

ZID (Dept. W) / IDP (Dept. T)

Äquivalenztests zur Evaluation von Interventionen in der Lehre

Gekürzte Version

Treffen der Statistikinteressierten an der ZHAW
25. 6. 2019

Claude Müller Werder (muew, ZID)
Thoralf Mildenerger (mild, IDP)

Basiert teilweise auf Paper mit Maren Lübcke (HIS Institut für Hochschulentwicklung Hannover)

Äquivalenz von Behandlungen

Ziel: Es soll gezeigt werden, dass zwei Populationen den selben Mittelwert haben

t-Test $H_0: \mu_1 = \mu_2$ vs. $H_1: \mu_1 \neq \mu_2$

Nullhypothese kann nicht abgelehnt werden ($p > 0.05$).

Häufiger Fehlschluss: „Damit ist gezeigt, dass es keinen Unterschied gibt.“

Warum ist das falsch?

- Hypothesentests bewerten nur Evidenz **gegen** die Nullhypothese, **nicht für** die Nullhypothese
- Nicht-Ablehnen von H_0 *kann* heissen, dass H_0 zutrifft.
- Nicht-Ablehnen von H_0 *kann* aber auch daher kommen, dass H_0 falsch ist, dies sich aber anhand der Daten nicht eindeutig zeigen lässt (z.B. zu kleine Stichprobe, zu grosse Varianz, generell zu tiefe Power des Tests).
- Analogie: Vor Gericht wird ein Angeklagter freigesprochen, wenn ihm keine Schuld nachgewiesen werden kann. Vielleicht ist er unschuldig, vielleicht gibt es einfach keine Beweise!

Äquivalenz von Behandlungen

Was kann man dagegen machen?

Verschiedene Ansätze:

- **Klassischer t-Test mit Analyse der Power**
t-Test wird wie gehabt durchgeführt und Power gegen Effekte bestimmter Grössen analysiert. Ältester Ansatz.
- **Bayes-t-Test**
Bayes-Ansätze behandeln H_0 und H_1 symmetrisch. Bayes-Faktor sogar unabhängig von Priors für Hypothesen (aber ein Prior *unter* H_1 wird benötigt!). Problem: Wir glauben meist gar nicht, dass die Differenz exakt Null ist, sondern wollen zeigen, dass sie klein ist.
- **Konfidenzintervalle**
Für einfache Nullhypothesen praktisch äquivalent zum Testen, aber informativer. Hier extrem nützlich, da man schauen kann, welche Bereiche man einigermaßen sicher ausschliessen kann. Nicht immer optimal.
- **Äquivalenztests**
Eine Art Umkehrung der klassischen Tests. Fällt komplett unter klassisches Neyman-Pearson-Framework, ist in der Praxis aber wenig bekannt. Bayes-Versionen gibt es auch!

Äquivalenztests

t-Test $H_0: \mu_1 = \mu_2$ vs. $H_1: \mu_1 \neq \mu_2$

Verbreiteter Irrtum: „Nullhypothese besagt immer, dass kein Effekt existiert bzw. eine Differenz Null ist.“

Definition von Null- und Alternativhypothese ergibt sich aus der Fragestellung:
Die Nullhypothese möchte man widerlegen („Beweislast“).

t-Test umgekehrt $H_0: \mu_1 \neq \mu_2$ vs. $H_1: \mu_1 = \mu_2$

Probleme:

- Es existiert keine gute Lösung des Problems. Kein Test kann höhere Power haben als der triviale Niveau- α -Test (Daten gar nicht benutzen und H_0 mit Wahrscheinlichkeit α verwerfen)
- Wir wollen eigentlich auch gar nicht zeigen, dass es gar keine Differenz gibt, sondern dass sie klein genug ist um praktisch irrelevant zu sein.

