

Bestimmung von Vertrauensintervallen (Konfidenzintervallen) bei unbekanntem Wahrscheinlichkeiten

Gegeben sein müssen n , X oder h einer Stichprobe und das Vertrauensniveau γ .

n : Umfang der Stichprobe; X : Absolute Häufigkeit eines Merkmals, h : Relative Häufigkeit eines Merkmals

γ : Sicherheit; Vertrauenszahl. h ergibt sich aus n : $h = \frac{X}{n}$. k ergibt sich aus γ :

γ	90%	95%	99%
k	1,64	1,96	2,58

Mit der Sicherheit γ liegt die unbekannt Wahrscheinlichkeit p im Vertrauensintervall.

Grafische Bestimmung der exakten Intervallgrenzen

p muss aus der Ungleichungskette

$$p - k \sqrt{\frac{p \cdot (1-p)}{n}} \leq h \leq p + k \sqrt{\frac{p \cdot (1-p)}{n}}$$

bestimmt werden.

Dazu werden die drei Terme in den y-Editor des GTR eingegeben (p entspricht x im GTR) und die Schnittstellen von y_3 und y_2 (untere Intervallgrenze) bzw. y_1 und y_2 (obere Intervallgrenze) bestimmt.

Beispiel

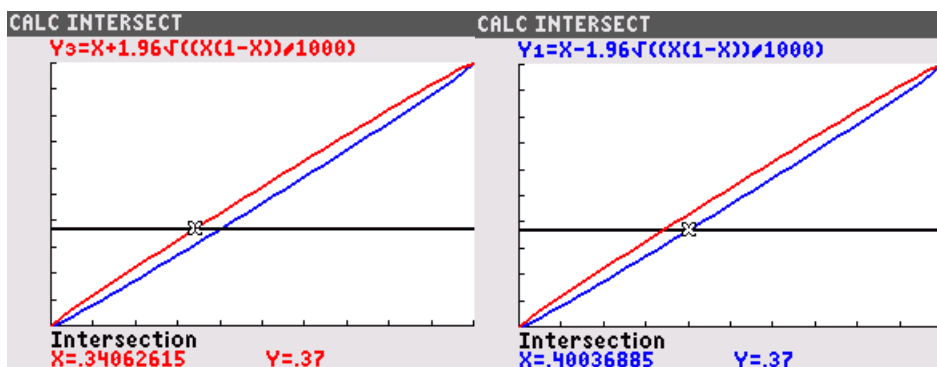
Die Partei CFP gibt eine Umfrage in Auftrag. Eine repräsentative Stichprobe von 1000 Wählern ergibt 370 Wähler der CFP.

Bestimmen Sie das 95%-Vertrauensintervall für den unbekannt Anteil p der CFP-Wähler in der Bevölkerung.

$$n = 1000; h = \frac{370}{1000} = 0,37; k = 1,96$$

```

Plot1 Plot2 Plot3 WINDOW
█ Y1 X-1.96√(X(1-X)/1000 Xmin=0
█ Y2 0.37 Xmax=1
█ Y3 X+1.96√(X(1-X)/1000 Xscl=.1
Ymin=0
Ymax=1
Yscl=.1
    
```



Mit 95% Sicherheit liegt die unbekannt Wahrscheinlichkeit p im Konfidenzintervall $[0,34063; 0,40037]$.

Interpretation im Sachzusammenhang:

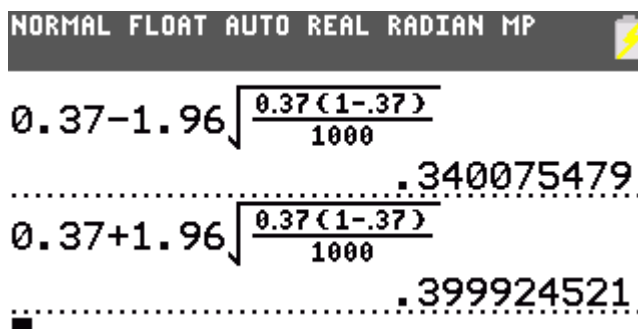
Die Partei CFP kann bei der Wahl mit einer Sicherheit von 95 Prozent ein Ergebnis zwischen 34,06 % und 40,04 % der Wählerstimmen erwarten (eine Spanne von fast 6%).

