



# Poweranalyse oder: Die richtige Stichprobengrösse

# Warum Poweranalyse ?

- Wie viele Stichproben brauchen wir, um eine gewisse Alternative mit 80% Wa. (= Macht) erkennen zu können ?
- Zu viel: Unnötiger Aufwand
- Zu wenig: Nutzlose Studie
  
- Zeitverschwendung
- Ethische Probleme
  
- Praxis: Stichprobengrösse = «Educated guess»  
(weil Parameter willkürlich)

# Wdh: Zauberwürfel oder nicht ?



Wie oft müssen wir würfeln ?

# Binomialtest: Bsp Zauberwürfel

1. Modell:  $X$ : Anzahl 6er bei 50 Würfeln;  $X \sim \text{Bin}(n = 50, \pi = 1/6)$

2. Nullhypothese:  $H_0: \pi = 1/6$   
Alternative:  $H_A: \pi > 1/6$  (einseitig)

3. Teststatistik  $T$ : Anz. 6er bei 50 Würfeln  
Verteilung der Teststatistik, wenn Nullhypothese stimmt:  
$$T \sim \text{Bin}(50, 1/6)$$

4. Signifikanzniveau:  $\alpha = 0.05$  (Konvention)

5. Verwerfungsbereich der Teststatistik:  
 $P[T = t] = \binom{n}{t} \pi^t (1 - \pi)^{n-t}$ ; berechne  $P[T \geq t]$

Verwerfungsbereich  
Grenze: Kleinste Zahl  $t$ ,  
sodass  $P[T \geq t] \leq \alpha$

t	...	13	14	15	...
$P[T \geq t]$	...	0.06	0.03	0.01	...

6. Testentscheid: Liegt die beobachtete Anzahl 6er bei 50 Würfeln im Verwerfungsbereich der Nullhypothese?

Falls ja:  $H_0$  wird auf dem 5% Niveau verworfen

Falls nein:  $H_0$  kann auf dem 5% Niveau nicht verworfen werden

## Wdh: Fehler 1. und 2. Art, Macht

- $H_0: X \sim \text{Bin}\left(n, p = \frac{1}{6}\right); H_A: p > \frac{1}{6}$
- **Fehler 1. Art:**  $H_0$  stimmt, wird aber im Test verworfen  
Wa. für Fehler 1. Art ist höchstens  $\alpha$
- Fehler 2. Art:  $H_A$  stimmt,  $H_0$  wird aber im Test **nicht** verworfen
- **Macht:** Wa. dass  $H_0$  verworfen wird, falls  $H_A$  stimmt  
Macht =  $1 - P(\text{Fehler 2. Art})$
- Macht und Wa. für Fehler 2. Art kann nur mit **konkreter Alternative** berechnet werden (z.B.  $H_A: p = \frac{1}{3}$ )

H0 true ( p0 = 0.167 )

$X \sim \text{Bin}(50, 1/6)$



14

H1 true ( p1 = 0.333 )

