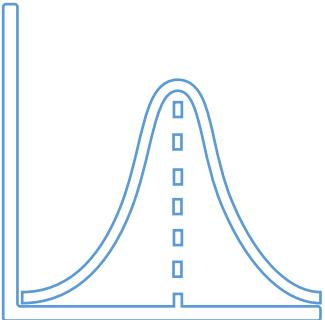


Statistik 1 – Tutorate

Sitzung 10: Mittelwertvergleiche

Marco Giesselmann, Norma De Min, Mara Moos, Lea Elina Hofer, Rémy Blum

Lernziele dieser Sitzung



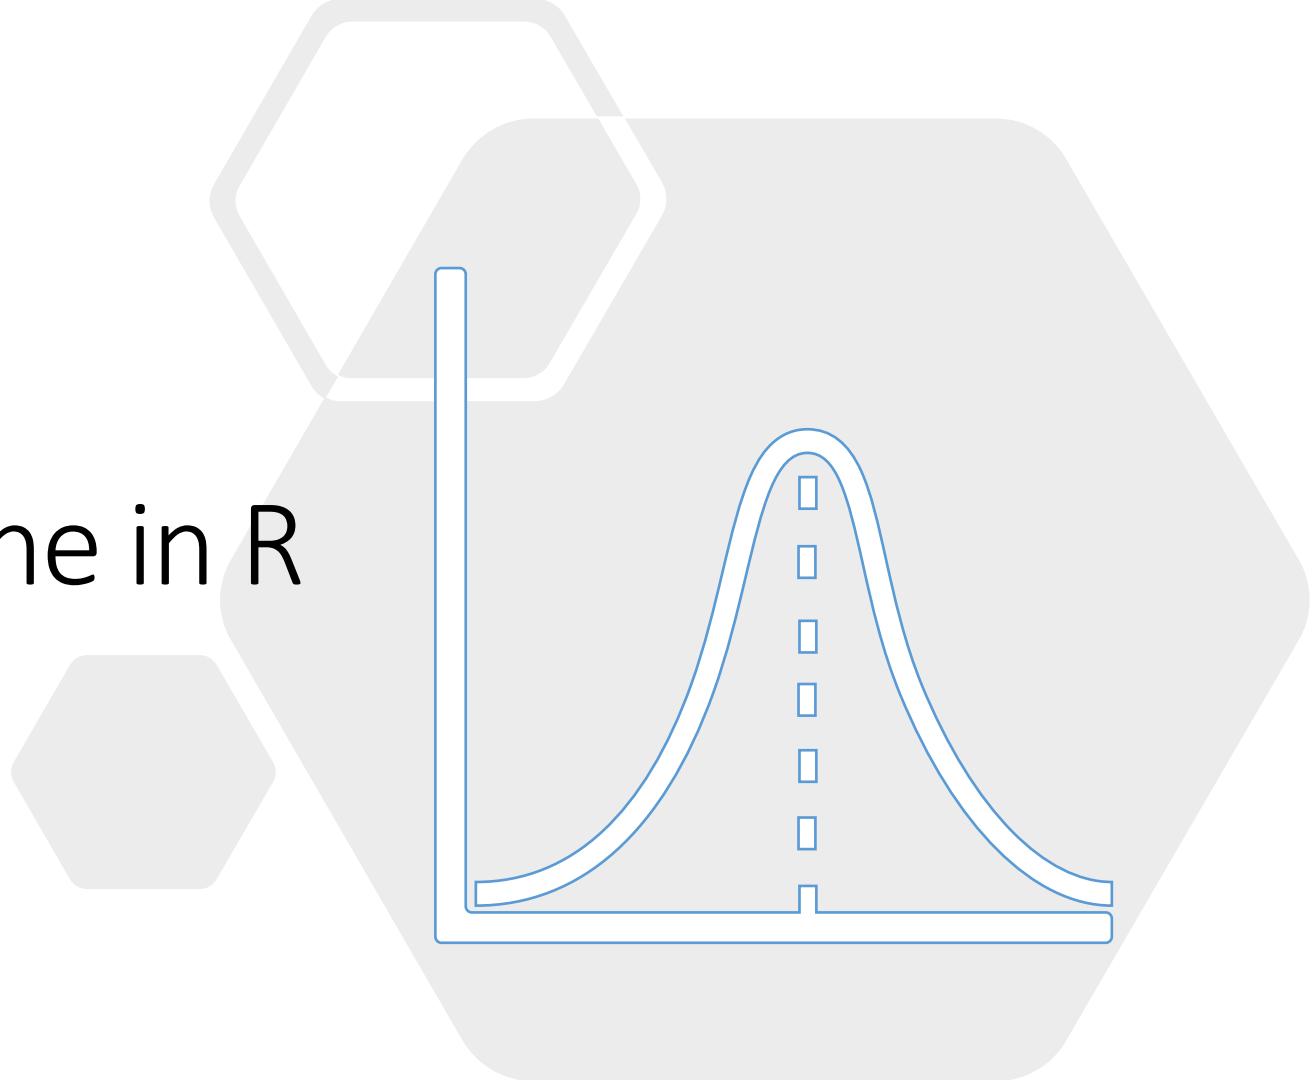
Mittelwertvergleiche in R

Recap: Mittelwertvergleich durch Gruppierung

Mittelwertvergleich durch **t.test**

(Visualisierung von Mittelwertvergleichen)

Mittelwertvergleiche in R



1

Recap: Mittelwertvergleich durch Gruppierung

Wir analysieren den Zusammenhang der Variablen **Erwerbstätigkeit neben dem Studium (Ja; Nein)** und **Lebenszufriedenheit (0 - sehr geringe Lebenszufriedenheit; 100 - sehr hohe Lebenszufriedenheit)** in der Statistik I-Kursumfrage.

Frage:

Welche **Perspektive auf den Zusammenhang** scheint euch hier sinnvoll? (Kausalrichtung? Tendenz?)

Recap: Mittelwertvergleich durch Gruppierung

Was ist vor der Analyse zu tun?

Vorbereitungen:

- Faktorisierung der unabhängigen, kategorialen Variable *sidejob* (nicht notwendig, aber sinnvoll)
- Bereinigung der abhängigen Variable *lezufr* (hier notwendig wegen falsch codiertem Missing)

	sidejob	lezufr
1	2	78
2	2	81
3	2	60
4	1	30
5	1	16
6	1	73
7	1	-99
8	2	80
9	2	69
10	2	70

```
kursdata_anon$lezufr[kursdata_anon$lezufr == -99] <- NA
```

```
kursdata_anon$sidejob <- as_factor(kursdata_anon$sidejob)
```

1

Recap: Mittelwertvergleich durch Gruppierung

