

# Biostatistik

## Wilcoxon's Rangsummen-Test

Matthias Birkner





JOHANNES GUTENBERG  
UNIVERSITÄT MAINZ

Bei (ungefähr) glockenförmigen und symmetrisch verteilten Beobachtungen oder wenn die Stichprobenumfänge genügend groß sind können wir den  $t$ -Test benutzen, um die Nullhypothese  $\mu_1 = \mu_2$  zu testen: Die  $t$ -Statistik ist (annähernd) Student-verteilt.

Besonders bei sehr asymmetrischen und langschwänzigen Verteilungen kann das anders sein

Nehmen wir an, wir sollten folgende Verteilungen vergleichen:



## Beispiele

- Wartezeiten
- Ausbreitungsentfernungen
- Zelltypenhäufigkeiten
- Genexpressionsniveaus

Gesucht:

ein „verteilungsfreier“ Test,  
mit dem man die Lage zweier Verteilungen  
zueinander testen kann

(Eine Aufgabe der *nicht-parametrischen Statistik*.)

## Beobachtungen: Zwei Stichproben

$$X : x_1, x_2, \dots, x_m$$

$$Y : y_1, y_2, \dots, y_n$$

Wir möchten die **Nullhypothese**:  
 $X$  und  $Y$  aus derselben Population  
( $X$  und  $Y$  haben **diesselbe Verteilung**)  
testen

gegen die **Alternative**:

Die beiden Verteilungen sind gegeneinander verschoben.

Wir sind also in einer Situation, die wir schon beim  $t$ -Test getroffen haben: Die zwei Verteilungen sind möglicherweise gegeneinander verschoben (haben insbesondere möglicherweise unterschiedliche Mittelwerte), aber wir möchten *nicht* die implizite Annahme treffen, dass es sich dabei (wenigstens ungefähr) um Normalverteilungen handelt.

# Idee

Beobachtungen:

$X : x_1, x_2, \dots, x_m$

$Y : y_1, y_2, \dots, y_n$

- Sortiere alle Beobachtungen der Größe nach.
- Bestimme die Ränge der  $m$   $X$ -Werte unter allen  $m + n$  Beobachtungen.
- Wenn die Nullhypothese zutrifft, sind die  $m$   $X$ -Ränge eine rein zufällige Wahl aus  $\{1, 2, \dots, m + n\}$ .
- Berechne die Summe der  $X$ -Ränge, prüfe, ob dieser Wert untypisch groß oder klein.

# Wilcoxons Rangsummenstatistik

Beobachtungen:

$X : x_1, x_2, \dots, x_m$

$Y : y_1, y_2, \dots, y_n$



Frank Wilcoxon,  
1892–1965

$U = \text{Summe der } X\text{-Ränge} - (1 + 2 + \dots + m)$   
heißt

**Wilcoxons Rangsummenstatistik**

(Der minimal mögliche Wert ist 0, der maximal mögliche Wert ist  $m \cdot n$ .)

# Wilcoxon's Rangsummenstatistik

Bemerkung:

$$U = \text{Summe der } X\text{-Ränge} - (1 + 2 + \dots + m)$$

Wir könnten auch die Summe der  $Y$ -Ränge benutzen, denn

$$\begin{aligned} & \text{Summe der } X\text{-Ränge} + \text{Summe der } Y\text{-Ränge} \\ &= \text{Summe aller Ränge} \\ &= 1 + 2 + \dots + (m + n) = \frac{(m + n)(m + n + 1)}{2} \end{aligned}$$

Bemerkung

Der Wilcoxon-Test heißt auch Mann-Whitney-Test.

In der Literatur sind verschiedene Zentrierungen der Rangsumme gebräuchlich, ggfs. prüfen, bevor Sie eine Formel aus einem Buch verwenden.

