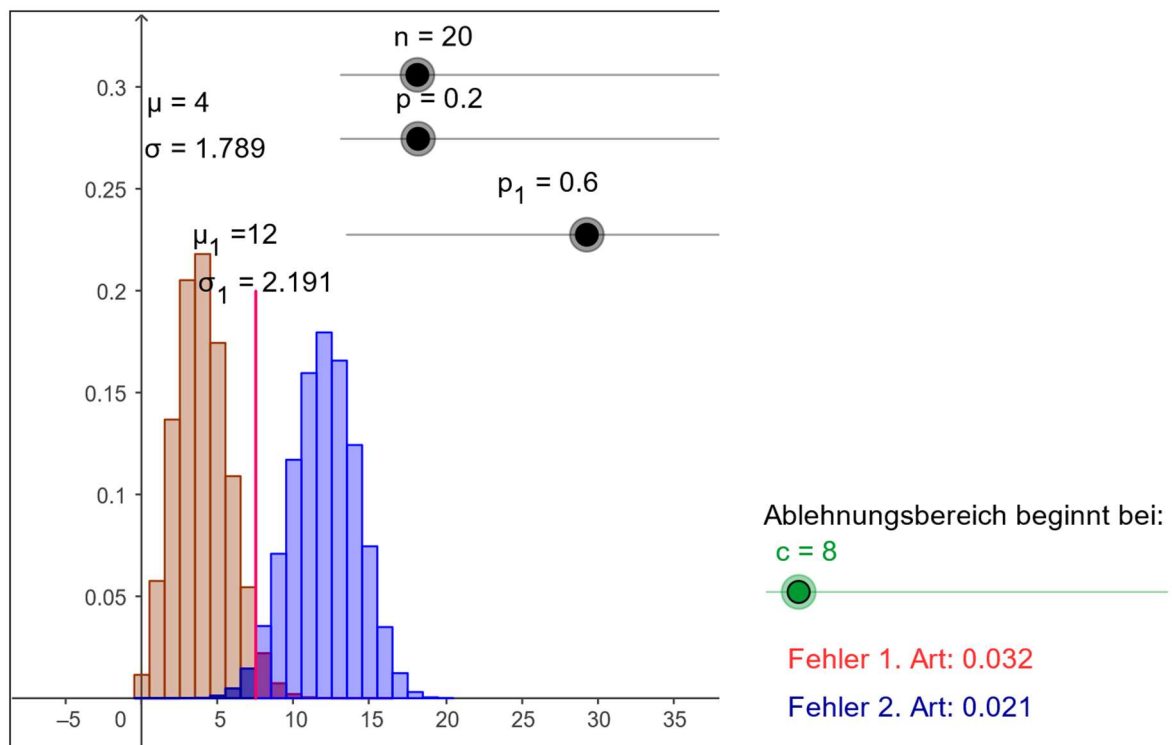
Je grösser der Grad aussersinnlicher Begabung ist (das heisst, je grösser  $p$  ist), umso kleiner ist die Wahrscheinlichkeit, diese besondere Begabung nicht festzustellen.

Das Risiko 2. Art wird mit  $\beta$  bezeichnet. Es hängt von der Trefferwahrscheinlichkeit der Testperson ab:

Im Beispiel wurde  $p' = 0.6$  gewählt.

Verschärft man die Entscheidungsregel ( $Z > 9$ ) so verkleinert sich zwar der Fehler 1. Art, aber der Fehler 2. Art vergrössert sich.

Will man beide Fehler verkleinern, dann bedingt dies eine Erhöhung der Anzahl  $n$ .



Ist wie im folgenden Beispiel  $n > \frac{9}{p \cdot q}$ , dann kann die Binomialverteilung durch die Normalverteilung approximiert werden.

### Multiplechoice-Test

Bei einem Multiple-choice-Test werden einer Kandidatin  $n$  Fragen mit z.B. 4 möglichen Antworten vorgelegt, die entweder richtig oder falsch sein können. Die Kandidatin hat alle richtigen Antworten anzukreuzen. In dem folgenden Beispiel wird eine einfachere Version behandelt.

1.

**Alternativhypothese  $H_A$ :** Die Kandidatin ist eine Könnerin  $p > \frac{1}{2}$  (Test einseitig);  
ihre Trefferwahrscheinlichkeit  $p$  ist grösser als  $\frac{1}{2}$

2.