$Y \sim \text{Bin}(50, 1/3)$



1-beta = 0.8273

Macht =  $P(Y \geq 14) = 1 - P(Y \leq 13)$

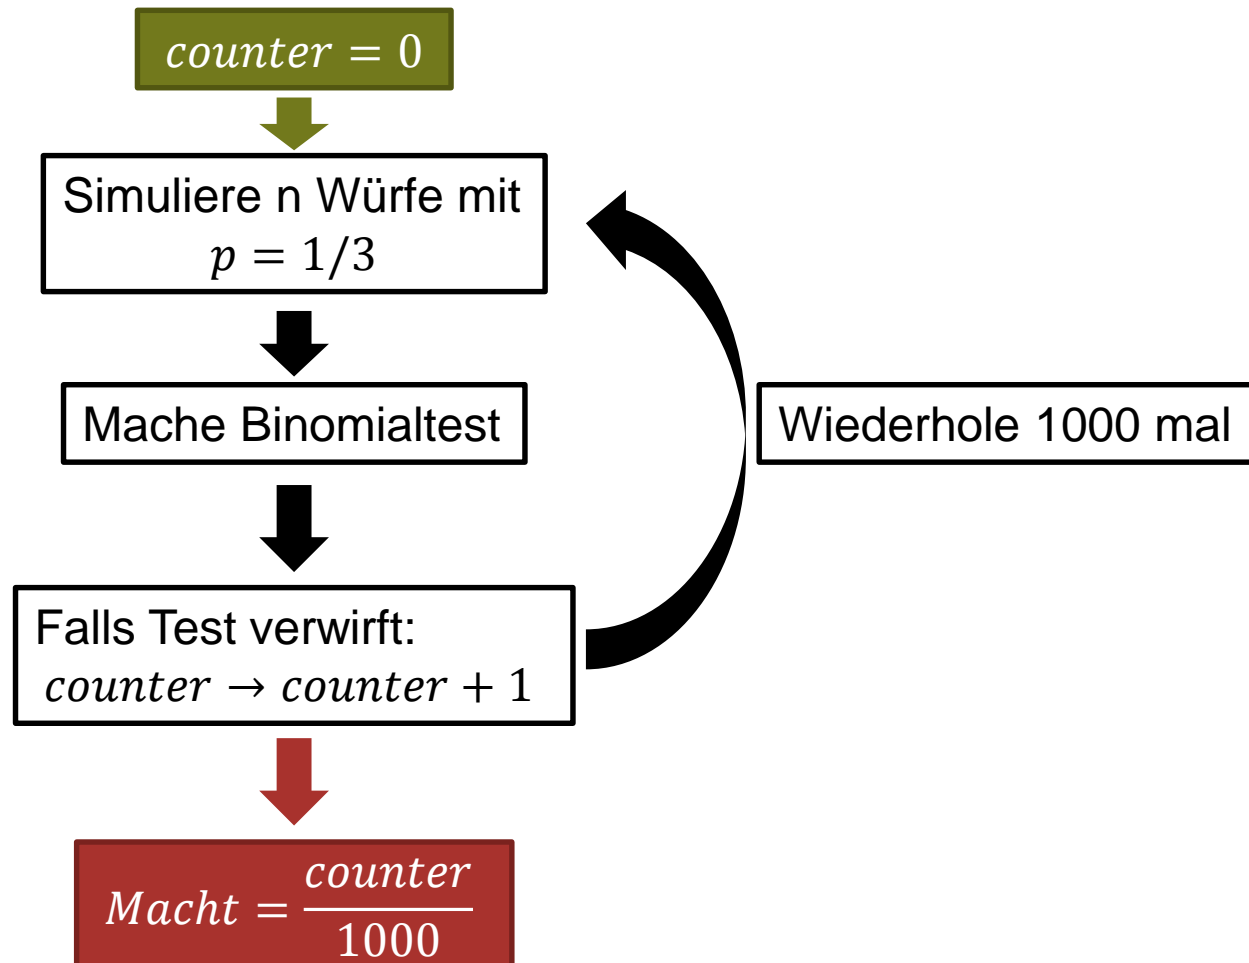
0 10 20 30 40 50

$n = 50 / c = 14$

## Berechnung der Macht: 2 Arten

- Mit Theorie (wie im Bsp Zauberwürfel)
  - + Genau, schnell berechnet
  - kompliziert → oft zu kompliziert
- Mit Simulation
  - + ***fast immer möglich***
  - Programmieraufwand, ungenau(er), evtl. langsam

# Zauberwürfel: Simulation







# Programmieren in R

- Vektoren, Matrizen
- Listen
- For-Schleifen
- Funktionen

## Quiz: Welches Ergebnis ?

```
f <- function(x=2, n=3) {  
  res <- vector("numeric", n)  
  for (i in 1:n) {  
    res[i] <- x*i  
  }  
  list(res1 = res[1], res2 = res[2])  
}  
f(x=3)$res2
```

- A: 2
- B: 3
- C: 4
- D: 5
- E: 6




# Macht beim Binomialtest

```
machtBinom <- function(n=50, reps = 1000, alpha = 0.05, pA = 0.7,  
                      p0 = 0.5, alt = "two.sided") {  
  res <- vector("numeric", reps)  
  for (i in 1:reps) {  
    x <- rbinom(n=1, size = n, prob = pA) ## Simuliere Daten  
    tmp <- binom.test(x, n = n, p = p0, alternative = alt) ## Mache Test  
    res[i] <- (tmp$p.value < alpha) ## Speichere Ergebnis  
  }  
  list(m = mean(res), s = sd(res)/sqrt(reps) )  
}
```