# Ein kleines Beispiel

- Beobachtungen:

$X$  : 1,5; 5,6; 35,2

$Y$  : 7,9; 38,1; 41,0; 56,7; 112,1; 197,4; 381,8

- Lege Beobachtungen zusammen und sortiere:

1,5; 5,6; 7,9; 35,2; 38,1; 41,0; 56,7; 112,1; 197,4; 381,8

- Bestimme Ränge:

1, 2, 3, 4, 5, 6, 7, 8, 9, 10

- Rangsumme:  $U = 1 + 2 + 4 - (1 + 2 + 3) = 1$

# Interpretation von $U$

X-Population kleiner  $\implies U$  klein:

1, 2, 3, 4, 5, 6, 7, 8, 9, 10  $U = 0$

1, 2, 3, 4, 5, 6, 7, 8, 9, 10  $U = 1$

1, 2, 3, 4, 5, 6, 7, 8, 9, 10  $U = 2$

1, 2, 3, 4, 5, 6, 7, 8, 9, 10  $U = 2$

X-Population größer  $\implies U$  groß:

1, 2, 3, 4, 5, 6, 7, 8, 9, 10  $U = 21$

1, 2, 3, 4, 5, 6, 7, 8, 9, 10  $U = 20$

1, 2, 3, 4, 5, 6, 7, 8, 9, 10  $U = 20$

1, 2, 3, 4, 5, 6, 7, 8, 9, 10  $U = 19$

# Signifikanz

Nullhypothese:  
 $X$ -Stichprobe und  $Y$ -Stichprobe  
 stammen aus  
 derselben Verteilung

Die 3 Ränge der  $X$ -Stichprobe

1 2 3 4 5 6 7 8 9 10


hätten genausogut irgendwelche 3 Ränge

1 2 3 4 5 6 7 8 9 10

sein können.

Es gibt  $\frac{10 \cdot 9 \cdot 8}{3 \cdot 2 \cdot 1} = 120$  Möglichkeiten.

(Allgemein:  $\frac{(m+n)(m+n-1)\dots(n+1)}{m(m-1)\dots 1} = \frac{(m+n)!}{n!m!} = \binom{m+n}{m}$  Möglichkeiten)

Verteilung der Wilcoxon-Statistik ( $m = 3, n = 7$ )


Unter der Nullhypothese sind alle Rangbelegungen gleich wahrscheinlich, also

$$\mathbb{P}(U = u) = \frac{\text{Anz. Möglichkeiten mit Rangsummenstatistik } u}{120}$$

Wir beobachten in unserem Beispiel:

1,5, 5,6; 7,9; 35,2; 38,1; 41,0; 56,7; 112,1; 197,4; 381,8  
somit  $U = 1$

$$\begin{aligned} & \mathbb{P}(U \leq 1) + \mathbb{P}(U \geq 20) \\ &= \mathbb{P}(U = 0) + \mathbb{P}(U = 1) + \mathbb{P}(U = 20) + \mathbb{P}(U = 21) \\ &= \frac{1+1+1+1}{120} \doteq 0,033 \end{aligned}$$

Verteilung der Wilcoxon-Statistik ( $m = 3, n = 7$ )

Für unser Beispiel ( $U = 1$ ) also:

$$p\text{-Wert} = \mathbb{P}(\text{ein so extremes } U) = 4/120 = 0,033$$

Wir **lehnen** die **Nullhypothese**,  
dass die Verteilungen  
von  $X$  und  $Y$   
identisch sind,  
auf dem 5%-Niveau **ab**.

R kennt den Wilcoxon-Test mittels `wilcox.test`:

```
> x <- c(1.5, 5.6, 35.2)
> y <- c(7.9, 38.1, 41.0, 56.7, 112.1, 197.4, 381.8)

> wilcox.test(x,y)
```

Wilcoxon rank sum test

data: x and y

$W = 1$ , p-value = 0.03333

alternative hypothesis: true location shift is  
not equal to 0

# Wilcoxon-Test: allgemeine Theorie

Gegeben zwei Stichproben  $x_1, x_2, \dots, x_m$  ( $m$   $x$ -Werte) und  $y_1, \dots, y_n$  ( $n$   $y$ -Werte)

bilde (normierte) Rangsumme

$$\begin{aligned} U &= \text{Summe aller } x\text{-Ränge} - (1 + 2 + \dots + m) \\ &= \sum_{i=1}^m \#\{j \leq n : x_i > y_j\} =: \sum_{i=1}^m U_i \end{aligned}$$

(mit möglichen Werten in  $0, 1, \dots, m \cdot n$ ).

