

Punktbiseriale Korrelation

Es wird der Zusammenhang zwischen einer *natürlich dichotomen* Variablen und einer *intervallskalierten* Variablen berechnet. Auch für diesen Korrelationskoeffizienten gilt: Kodiert man die Ausprägungen des dichotomen Merkmals mit den Werten 0 und 1, so ist der punktbiseriale Korrelationskoeffizient mit dem Produkt-Moment-Korrelationskoeffizienten identisch.

Wozu benötigt man die punktbiseriale Korrelation? Eine wesentliche Anwendung liegt in der Testtheorie. Stellen Sie sich vor, Sie hätten einen Schulleistungstest erarbeitet, indem eine Reihe von Teilaufgaben zu lösen ist. Sie bewerten die Leistung einfach an der Summe der gelösten Aufgaben. Jeder Proband bekommt die gleichen Aufgaben gestellt - beispielsweise 20 Aufgaben. Für jede gelöste Aufgabe erhält er einen Punkt. Die beste Leistung pro Proband sind somit 20 Punkte.

Angenommen, Sie wollen nun wissen, wie gut eine einzelne Aufgabe die Gesamtleistung repräsentiert. Eine einzelne Aufgabe kann nur gelöst sein oder nicht - 0 oder 1. Die Frage ist nun, inwiefern zwischen der Lösung dieser Aufgabe und der Gesamtleistung ein Zusammenhang besteht. Ein guter Zusammenhang würde sich vorerst - rein intuitiv gesprochen - dann ergeben, wenn Probanden, die die Aufgabe nicht gelöst haben, auch eine schlechte Gesamtleistung aufweisen, und wenn umgekehrt Probanden, die die Aufgabe gelöst haben, auch in der Gesamtleistung gut abschneiden.

Das bedeutet: Wir fragen nach dem Zusammenhang zwischen der Lösung einer einzelnen Aufgabe, einer natürlich dichotomen Variable also, und der Gesamtleistung, die intervallskaliert ist.

Dafür eignet sich nun der punktbiseriale Korrelationskoeffizient. Er wird auch als *Trennschärfekoeffizient* bezeichnet. Er gibt nämlich an, wie gut eine einzelne Aufgabe zu trennen vermag zwischen Probanden mit einer niederen Gesamtleistung und solchen mit einer höheren Gesamtleistung. Diese Trennung wird umso besser sein, je höher die einzelne Aufgabe und die Gesamtleistung miteinander korrelieren.

Wie gehen wir vor?

Gehen wir zunächst von der Erfassung der Rohdaten aus. Wir schreiben die beiden Variablen - die natürlich dichotome und die intervallskalierte - nebeneinander je in eine Spalte. Beispiel:

x	y
0	4
0	6
1	6
0	5
1	12
0	11
1	11
1	13
1	16
1	18

Die Variable x ist die natürlich dichotome Variable, die Variable y die Gesamtleistung.

Für einen späteren Schritt benötigen wir die Standardabweichung der Variable y (diese ist in dem vorliegenden Beispiel: $s = 4,56$). Die Gesamtanzahl aller getesteten Personen ist 10.

In einem nächsten Schritt unterteilen wir die Gesamtleistung in zwei Spalten und zwar nach dem Kriterium, ob die einzelne Aufgabe gelöst wurde oder nicht. Wir bezeichnen die beiden Spalten mit y_0 und y_1 , also:

y_0	y_1
4	6
6	12
5	11
11	13
	16
	18

y_0 enthält 4 Fälle - vier Probanden haben die Aufgabe nicht gelöst - y_1 enthält 6 Fälle - sechs Probanden haben die Aufgabe gelöst. Wir drücken das auch so aus: $n_0 = 4$; $n_1 = 6$. Der Mittelwert von y_0 ist 6,5; der Mittelwert von $y_1 = 12,67$.

Damit haben wir alle notwendigen Voraussetzungen, um r_{pb} berechnen zu können.

$$r_{pb} = \frac{\bar{y}_1 - \bar{y}_0}{s_y} \cdot \sqrt{\frac{n_0 \cdot n_1}{n^2}}$$

In unserem konkreten Fall ist r_{pb} :

$$r_{pb} = \frac{12.67 - 6.5}{4.56} \cdot \sqrt{\frac{4 \cdot 6}{10^2}}$$

$$r_{pb} = 1.353 \cdot 0.489 = 0.662$$