

# Schluss von der Stichprobe auf die Gesamtheit

Problem: Auf Grund einer Stichprobe soll die Wahrscheinlichkeit  $p$  einer Binomialverteilung mit einer vorgegebenen Irrtumswahrscheinlichkeit ermittelt werden.

Beispiel: Vor einer Wahl möchte die Partei C gerne wissen, ob sie in ihrem Bundesland die absolute Mehrheit erringen wird. Es werden  $n=1000$  Personen befragt und  $H_{1000}=538$  davon geben an, Partei C wählen zu wollen. Kann die Partei mit 95%-iger Sicherheit davon ausgehen, die absolute Mehrheit zu erringen?  
Die Frage soll entschieden werden, indem alle Ergebnisse (also alle  $p$ ) berechnet werden, für die der Umfragewert 538 innerhalb der 95%-Umgebung liegt.

Für eine 95%-Umgebung gilt die Ungleichung  $\mu - 1,96 \cdot \sigma \leq H_n \leq \mu + 1,96 \cdot \sigma$  oder ausführlicher  $n \cdot p - 1,96 \cdot \sqrt{n \cdot p \cdot (1-p)} \leq H_n \leq n \cdot p + 1,96 \cdot \sqrt{n \cdot p \cdot (1-p)}$

Angewendet auf das Beispiel ergibt sich die Ungleichung  $1000 \cdot p - 1,96 \cdot \sqrt{1000 \cdot p \cdot (1-p)} \leq 538 \leq 1000 \cdot p + 1,96 \cdot \sqrt{1000 \cdot p \cdot (1-p)}$

Im Extremfall (also für die Randwerte des Intervalls der gesuchten  $p$ -Werte) gelten die beiden Gleichungen

$$(1) \quad 1000 \cdot p - 1,96 \cdot \sqrt{1000 \cdot p \cdot (1-p)} = 538 \quad \text{und} \quad (2) \quad 538 = 1000 \cdot p + 1,96 \cdot \sqrt{1000 \cdot p \cdot (1-p)}$$

Aus Gleichung (1) folgt  $(3) \quad 1000 \cdot p - 538 = 1,96 \cdot \sqrt{1000 \cdot p \cdot (1-p)}$

Aus Gleichung (2) folgt  $(4) \quad 538 - 1000 \cdot p = 1,96 \cdot \sqrt{1000 \cdot p \cdot (1-p)}$

Um die Wurzeln zu entfernen, werden die Gleichungen (3) und (4) quadriert:

Gleichung (3):  $(1000 \cdot p - 538)^2 = 1,96^2 \cdot (1000 \cdot p \cdot (1-p)) \rightarrow$   
 $1000000 \cdot p^2 - 2 \cdot 1000 \cdot p \cdot 538 + 538^2 = 1,96^2 \cdot 1000 \cdot p - 1,96^2 \cdot 1000 \cdot p^2 \quad (5)$

Gleichung (4):  $(538 - 1000 \cdot p)^2 = 1,96^2 \cdot (1000 \cdot p \cdot (1-p)) \rightarrow$   
 $538^2 - 2 \cdot 1000 \cdot p \cdot 538 + 1000000 \cdot p^2 = 1,96^2 \cdot 1000 \cdot p - 1,96^2 \cdot 1000 \cdot p^2 \quad (6)$

Da die Gleichungen (5) und (6) übereinstimmen, wird für beide zusammen weiter umgeformt:

$$1000000 \cdot p^2 - 1076000 \cdot p + 289444 = 3841,6 \cdot p - 3841,6 \cdot p^2 \rightarrow$$

$$1003841,6 \cdot p^2 - 1079841,6 \cdot p + 289444 = 0 \rightarrow p^2 - \frac{1079841,6}{1003841,6} \cdot p + \frac{289444}{1003841,6} = 0 \rightarrow$$

$$p^2 - \frac{10798416}{10038416} \cdot p + \frac{2894440}{10038416} = 0 \rightarrow p_{1,2} = + \frac{5399208}{10038416} \pm \sqrt{\frac{5399208^2}{10038416^2} - \frac{2894440}{10038416}} \rightarrow$$

$$p_1 = 0,507 \quad ; \quad p_2 = 0,569$$

Mit 95%-iger Sicherheit wird also die Partei C ein Wahlergebnis zwischen 50,7% und 56,9% erringen und damit die absolute Mehrheit erreichen.