Unter  $H_0$  : die  $x$ -Werte und die  $y$ -Werte sind unabhängige Stichproben aus derselben Verteilung

hängt die Verteilung von  $U$  nicht von der tatsächlichen Verteilung ab.

(Strenggenommen: Sofern die Verteilung „stetig“ ist, also kein Wert mehrmals vorkommen kann)

# Wilcoxon-Test: allgemeine Theorie, 2

normierte Rangsumme  $U = U_{m,n} = \sum_{i=1}^m \#\{j \leq n : x_i > y_j\}$

$H_0$  :  $x$ -Werte und  $y$ -Werte stammen aus derselben Verteilung

Die Verteilung von  $U_{m,n}$  unter  $H_0$  ist (prinzipiell) ein rein kombinatorisches Problem:

$$\mathbb{P}_{H_0}(U_{m,n} = u) = \frac{\# \left( \begin{array}{l} \text{Zuordnungen von } m \text{ Rängen an } x\text{-Werte,} \\ \text{die Rangsumme } u \text{ ergeben} \end{array} \right)}{\binom{m+n}{m}}$$

Für sehr kleine Stichproben kann man dies durch Auszählen bestimmen (wie vorhin), für größere Stichproben verwendet man eine Rekursionsformel (in R implementiert) oder eine Normalapproximation.

# Wilcoxon-Test: allgemeine Theorie, 3

$$\mathbb{P}_{H_0}(U_{m,n} = u) = \frac{\# \left( \begin{array}{l} \text{Zuordnungen von } m \text{ Rängen an } x\text{-Werte,} \\ \text{die Rangsumme } u \text{ ergeben} \end{array} \right)}{\binom{m+n}{m}}$$

(in R: `dwilcox(u,m,n)`, z.B. `dwilcox(1,3,7)=0.00833`, R kennt auch die Verteilungsfunktion `pwilcox` und die Quantilfunktion `qwilcox`.)

Quantile  $u_{m,n,\alpha}$  mit

$$\mathbb{P}_{H_0}(U_{m,n} \leq u_{m,n,\alpha}) = \alpha$$

für  $\alpha \in (0, 1)$  findet man in Tabellen  
(oder mit R: `qwilcox(\alpha,m,n)`)

# Zweiseitiger Wilcoxon-Rangsummen-Test

Gegeben  $m$   $x$ -Werte  $x_1, \dots, x_m$ ,  $n$   $y$ -Werte  $y_1, \dots, y_n$ ,  
Signifikanzniveau  $\alpha \in (0, 1)$ .

Bestimme (normierte) Rangsumme  $U = \sum_{i=1}^m \#\{j \leq n : x_i > y_j\}$ ,  
 $u_{m,n,1-\alpha/2}$  mit  $\mathbb{P}_{H_0}(U_{m,n} \leq u_{m,n,1-\alpha/2}) = 1 - \alpha/2$  (aus Tabelle oder  
mit R)

Lehne  $H_0$ : die  $x$ -Werte und die  $y$ -Werte sind unabhängige  
Stichproben aus derselben Verteilung

ab zugunsten von

$H_1$ : die Verteilung der  $x$ -Werte ist verschoben  
im Vergleich zu der der  $y$ -Werte

ab, falls

$$U > u_{m,n,1-\alpha/2} \quad \text{oder} \quad U < m \cdot n - u_{m,n,1-\alpha/2}$$

# Einseitiger Wilcoxon-Rangsummen-Test

Gegeben  $m$   $x$ -Werte  $x_1, \dots, x_m$ ,  $n$   $y$ -Werte  $y_1, \dots, y_n$ ,  
Signifikanzniveau  $\alpha \in (0, 1)$ .