**Nullhypothese  $H_0$ :** Die Kandidatin rät nur  $p = \frac{1}{2}$

3.

#### Planen eines Zufallsexperiments

Einer Kandidatin werden  $n = 100$  Fragen mit zwei Auswahlantworten vorgelegt, von denen genau eine richtig ist. Es soll geprüft werden, ob die Kandidatin eine Könnerin ist ( $p > 0.5$ ) oder nur rät ( $p = 0.5$ ).

4.

Die Testgrösse  $X$ : Anzahl der richtig geratenen Karten.

Die Zufallsvariable  $X$  ist binomialverteilt mit dem Erwartungswert  $\mu = 50$  und der Standardabweichung  $\sigma = 5$ . Da die Faustregel erfüllt ist, kann die Binomialverteilung durch die Normalverteilung approximiert werden.

Beim gebräuchlichen Signifikanzniveau  $\alpha = 5\%$ , ist  $u$  so zu wählen, dass  $\Phi(u) = 0.95$  gilt. Für die kritische Grenze erhält man damit:

$$50 + 1.645 \cdot \sigma = 50 + 1.645 \cdot 5 = 58.2$$

Beantwortet die Kandidatin also mindestens 59 Fragen richtig, dann wird sie als Könnerin eingestuft.

<b>Entscheidungsregel:</b>	$X \geq 59$	Entscheid für $H_A$
	$X < 59$	Entscheid für $H_0$

5.

#### Durchführung des Zufallsexperiments

Das Zufallsexperiment wird durchgeführt und der Wert der Zufallsvariable bestimmt.

6.

**Fehlermöglichkeiten:**Fehler 1. Art  $\alpha$ :

Die Nullhypothese wird abgelehnt, obwohl sie richtig ist.

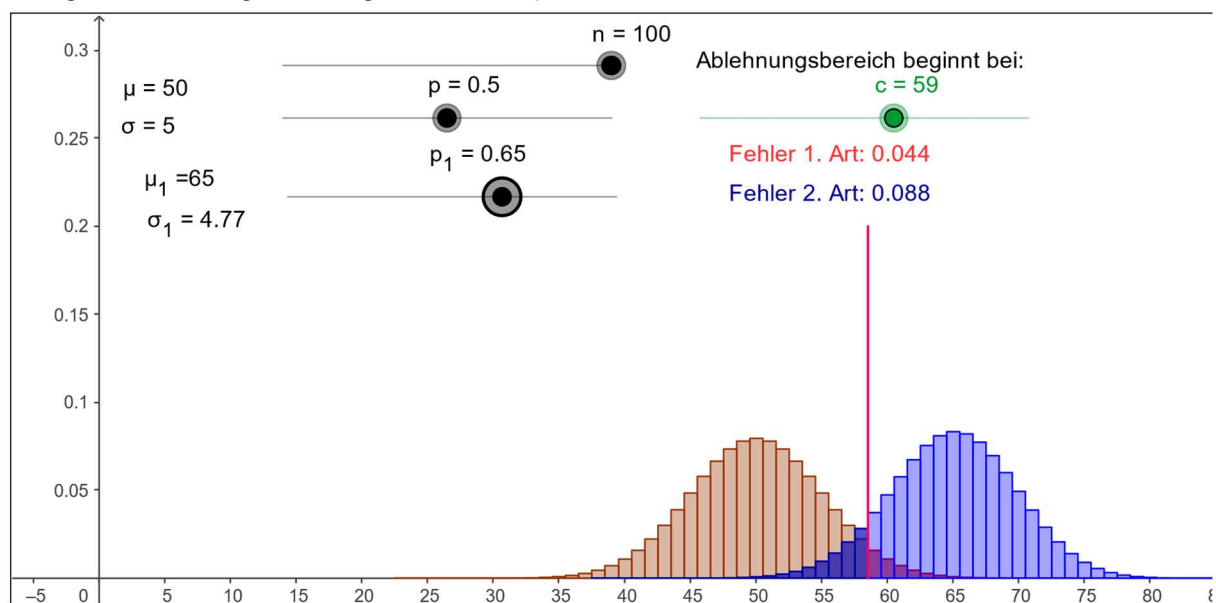
Im Beispiel bedeutet dies: Eine ratende Kandidatin beantwortet, obwohl sie nur rät, mindestens 59 Fragen richtig und wird damit fälschlicherweise als Könnlerin eingestuft

Fehler 2. Art:  $\beta$ 

Die Nullhypothese ist falsch, wird aber fälschlicherweise beibehalten.

