



# Statistik für Psychologen und Sozialwissenschaftler

2., aktualisierte und erweiterte Auflage

**Markus Bühner**  
**Matthias Ziegler**

 **Pearson**

**EXTRAS**  
**ONLINE**



Befruchtung unterzogen worden zu sein, wenn Zwillinge geboren wurden. Wenn wir dies nun auf die Entscheidung bei Hypothesen übertragen, bedeutet dies:  $p(H_0|D) \neq p(D|H_0)$  und  $p(H_1|D) \neq p(D|H_1)$ . Über den Satz von Bayes (siehe *Abschnitt 3.7.1*) ist es möglich,  $p(H_0|D)$  aus  $p(D|H_0)$  unter bestimmten Vorannahmen zu berechnen:

$$p(H_1|D) = \frac{p(H_1) \cdot p(D|H_1)}{p(D)} \quad \text{und} \quad p(H_0|D) = \frac{p(H_0) \cdot p(D|H_0)}{p(D)}$$

Wahrscheinlichkeiten für eine Hypothese, die auf der Basis von bereits vorliegenden Daten ermittelt werden, bezeichnet man als **A-posteriori Wahrscheinlichkeiten**. Diese werden ins Verhältnis gesetzt und ergeben einen **Wettquotienten** bzw. genauer eine **Posterior Odds**  $\Omega$  (sprich Omega, großer griechischer Buchstabe).

$$\Omega = \frac{p(H_1|D)}{p(H_0|D)} = \frac{f(D|H_1)}{f(D|H_0)} \cdot \frac{p(H_1)}{p(H_0)}$$

Wenn  $\Omega = 10$ , ist  $H_1|D$  zehnmal wahrscheinlicher als  $H_0|D$ .

**Vorannahmen.** Um die Odds

$$\frac{p(H_1|D)}{p(H_0|D)}$$

zu ermitteln, ist es nötig, bestimmte Vorannahmen zu treffen: Diese „stecken“ im zweiten Teil der Formel:

$$\frac{p(H_1)}{p(H_0)}$$

Mit diesem Teil wird vor der Durchführung der Datenerhebung eine Annahme darüber getroffen, wie das Verhältnis von  $H_0$  und  $H_1$  a priori definiert ist. Man spricht von einer **Prior Odds**. Werden im Rahmen eines Experiments mit zwei unabhängigen Gruppen  $H_0$  und  $H_1$  als gleichwahrscheinlich angenommen, ergibt sich der Faktor 1. Wird erwartet, dass die  $H_1$  wahrscheinlicher als die  $H_0$  auftritt, wird ein Faktor größer eins verwendet.

**Marginale Likelihoods.** Der erste Faktor setzt sogenannte marginale Likelihoods ins Verhältnis:

$$\frac{f(D|H_1)}{f(D|H_0)}$$

Ein solcher Koeffizient wird als Bayes-Faktor  $BF_{10}$  bezeichnet, da im Zähler  $H_1$  und im Nenner  $H_0$  steht. Es gibt auch den Bayes-Faktor  $BF_{01}$ , bei dem im Zähler die  $H_0$  und im Nenner die  $H_1$  steht. Man erhält so einen Wert, der angibt, um welchen Faktor die Likelihood im Zähler die des Nenners übersteigt. Im Zähler steht in der Regel die Likelihood der Daten ( $D$ ) unter  $H_1$ :  $f(D|H_1)$ . Im Nenner steht in der Regel die Likelihood der Daten ( $D$ ) unter  $H_0$ :  $f(D|H_0)$ . Im Folgenden ist der  $BF_{10}$  dargestellt:

$$BF_{10} = \frac{f(D|H_1)}{f(D|H_0)} = \frac{M_1}{M_0}$$

Die Berechnung der Likelihoods ist kompliziert und wird im Exkurs nicht dargestellt. Sie findet sich bei Rouder et al. (2009). Die Berechnung mit R ist hingegen einfach und mit dem R-Paket **Bayes Factor (Morey & Rouder, 2015)** möglich:

```
ttest.tstat(t, n1, n2, rscale = "wide")
```

Dabei sind folgende Eingaben vorzunehmen:

`t` = *t*-Wert des *t*-Tests für unabhängige Stichproben

`n1` = Stichprobengröße Gruppe 1

`n2` = Stichprobengröße Gruppe 2

`medium` = kleine a priori erwartete Effektstärke

`wide` = mittlere bis große a priori erwartete Effektstärke

`ultrawide` = große a priori erwartete Effektstärke

Der aus der Formel resultierende Bayes-Faktor gibt an, um welchen Faktor die beobachteten Daten unter der  $H_1$  wahrscheinlicher sind als unter der  $H_0$ . Damit sind **Bayes-Faktoren unabhängig von den Prior Odds**. Unterschiedliche Wissenschaftler können bei gleichem Bayes-Faktor zu unterschiedlichen Posterior Odds kommen, abhängig davon, ob sie a priori die  $H_0$  oder die  $H_1$  für wahrscheinlicher halten und wie stark die jeweilige Präferenz ausfällt.

Allerdings hängt der Bayes-Faktor davon ab, ob wir unter der  $H_1$  eher große oder eher kleine Effekte erwarten. Der Einfluss dieser Vorannahme fällt jedoch in der Regel klein aus. Die Vorannahme ist subjektiv und spiegelt die „Vermutung“ des Wissenschaftlers unter der gegebenen Fragestellung wider. In R wird die a priori erwartete Effektstärke indirekt mit dem `rscale`-Argument spezifiziert. Es stehen drei mögliche Voreinstellungen zur Verfügung. Geht man a priori von kleinen Effektstärken aus, empfiehlt sich die Einstellung „`medium`“. Werden größere Effekte erwartet, ist die Einstellung „`wide`“ angemessen. Je „weiter“ `rscale` gewählt wird, desto stärker fällt der Bayes-Faktor zugunsten der  $H_0$  aus. Möchte man also die Vorannahme möglichst so wählen, dass ein gewünschtes Ergebnis am „schwersten“ realisiert wird, kann auch die Einstellung „`ultrawide`“ sinnvoll sein.

Obwohl der oben beschriebene Bayes-Faktor sehr anschaulich ist, wird er in der Regel logarithmiert und anschließend bewertet. Dies wird im Folgenden kurz dargestellt.

Teilt man zwei Wahrscheinlichkeiten, setzt sie also ins Verhältnis, ergibt sich ein Wert von null bis plus unendlich. Man bezeichnet solche Koeffizienten auch als Wettquotienten oder Odds. Ist ein Wettquotient eins, bedeutet dies in unserem Fall, dass die Wahrscheinlichkeiten der Daten unter der Null- und Alternativhypothese gleich sind, z. B. jeweils  $p = 0.50$ . Je weiter der Wettquotient unter eins liegt, desto mehr Evidenz liegt für die Nullhypothese vor, je mehr der Wert über eins liegt, desto mehr Evidenz liegt für die Alternativhypothese vor. Werden die Wettquotienten logarithmiert, ergibt sich für