

# Konfidenzintervall für den Parameter $p$ einer Binomialverteilung $B(n, p)$

## *Ausgangssituation*

Man ziehe aus einer (unendlich groß gedachten) Population eine Stichprobe des Umfangs  $n$ . Die Personen werden nach ihrer Einstellung zu einem bestimmten Thema gefragt und haben genau 2 Antwortmöglichkeiten: + oder –.

$k$  sei die Anzahl der „+“-Antworten in der Stichprobe (absolute Häufigkeit).

Die entsprechende relative Häufigkeit ist  $r = \frac{k}{n}$ .

$p$  sei der wahre Anteil der „+“-Stimmen in der Gesamtpopulation.

## *Die Verteilungen*

$K$  sei die Zufallsvariable, die durch wiederholte Ziehung unabhängiger Stichproben und Berechnung von  $k$  entsteht. Analog zur einzelnen Stichprobe gilt  $R = \frac{K}{n}$ .

$K$  ist binomialverteilt mit  $E(K) = \mu_K = n \cdot p$  und  $\sigma_K = \sqrt{n \cdot p \cdot q}$ .

Die Binomialverteilung  $B(n, p)$  darf durch die Normalverteilung  $N(\mu_K, \sigma_K)$  ersetzt werden, falls  $n \cdot p \geq 5$  und  $n \cdot q \geq 5$ . Da  $p$  und  $q$  unbekannt sind, muss hier stattdessen (als Schätzung)  $n \cdot r$  und  $n \cdot (1 - r)$  verwendet werden. Da  $r$  ein erwartungstreuer und konsistenter Schätzer für  $p$  ist, ist anzunehmen, dass  $r \approx p$  und  $1 - r \approx q$  gilt. Sind also  $n \cdot r$  und  $n \cdot (1 - r)$  deutlich größer als 5, so kann man getrost die NV-Approximation durchführen:

$$K \sim B(n, p) \rightarrow K \stackrel{a.}{\sim} N(\mu_K, \sigma_K)$$

Für die Verteilung von  $R = \frac{K}{n}$  folgt:

$$R \stackrel{a.}{\sim} N\left(\frac{\mu_K}{n}, \frac{\sigma_K}{n}\right) = N\left(p, \sqrt{\frac{pq}{n}}\right)$$

**Standardisierung...**

$$\frac{R - E(R)}{\sigma_R} = \frac{R - p}{\sqrt{pq/n}} \sim N(0, 1)$$

Wir wissen, dass für 95% der Werte jeder standardnormalverteilten Variable gilt:

$$|Z| \leq 1.96$$

also auch:

$$\left| \frac{R - p}{\sqrt{pq/n}} \right| = \frac{|R - p|}{\sqrt{pq/n}} \leq 1.96$$
$$|R - p| \leq 1.96 \cdot \sqrt{\frac{pq}{n}}$$

Die (unbekannte!) Populationsvarianz wird nun durch eine (bias-korrigierte) Schätzung ersetzt:

$$\sigma_R = \sqrt{\frac{pq}{n}} \longrightarrow \hat{\sigma}_R = \sqrt{\frac{r(1-r)}{n-1}}$$

Somit gilt:

$$|R - p| \leq 1.96 \cdot \sqrt{\frac{r(1-r)}{n-1}}$$

**Die Grenzen des 95%-KI**

$$p_{1,2} = r \pm 1.96 \cdot \sqrt{\frac{r(1-r)}{n-1}}$$

**Allgemein: Die Grenzen für ein KI mit Irrtumswkt.  $\alpha$**

$$p_{1,2} = r \pm z_{1-\alpha/2} \cdot \sqrt{\frac{r(1-r)}{n-1}}$$

**Beispiel**

Am Abend der Präsidentschafts-Wahl werden  $n = 300$  Personen befragt, ob sie zur Wahl gegangen sind.  $k = 267$  antworten mit „Ja“. Eine erste Schätzung des Anteils in der Gesamtbevölkerung ist demnach  $\hat{p} = r = \frac{k}{n} = 0.89$ .

*Berechnen des KI:*

$$p_{1,2} = 0.89 \pm 1.96 \cdot \sqrt{\frac{0.89 \cdot 0.11}{299}}$$

$$p_1 \approx 0.8545$$

$$p_2 \approx 0.9255$$

$$KI : [0.8545; 0.9255]$$

Der „wahre“ Anteil der Personen in der Bevölkerung, die zur Wahl gegangen sind, liegt (mit einer Wahrscheinlichkeit von 95%) zwischen 85.45% und 92.55%.