Im Beispiel bedeutet dies: Eine Könnlerin (z.B.  $p_1 = 0.65$ ) hat Pech, beantwortet zu wenig Fragen richtig und wird deshalb als Raterin eingestuft.In der Abbildung sind die beiden Wahrscheinlichkeiten für den Fehler 1. und 2. Art (unter der Annahme  $p_1 = 0.65$  zu erkennen).

Die Wahrscheinlichkeit, dass eine ratende Kandidatin die Prüfung besteht (d.h. mindestens 59 Fragen richtig beantwortet ist) höchstens 5%.

Die Wahrscheinlichkeit, dass eine Kandidatin mit  $p_1 = 0.65$  die Prüfung nicht besteht (d.h. weniger als 59 Fragen richtig beantwortet) ist 8.8%.

## **Zusammenfassung Signifikanztest:**

1.

### **Alternativhypothese $H_A$**

Aufgrund der Daten ergibt sich eine bestimmte Vermutung (Hypothese) über den unbekannt Parameter einer Wahrscheinlichkeitsverteilung (z.B. über die Erfolgswahrscheinlichkeit bei einem Bernoullierversuch).

2.

### **Nullhypothese $H_0$**

Die Nullhypothese behauptet Abwesenheit eines Effekts, den man eigentlich nachweisen möchte. Die Nullhypothese möchte man eigentlich widerlegen.

3.

Planen eines **Zufallsexperiments**

4.

Festlegen einer **Entscheidungsregel** gemäss der Vorgabe des Signifikanzniveaus

5.

**Durchführung des Zufallsexperiments**

6.

**Fehlermöglichkeiten:**

Fehler 1. Art:

$H_0$  wird verworfen, obwohl  $H_0$  richtig ist. Die zugehörige Wahrscheinlichkeit wird mit  $\alpha$  bezeichnet,  $\alpha$  heisst Signifikanzniveau. Übliches Signifikanzniveau ist  $\alpha = 5\%$ .

Fehler 2. Art:

$H_0$  wird beibehalten, obwohl  $H_0$  falsch ist. Der Wert der Testgrösse fällt nicht in den Verwerfungsbereich. Die Wahrscheinlichkeit für diesen Fehler wird mit  $\beta$  bezeichnet.  $\beta$  kann in der Regel nur durch zusätzliche Annahmen bestimmt werden.

Beispiele für weitere Anwendungen

Ist das neue Medikament besser als Placebo?  
Ist ein konkreter Würfel gefälscht?

Nullhypothese: Sie sind beide gleich gut  
Nullhypothese: Es handelt sich um einen Laplace-Würfel.

Statistische Qualitätskontrolle:  
Der Ausschussanteil ist zu gross?

Die Lieferung ist in Ordnung

Die beiden Fehler in zwei anderen Kontexten:

In der Justiz: Justizirrtum:

Ein Schuldiger wird freigesprochen

Ein Unschuldiger wird bestraft

In der Produktion:

Ein Verfahren wird überschätzt

Ein Verfahren wird unterschätzt

Ein giftiger Pilz wird als essbar eingestuft

Ein essbarer Pilz wird als giftig eingestuft

Je nach den möglichen Auswirkungen des Fehlers wird man versuchen den Fehler 1. oder 2. Art oder beide zu minimieren

Mehrfaches Testen

Testet man eine Hypothese mehrfach mit voneinander unabhängigen Signifikanztests, dann erhöht sich die Wahrscheinlichkeit, dass der kritische Wert übertroffen wird, womit die Nullhypothese fälschlicherweise abgelehnt wird (Fehler 1. Art). Dazu ein Beispiel:

Die Wahrscheinlichkeit, dass von vier voneinander unabhängigen Tests mit dem Signifikanzniveau  $\alpha = 0.05$  mindestens einer zufällig signifikant ist, beträgt bereits  $1 - 0.95^4 \approx 0.185$