



Optimal Design of Non-Parametric Two-Sample Tests

Paul Bürkner, Philipp Doebler, Heinz Holling

Institut für Psychologie
Westfälische Wilhelms-Universität Münster

17.09.2015







Problemstellung

- Sei T ein Zweistichproben-Test zu $H_0 : G(Y) = F(X)$ gegen $H_1 : G(Y) \neq F(X)$.
- Seien m und n die Stichprobengrößen der beiden Gruppen bei fester Gesamtstichprobengröße $N := m + n$.
- Sei $\omega = m/N$ der Anteil der Gesamtstichprobe, der für die erste Gruppe verwendet wird.
- Maximiere die Power $P(T = H_1 | H_1)$ über ω

Wilcoxon-Mann-Whitney-Test

- Teststatistik:

$$U_{mn} := \sum_{i=1}^m \sum_{j=1}^n \chi(x_i, y_j)$$

mit

$$\chi(x_i, y_j) := \begin{cases} 1 & \text{if } x_i \geq y_j \\ 0 & \text{if } x_i < y_j. \end{cases}$$

- U_{mn} ist approximativ normalverteilt für alle Verteilungen F und G , sofern sich die Verteilungen überlappen (also $P(X \geq Y) \in (0, 1)$).
- Unter H_0 gilt:

$$E(U_{mn}) = \frac{mn}{2} \quad V(U_{mn}) = \frac{mn(m+n+1)}{12}.$$



Erwartungswert und Varianz unter H_1

$$E(U_{mn}) = mnP(X \geq Y),$$

$$V(U_{mn}) = mn \left(P(X \geq Y) - (m + n - 1)P(X \geq Y)^2 \right. \\ \left. + (n - 1) \int G(x)^2 df(x) + (m - 1) \int (1 - \tilde{F}(x))^2 dg(x) \right).$$



Optimal Design für symmetrische Verteilungen gleicher Form


- Für symmetrische Verteilungen gleicher Form (d.h. $H1 : G(Y) = F(X + a)$) folgt durch Standardisieren:

$$\mu_{mn} = \frac{\sqrt{\omega(1-\omega)}N(P(X \geq Y) - 1/2)}{\sqrt{P(X \geq Y) - (N-1)P(X \geq Y)^2 + (N-2) \int G(x)^2 df(x)}}$$



$$\sigma_{mn}^2 = \frac{P(X \geq Y) - (N-1)P(X \geq Y)^2 + (N-2) \int G(x)^2 df(x)}{(N+1)/12}$$

- Unter Zuhilfenahme von Symmetrie-Eigenschaften folgt, dass $\omega = 0.5$ optimal ist.
- Die Normalverteilungsapproximation wird dafür nicht gebraucht.

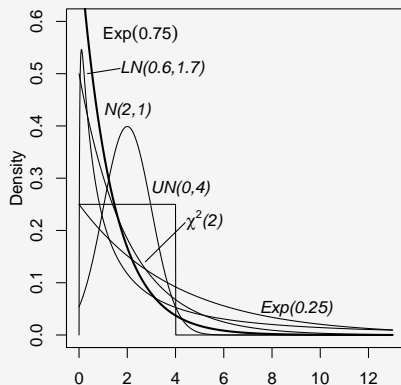

In Simulationen genutzte symmetrische Verteilungen





Optimal Design für symmetrische Verteilungen ungleicher Form





In Simulationen genutzte asymmetrische Verteilungen



Optimal Design für asymmetrische Verteilungen ungleicher Form



Optimal Design für asymmetrische Verteilungen ungleicher Form





Kolmogorov-Smirnov-Test



- Teststatistik:

$$D_{mn} := \sqrt{\frac{mn}{m+n}} \sup_{x \in \mathbb{R}} |F_m(x) - G_n(x)|, \quad (1)$$

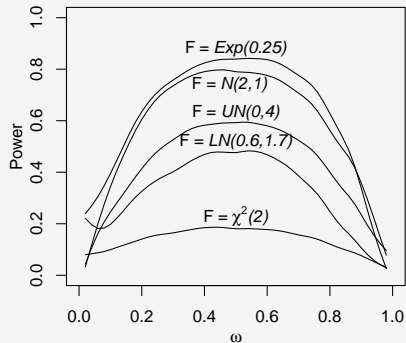

- Unter der H_0 ist die approximative Verteilung von D_{mn} bekannt:

$$\lim_{m,n \rightarrow \infty} P(D_{mn} \leq d) = 1 - 2 \sum_{i=1}^{\infty} (-1)^{i-1} e^{-2i^2 d^2}, \quad (2)$$

Optimal Design für symmetrische Verteilungen ungleicher Form



Optimal Design für asymmetrische Verteilungen ungleicher Form



Optimal Design für asymmetrische Verteilungen ungleicher Form