Äquivalenztests

Eigentlich interessierendes Testproblem:

$$H_0: \mu_1 - \mu_2 \leq -\varepsilon \quad \text{oder} \quad \mu_1 - \mu_2 \geq +\varepsilon \quad \text{vs.} \quad H_1: -\varepsilon < \mu_1 - \mu_2 < +\varepsilon$$

Nullhypothese: Die Differenz ist grösser als ein Toleranzwert

Alternative: Die Differenz ist kleiner als ein Toleranzwert

Verwerfen von H_0 bedeutet, dass man Gleichheit bis auf ε nachgewiesen hat.

Nichtverwerfen von H_0 bedeutet nicht, dass man einen grossen Effekt nachgewiesen hat!

Methoden:

- TOST (Two One-sided t-Tests) für nicht-standardisierte Mittelwertdifferenz
- UMPI-Test für standardisierte Mittelwertdifferenz (Cohen's d, Effektstärke) vgl. Wellek (2010)

Äquivalenztests: TOST

Two One-Sided t-Tests:

$$\begin{array}{ll} H_{0,1}: \mu_1 - \mu_2 \leq -\varepsilon & \text{vs.} & H_{1,1}: -\varepsilon < \mu_1 - \mu_2 \\ H_{0,2}: \mu_1 - \mu_2 \geq +\varepsilon & \text{vs.} & H_{1,2}: \mu_1 - \mu_2 < +\varepsilon \end{array}$$

Wir führen also **zwei** Tests durch:

- Ablehnen von $H_{0,1}$ bedeutet, die Differenz ist nicht kleiner als $-\varepsilon$
- Ablehnen von $H_{0,2}$ bedeutet, die Differenz ist nicht grösser als $+\varepsilon$

Ablehnen von $H_{0,1}$ **und** $H_{0,2}$ bedeutet also, $-\varepsilon < \mu_1 - \mu_2 < +\varepsilon$.

Die einzelnen Tests sind normale t-Tests, alle Varianten möglich

- Unverbundene Stichproben (gleiche oder ungleiche Varianz)
- Verbundene Stichprobe
- Eine Stichprobe

Zu welchem Niveau müssen wir die beiden Tests durchführen?

Müssen wir eine **Korrektur für multiples Testen** machen?

Äquivalenztests: TOST

Wir wollen zum Niveau α testen, d.h. wenn keine Äquivalenz vorliegt, wollen wir nur mit Wahrscheinlichkeit α Äquivalenz behaupten.

Es reicht, beide Tests zum Niveau α durchzuführen!

Warum?

Sei dazu H_0 richtig. Wir machen einen Fehler 1. Art, wenn $H_{0,1}$ und $H_{0,2}$ ablehnen.

Da nur **entweder** $\mu_1 - \mu_2 \leq -\varepsilon$ **oder** $\mu_1 - \mu_2 \geq +\varepsilon$ sein kann, ist entweder $H_{0,1}$ oder $H_{0,2}$ richtig, aber **nicht beide**.

Sei o.E. $H_{0,1}$ richtig.

$$P_{H_{0,1}}(\text{Fehler 1. Art}) = P_{H_{0,1}}(H_{0,1} \text{ ablehnen und } H_{0,2} \text{ ablehnen}) \leq P_{H_{0,1}}(H_{0,1} \text{ ablehnen}) \leq \alpha$$

Analog für den Fall $H_{0,2}$ richtig.


Wir müssen also keine **Korrektur für multiples Testen** durchführen!

Äquivalenztests: TOST

Dies hat eine weitere Konsequenz: Wir können den Test mit einem **(1-2 α)-Konfidenzintervall** durchführen:

- $H_{0,1}$ wird genau dann abgelehnt, wenn das einseitige (1- α)-KI $[d_l, \infty)$ komplett rechts von $-\varepsilon$ liegt
- $H_{0,2}$ wird genau dann abgelehnt, wenn das einseitige (1- α)-KI $(-\infty, d_u]$ komplett links von $+\varepsilon$ liegt
- Die Schnittmenge $[d_l, d_u] = [d_l, \infty) \cap (-\infty, d_u]$ ist aber genau das (1-2 α)-Konfidenzintervall für die Differenz der Erwartungswerte!