Bestimme (normierte) Rangsumme  $U = \sum_{i=1}^m \#\{j \leq n : x_i > y_j\}$ ,  
 $u_{m,n,1-\alpha}$  mit  $\mathbb{P}_{H_0}(U_{m,n} \leq u_{m,n,1-\alpha}) = 1 - \alpha$  (aus Tabelle oder mit R)

Lehne  $H_0$  ab zugunsten von

$H_1$ : die Verteilung der  $x$ -Werte hat mehr Gewicht auf  
größten Werten im Vergleich zu der der  $y$ -Werte

ab, falls

$$U > u_{m,n,1-\alpha}$$

(analog für  $H_1$  : „Verteilung der  $x$ -Werte nach links verschoben  
im Vgl. zu  $y$ -Werten“, falls  $U < m \cdot n - u_{m,n,1-\alpha}$ ,  
oder vertausche Rollen von  $x$  und  $y$ .)

# Wilcoxon-Test: Normalapproximation

Unter  $H_0$  :  $x$ -Werte und  $y$ -Werte stammen aus derselben Verteilung

ist

$$\frac{U_{m,n} - \frac{m \cdot n}{2}}{\sqrt{\frac{mn(m+n+1)}{12}}} \approx \text{Standard-normalverteilt}$$

Damit lautet der (approximative) zweiseitige Test zum Signifikanzniveau  $\alpha$  bei beobachteter Rangsumme  $U$ :

$$\text{lehne } H_0 \text{ ab, wenn } \left| U - \frac{m \cdot n}{2} \right| > z_{1-\alpha/2} \sqrt{\frac{mn(m+n+1)}{12}}$$

wobei  $z_{1-\alpha/2} = (1 - \alpha/2)$ -Quantil der Standard-Normalverteilung

Analog einseitig ( $H_1 =$  „Verteilung der  $x$ -Werte nach rechts verschoben im Vgl. zu  $y$ -Werten“):

$$\text{Lehne } H_0 \text{ ab, falls } U > \frac{m \cdot n}{2} + z_{1-\alpha} \sqrt{\frac{mn(m+n+1)}{12}}.$$

# Wilcoxon-Test, Fall mit Bindungen

Bei diskreten Verteilungen (und in der Praxis!) kann es vorkommen, dass einzelne Werte in den Daten  $x_i$  und  $y_j$  mehrfach vorkommen. Dies nennt man **Bindungen**. In diesem Fall wird der Rang von  $x_i$  in den  $y_1, \dots, y_n$  berechnet als

$$U_i = \text{Anzahl der } j \text{ mit } y_j < x_i + \frac{1}{2} \text{Anzahl der } j \text{ mit } y_j = x_i$$

und die Rangsumme als

$$U = \sum_{i=1}^m U_i.$$

In diesem Fall hält der Wilcoxon-Test das geforderte Niveau nicht exakt ein, meistens aber doch recht gut. R gibt dann eine Warnmeldung.

## Beachte:

Wenn der Wilcoxon-Test Signifikanz anzeigt, so kann das daran liegen, dass die zugrunde liegenden Verteilungen verschiedene Formen haben.

Der Wilcoxon-Test kann beispielsweise Signifikanz anzeigen, **selbst wenn die Stichproben-Mittelwerte übereinstimmen!**

# Vergleich von $t$ -Test und Wilcoxon-Test

Sowohl der (2-Stichproben-)  $t$ -Test als auch der Wilcoxon-Test können verwendet werden, um eine vermutete Verschiebung der Verteilung zu stützen.

Der  $t$ -Test testet „nur“ auf Gleichheit der Erwartungswerte. Der Wilcoxon-Test dagegen testet auf Gleichheit der gesamten Verteilungen.

**In den meisten Fällen liefern beide Tests dasselbe Ergebnis.** Sofern die zugrundeliegenden Verteilungen einigermaßen glockenförmig sind, ist der  $t$ -Test empfehlenswerter.

In besonderen Fällen

- Verteilungen sind asymmetrisch
- Stichprobenlänge ist klein

hat der Wilcoxon-Test eine höhere Testpower.

## Vergleichen wir (spaßeshalber) mit dem $t$ -Test:

```
> x
[1] 1.5 5.6 35.2
> y
[1] 7.9 38.1 41.0 56.7 112.1 197.4 381.8
> t.test(x,y)
```

Welch Two Sample t-test

```
data: x and y
t = -2.0662, df = 6.518, p-value = 0.08061
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 -227.39182 17.02039
sample estimates:
mean of x mean of y
 14.1000 119.2857
```