# Suche von Hand: Binäre Suche

Bsp: Nullstellensuche bei monotoner Funktion





# Macht beim t-Test

```
machtTtest2 <- function(n1=20, n2=20, m1=0, m2=1, s1=1, s2=1, reps = 1000, alpha = 0.05) {  
  ## Ungepaarter t-Test mit evtl. ungleichen Varianzen  
  res <- vector("numeric", reps)  
  for (i in 1:reps) {  
    x <- rnorm(n=n1, mean = m1, sd = s1) ## Simuliere Daten  
    y <- rnorm(n=n2, mean = m2, sd = s2)  
    tmp <- t.test(x,y, paired = FALSE) ## Mache Test  
    res[i] <- (tmp$p.value < alpha) ## Speichere Ergebnis  
  }  
  list(m=mean(res), s=sd(res)/sqrt(reps))  
}
```



# Macht bei 1-weg ANOVA

```
machtAnova1 <- function(n, mu, s=1, reps = 1000) {
  res <- vector("numeric", reps)
  for (i in 1:reps) {
    ## simuliere Daten
    x <- rep(LETTERS[1:length(n)], times = n)
    y <- vector("numeric",0)
    for (j in 1:length(n)) {
      y <- c(y,rnorm(n[j], mean = mu[j], sd = s))
    }
    df <- data.frame(x=x, y=y)
    ## Mache Test
    sm <- summary(aov(y~x, data = df))
    pval <- sm[[1]][[5]][1]
    ## speichere Ergebnis
    res[i] <- ( pval < alpha )
  }
  list(m = mean(res), s = sd(res)/sqrt(reps))
}
```



# Macht bei Linearer Regression (Steigung)

```
machtLM <- function(n = 5, b0 = 0, b1 = 1, s=1, reps = 1000, alpha = 0.05) {  
  res <- vector("numeric", reps)  
  for (i in 1:reps) {  
    ## Simuliere Daten  
    x <- runif(n=n, min = -1, max = 1)  
    y <- b0 + b1*x + rnorm(n, mean = 0, sd = s)  
    ## Mache Test  
    tmp <- lm(y~x)  
    pval <- summary(tmp)$coefficients[2,4]  
    ## Speichere Ergebnis  
    res[i] <- (pval < alpha)  
  }  
  list(m = mean(res), s = sd(res)/sqrt(reps))  
}
```



# Macht beim Fisher-Test

```
machtFisher <- function(n1 = 50, n2 = 50, p1 = 0.3, p2 = 0.1, reps = 1000, alpha = 0.05) {  
  res <- vector("numeric", reps)  
  for (i in 1:reps) {  
    ## Simuliere Daten  
    x1 <- rbinom(n=1, size=n1, prob=p1)  
    x2 <- n1 - x1  
    y1 <- rbinom(n=1, size=n2, prob=p2)  
    y2 <- n2 - y1  
    tt <- matrix(c(x1,y1,x2,y2),2,2)  
    ## Mache Test  
    tmp <- fisher.test(tt)  
    pval <- tmp$p.value  
    ## Ergebnis des Tests  
    res[i] <- (pval < alpha)  
  }  
  list(m = mean(res), s = sd(res)/sqrt(reps))  
}
```



## Exkurs: Falls $H_0$ nicht verworfen wird...

- Es gibt viele Varianten von “Post-hoc Power Analysis”  
Bsp:  $H_0$  wurde nicht verworfen, obwohl die Macht für  $p = \frac{1}{3}$  80% wäre; also muss der Würfel «ungefähr fair» sein
- Ungenaue Aussage; manche Varianten sind sogar falsch
- Besser: Vertrauensintervall
- Best practice:

**Vor dem Experiment: Power Analyse → Stichprobengrösse**  
**Nach dem Experiment: Vertrauensintervall**

Siehe: “The Abuse of Power: The Pervasive Fallacy of Power Calculations for Data Analysis”  
J.M. Hoenig, D.M. Heisey; The American Statistician, 2001, Vol. 55, No.1

# Schwierigkeit in Praxis

- Welche konkrete Alternative? Parameter?
- Verschiedene realistische Alternativen simulieren  
→ Gefühl für die richtige Grössenordnung der Stichprobengrösse