Vermutlich unterscheidet sich die relative Häufigkeit h in der Stichprobe von dem Anteil p in der Gesamtheit nur wenig. Daher genügt es oft, mit folgender Näherungsformel zu rechnen:

Direkte Berechnung von p mit einer Näherungsformel

$$\left[h - k \cdot \sqrt{\frac{h \cdot (1-h)}{n}}; h + k \cdot \sqrt{\frac{h \cdot (1-h)}{n}} \right]$$

Mit den Werten aus dem Beispiel oben ($n = 1000$; $h = \frac{370}{1000} = 0,37$; $k = 1,96$) ergibt sich jetzt die Näherung für das Vertrauensintervall $[0,34008; 0,39992]$.



Näherungslösung mit dem GTR:

Mit dem GTR wählt man den Test STAT → TESTS → A:1-propZInt...

EDIT	CALC	TESTS
3:1-PropZInt...	x: 370	1-PropZInt
4:2-SampTTest...	n: 1000	(.34008, .39992)
5:1-PropZTest...	C-Level: .95	p̂ = .37
6:2-PropZTest...	Calculate	n = 1000
7:ZInterval...		
8:TInterval...		
9:2-SampZInt...		
0:2-SampTInt...		
1:1-PropZInt...		

und erhält das gleiche Resultat wie mit der Näherungsformel oben.

Berechnung des Stichprobenumfangs:

Aus der Näherungsformel oben lässt sich auch der benötigte Stichprobenumfang n zu einer gewünschten maximalen Intervalllänge berechnen. Die Fehlertoleranz $\varepsilon = k \cdot \sqrt{\frac{h \cdot (1-h)}{n}}$ gibt die halbe Länge des Intervalls an. Wenn man eine Wahrscheinlichkeit auf $\pm 0,5\%$ genau haben möchte, so ist $\varepsilon = 0,005$ und die gesamte Intervalllänge $2\varepsilon = 0,01$.

Bei bekannter Größenordnung von h , z.B. aus einer vorherigen Umfrage, gilt:

Stichprobenumfang bei bekanntem h : $n > \left(\frac{k}{\varepsilon}\right)^2 \cdot h \cdot (1-h)$

Beispiel: Zum Vertrauensniveau $\gamma = 0,95$ und einer gewünschten Fehlertoleranz des Vertrauensintervalls von $\pm 2\%$ soll die Anzahl n der zu befragenden Personen bestimmt werden. Aus früheren Untersuchungen ist bekannt, dass h höchstens 10% beträgt.

$k = 1,96$, $\varepsilon = 0,02$, $h = 0,1$. (Beachte die Anmerkung unten zur Wahl von h .)


Damit ergibt sich für n : $n > \left(\frac{1,96}{0,02}\right)^2 \cdot 0,1 \cdot (1 - 0,1) \Leftrightarrow n > 864,36$

Es müssen mindestens 865 Personen befragt werden, um das Wahlergebnis mit einer Genauigkeit von $\pm 2\%$ vorherzusagen (bei einer Sicherheit von 95%).

Oft ist aber keine Größenordnung von h bekannt, so dass man den Faktor $h \cdot (1-h)$ durch den größtmöglichen Wert, den er annehmen kann, abschätzt. Dieser wird für $h=0,5$ erreicht, wie der Graph rechts zeigt. Ersetzt man also $h \cdot (1-h)$ durch $0,5 \cdot 0,5 = 0,25 = \frac{1}{4}$, so ergibt sich wegen

$\left(\frac{k}{\varepsilon}\right)^2 \cdot h \cdot (1-h) = \left(\frac{k}{\varepsilon}\right)^2 \cdot \frac{1}{4} = \left(\frac{k}{2\varepsilon}\right)^2$ der

Stichprobenumfang n : $n > \left(\frac{k}{2\varepsilon}\right)^2$



Für das Beispiel oben ergibt sich damit: $n > \left(\frac{k}{2\varepsilon}\right)^2 = \left(\frac{1,96}{2 \cdot 0,02}\right)^2 = 2401$

Es müssen mindestens 2402 Personen befragt werden, um das Wahlergebnis mit einer Genauigkeit von $\pm 2\%$ vorherzusagen (bei einer Sicherheit von 95%).

Der Faktor h führte in der oberen Formel zu $h(1-h) = 0,1 \cdot 0,9 = 0,09$, in der unteren Formel beträgt er mit $0,25$ fast das Dreifache.

Anmerkung zur Wahl von h : Wie der Graph oben zeigt, wird $h \cdot (1-h)$ für $h=0,5$ maximal, so dass in der ersten Formel für h derjenige Wert gewählt werden sollte, der am dichtesten an $0,5$ liegt. Wenn man weiß, dass h zwischen $0,3$ und $0,4$ liegt, sollte man $h=0,4$ einsetzen, bei möglichen Werten für h zwischen $0,75$ und $0,85$ wählt man $h=0,75$.