

Empirische Quantile

Seien $x_1 \leq x_2 \leq \dots \leq x_n$ der Größe nach aufsteigend geordnete Beobachtungswerte mit den Rängen 1, 2, ..., n, so heißt der kleinste Wert, der von einem Anteil p aller Werte nicht überschritten wird, das p - Quantil x_p ($0 < p < 1$). Beispielsweise ist $x_{0,5}$ das 0,5 - Quantil (Median). 50% der Beobachtungen liegen unterhalb $x_{0,5}$.

Spezielle Quantile sind:

Median: $p = 0,5$
 Quartile: $p = 0,25 ; 0,5 ; 0,75$
 Dezile: $p = k / 10 \quad (k = 1, \dots, 9)$
 Perzentile $p = k / 100 \quad (k = 1, \dots, 99)$

Es gibt mehrere Berechnungsmöglichkeiten bei gegebenen n Beobachtungen.

1. Es sind nur Beobachtungswerte zugelassen

$x_p = x_k$ mit $k = [n \cdot p + 1]_G$, wobei $[z]_G$ die **Gauß-Klammer-Funktion** darstellt. Sie bezeichnet die größte ganze Zahl, die kleiner oder gleich z ist, z.B. $[4,5]_G = 4$.

2. Es sind auch „berechnete“ Quantile zugelassen

2.1. Übliche Berechnung (1)

$x_p = x_k$ mit $k = [n \cdot p + 1]_G$ wenn $n \cdot p$ nicht ganzzahlig,
 $x_p = (x_{np} + x_{np+1}) / 2$ wenn $n \cdot p$ eine ganze Zahl ist.

2.2. Interpolation über die Ränge der aufsteigend geordneten Beobachtungen (2)

Die Rangzahl für das i-te Quantil erhält man aus $i = (n+1) \cdot p$, sie liegt zwischen den Rängen $k = [(n+1) \cdot p]_G$ und $(k+1)$ Man interpoliert:

<u>Rang</u>	<u>Wert</u>	
k	x_k	$\frac{(k+1) - k}{(n+1) \cdot p - k} = \frac{(n+1) \cdot p - k}{(n+1) \cdot p - k}$
$(n+1) \cdot p$	x_p	$x_{k+1} - x_k$
k+1	x_{k+1}	$x_p - x_k$

das ergibt: $x_p = x_k + ((n+1) \cdot p - k) \cdot (x_{k+1} - x_k)$ für $k < (n+1) \cdot p < (k+1)$

2.3. Bestimmung aus der empirischen Verteilungsfunktion F(X) (kumulative rel. Häufigkeit in `bactcount.sav`)

Für das p - Quantil x_p gilt $F(x_p) \geq p$

Für den Median gilt bei gerader Anzahl von Beobachtungen ($n \cdot p$ ist eine ganze Zahl):

$$x_{0,5} = (x_{n/2} + x_{n/2+1}) / 2$$

Beispiel zur Berechnung der Quartile Q_1 , Q_2 und Q_3 mit dem Datensatz `bactcount.sav` (SPSS)

Quelle: J.S.Kim, R.J. Dailey: Biostatistics for Oral Healthcare. Tab. 2.3.4 Blackwell Munksgaard 2008

$Q_1 = x_{0,25}$; $Q_2 = x_{0,5}$; $Q_3 = x_{0,75}$

1. Nur Beobachtungswerte

Q_1 : $n = 90$; $p = 0,25$; $n \cdot p = 22,5$; $k = [22,5 + 1]_G = 23$; $Q_1 = 220$ (der 23. Wert der aufsteigend geordnete Beobachtungswerte).

Q_2 (Median): $n = 90$; $p = 0,5$; $n \cdot p = 45$; $k = [45 + 1]_G = 46$; $Q_2 = 304$

Q_3 : $n = 90$; $p = 0,75$; $n \cdot p = 67,5$; $k = [67,5 + 1]_G = 68$; $Q_3 = 366$

2.1. Übliche Berechnung (1)

Q_1 : aus $n \cdot p = 22,5$ folgt $Q_1 =$ „23. Wert in der Reihe“ = **220**

Q_2 : aus $n \cdot p = 45$ folgt $Q_2 =$ „1/2 · (45 + 46. Wert)“ = **303**

Q_3 : aus $n \cdot p = 67,5$ folgt $Q_3 =$ „68. Wert in der Reihe“ = **366**

2.2. Interpolation über die Ränge (2)

Q_1 : $n = 90$; $p = 0,25$; $(n+1) \cdot p = 22,75$; $k = [22,75]_G = 22$; $x_{22} = 213$; $x_{23} = 220$ das ergibt

$$Q_1 = 213 + (22,75 - 22) \cdot (220 - 213) = \mathbf{218,25}$$

Q_2 (Median): $n = 90$; $p = 0,5$; $(n+1) \cdot p = 45,5$; $k = [45,5]_G = 45$; $x_{45} = 302$; $x_{46} = 304$ das ergibt

$$Q_2 = 302 + (45,5 - 45) \cdot (304 - 302) = \mathbf{303}$$

Q_3 : $n = 90$; $p = 0,75$; $(n+1) \cdot p = 68,25$; $k = 68$; $Q_3 = 366 + 0,25 \cdot 14 = \mathbf{369,5}$

Ausdruck aus SPSS:

COUNT		
N	Gültig	90
	Fehlend	0
Perzentile	25	218,25
	50	303,00
	75	369,50

SPSS verwendet die Methode der Interpolation über die Ränge.

¹ Hartung: Statistik. Oldenbourg Verlag

² Bland: An Introduction to Medical Statistics. Oxford University Press