Äquivalenztests: TOST



Äquivalenztests: TOST


Wir können den TOST zum Niveau α also auf zwei Arten durchführen:

- Zwei einseitige t-Tests, H_0 ablehnen, wenn beide p-Werte kleiner als α
- $(1-2\alpha)$ -Konfidenzintervall für die Mittelwertdifferenz berechnen. Wir schliessen auf Äquivalenz, wenn das KI komplett in $(-\varepsilon, +\varepsilon)$ enthalten ist.

Bemerkungen

- Konfidenzintervall ist evtl. informativer, da man damit auch Äquivalenz ausschliessen kann
- Der Test zum 5%-Niveau entspricht einem 90%-Konfidenzintervall
- **In R:** z.B. Paket TOSTER

Äquivalenztests: TOST / Konfidenzintervall



Äquivalenztests: UMPI-Test

Optimaler Äquivalenztest für standardisierte Mittelwertdifferenzen

Implementierungen in R-Paketen:

EQUINONINF:

- R-Paket zum Buch von Wellek (2010)
- Berechnet Ablehnbereiche, nicht p-Werte
- Kann mit asymmetrischen Äquivalenzbereichen umgehen
- Paket enthält auch andere Äquivalenztests

equivUMP:

- Selbst implementiert, seit April 2019 auf CRAN
- Syntax und Output soweit wie möglich analog zu `t.test()`
- Berechnet p-Werte
- Kann (bis jetzt) nicht mit asymmetrischen Äquivalenzbereichen umgehen
- Ein- und Zweistichprobenversionen (gepaart, ungepaart), ausserdem auch einseitige Versionen (non-inferiority testing, non-superiority testing)

Äquivalenztests: UMPI-Test

```
> equiv.test(grade ~ group, data = dat, alternative = "two.sided",  
eps = 0.5, mu = 0, paired = FALSE)
```

Two sample equivalence test

```
data: grade by group  
t = 0.45781, df = 98.0000, ncp = 2.2913,  
p-value = 0.03034  
alternative hypothesis: equivalence  
null values:  
      lower upper  
[1,]  -Inf  -0.5  
[2,]   0.5   Inf  
sample estimates:  
      d  
0.09990274
```

Literatur

Lakens, D. (2017). Equivalence Tests: A Practical Primer for t Tests, Correlations, and Meta-Analyses. *Social Psychological and Personality Science*, 8(4), 355-362. doi: 10.1177/1948550617697177

Lakens, D., Scheel, A. M., & Isager, P. M. (2018). Equivalence Testing for Psychological Research: A Tutorial. *Advances in Methods and Practices in Psychological Science*, 1(2), 259-269. doi:10.1177/2515245918770963

Meyners, M. (2012). Equivalence tests – A review. *Food Quality and Preference*, 26(2), 231-245. doi: <https://doi.org/10.1016/j.foodqual.2012.05.003>

Wellek, S. (2010). *Testing statistical hypotheses of equivalence and noninferiority* (2nd ed.). Boca Raton: CRC Press.

R-Pakete

- **BayesFactor:** Computation of Bayes Factors for Common Designs
Kann benutzt werden, um einen Bayesianischen Äquivalenztest durchzuführen
- **BEST:** Bayesian Estimation Supersedes the t-Test
Bayesianischer Ansatz auf Basis der Region of Practical Equivalence (ROPE)
- **Equivalence:** Provides Tests and Graphics for Assessing Tests of Equivalence
TOST und weitere Tests
- **EquivalenceTest:** Equivalence Test for the Means of Two Normal Distributions
Einige neuere spezielle Tests
- **EQUIVNONINF:** Testing for Equivalence and Noninferiority
zu Wellek (2010), optimale Tests
- **equivUMP:** Uniformly Most Powerful Invariant Tests of Equivalence
UMPI-Test
- **TOSTER:** Two One-Sided Tests (TOST) Equivalence Testing
TOST mit Varianten