Allgemeine Rechnung: (mit  $c$  als Maß für die Irrtumswahrscheinlichkeit)

$$n \cdot p - c \cdot \sqrt{n \cdot p \cdot (1-p)} \leq H_n \leq n \cdot p + c \cdot \sqrt{n \cdot p \cdot (1-p)}$$

Ränder des  $p$ -Intervalls:  $n \cdot p - c \cdot \sqrt{n \cdot p \cdot (1-p)} = H_n$  und  $H_n = n \cdot p + c \cdot \sqrt{n \cdot p \cdot (1-p)}$

Daraus folgt  $n \cdot p - H_n = c \cdot \sqrt{n \cdot p \cdot (1-p)}$  und  $H_n - n \cdot p = c \cdot \sqrt{n \cdot p \cdot (1-p)}$

Quadrieren ergibt in beiden Gleichungen  $n^2 \cdot p^2 - 2 \cdot n \cdot p \cdot H_n + H_n^2 = c^2 \cdot n \cdot p - c^2 \cdot n \cdot p^2 \rightarrow$

$$(n^2 + c^2 \cdot n) \cdot p^2 - (2 \cdot n \cdot H_n + c^2 \cdot n) \cdot p + H_n^2 = 0 \rightarrow p^2 - \frac{2 \cdot n \cdot H_n + c^2 \cdot n}{n^2 + c^2 \cdot n} \cdot p + \frac{H_n^2}{n^2 + c^2 \cdot n} = 0 \rightarrow$$

$$p^2 - \frac{2 \cdot H_n + c^2}{n + c^2} \cdot p + \frac{H_n^2}{n \cdot (n + c^2)} = 0 \rightarrow p_{1,2} = \frac{2 \cdot H_n + c^2}{2 \cdot (n + c^2)} \pm \sqrt{\frac{(2 \cdot H_n + c^2)^2}{4 \cdot (n + c^2)^2} - \frac{H_n^2}{n \cdot (n + c^2)}}$$

Die allgemeine Formel für p ist etwas unhandlich. Wenn die solver-Funktion des Taschenrechners benutzt werden darf, sollte man eine einfachere Gleichung vorziehen, z.B.

$|n \cdot p - H_n| = c \cdot \sqrt{n \cdot p \cdot (1-p)}$ , die sich aus  $n \cdot p - H_n = c \cdot \sqrt{n \cdot p \cdot (1-p)}$  und  $H_n - n \cdot p = c \cdot \sqrt{n \cdot p \cdot (1-p)}$  ergibt.

Setzt man dann noch statt der absoluten Häufigkeit  $H_n$  die relative Häufigkeit  $h = \frac{H_n}{n}$  ein, so ergibt

$$\text{sich } |n \cdot p - n \cdot h| = c \cdot \sqrt{n \cdot p \cdot (1-p)} \rightarrow |p - h| = \frac{c \cdot \sqrt{n \cdot p \cdot (1-p)}}{n} = c \cdot \sqrt{\frac{p \cdot (1-p)}{n}}$$

Die Lösung des Beispiels mit dem Taschenrechner ergibt sich so:

Konstanten-Werte eingeben

1000 → N	1000
1.96 → C	1.96
538 / 1000 → H	.538

Gleichung eingeben

```
EQUATION SOLVER
eqn: 0=abs(X-H)-C*sqrt(X*(1-X)/N)
```

Näherung p=0,5 gibt 0,507

```
abs(X-H)-C*sqrt(X*(1-X)/N)=0
X=.5
H=.538
C=1.96
N=1000
bound=(-1E99,1E99)
left-rt=0
```

```
abs(X-H)-C*sqrt(X*(1-X)/N)=0
X=.50701272718...
H=.538
C=1.96
N=1000
bound=(-1E99,1E99)
left-rt=0
```

Näherung p=0,6 gibt 0,569

```
abs(X-H)-C*sqrt(X*(1-X)/N)=0
X=.6
H=.538
C=1.96
N=1000
bound=(-1E99,1E99)
left-rt=0
```

```
abs(X-H)-C*sqrt(X*(1-X)/N)=0
X=.56869642852...
H=.538
C=1.96
N=1000
bound=(-1E99,1E99)
left-rt=0
```

Ist die Intervalllänge d des Vertrauensintervalls vorgegeben und wird nach dem für diese Intervalllänge notwendigen Stichprobenumfang gefragt, so ergibt sich aus

$$|p - h| = c \cdot \sqrt{\frac{p \cdot (1-p)}{n}} \text{ für die Intervalllänge } 2 \cdot |p - h| = 2 \cdot c \cdot \sqrt{\frac{p \cdot (1-p)}{n}} \leq d$$

Der Wert für  $p \cdot (1-p)$  wird maximal für  $p = \frac{1}{2}$ . Mit diesem Wert muss die Intervalllänge noch

$$\text{kleiner oder gleich d sein: } 2 \cdot c \cdot \sqrt{\frac{\frac{1}{2} \cdot \left(1 - \frac{1}{2}\right)}{n}} \leq d \rightarrow 4 \cdot c^2 \cdot \frac{1}{4n} \leq d^2 \rightarrow n \geq \frac{c^2}{d^2}$$