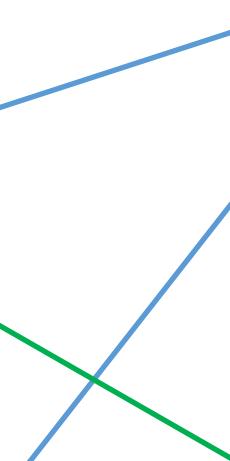
Zur Vorbereitung des Mittelwertvergleichs: Aufspaltung des Datensatzes nach Kategorien der UV

```
library(dplyr)
work <- filter(kursdata_anon, sidejob == "ja")
nowork <- filter(kursdata_anon, sidejob == "nein")
```

	sidejob sind sie neben dem studium erwerbstätig	lezufr Lebenszufriedenheit derzeit
1	ja	78
2	ja	81
3	ja	60
4	nein	30
5	nein	16
6	nein	73
7	nein	NA
8	ja	80
9	ja	69
10	ja	70

	sidejob sind sie neben dem studium erwerbstätig	lezufr Lebenszufriedenheit derzeit
1	ja	78
2	ja	81
3	ja	60
4	ja	80
5	ja	69
6	ja	70

	sidejob sind sie neben dem studium erwerbstätig	lezufr Lebenszufriedenheit derzeit
1	nein	30
2	nein	16
3	nein	73
4	nein	NA



1

Recap: Mittelwertvergleich durch Gruppierung

Ermittlung der Mittelwerte in den kategorien spezifischen Datensätzen bzw. Wertelisten

```
> mean(work$lezufr, na.rm = TRUE)  
[1] 69.01923  
> mean(nowork$lezufr, na.rm = TRUE)  
[1] 63.33333
```

Ergebnis?

Die durchschnittliche Lebenszufriedenheit arbeitender Studierender liegt etwa **5,7 Skalenpunkte (Mittelwertdifferenz)** oberhalb der von nicht arbeitenden Studierenden.

```
> sd(kursdata_anon$lezufr, na.rm = TRUE)  
[1] 21.046
```

Standardisierte Mittelwertdifferenz (Cohen's d):

Der durchschnittliche Zufriedenheitsüberhang arbeitender Studierender beträgt etwa ein Viertel (Cohen's d=0,27) der Standardabweichung der Lebenszufriedenheit.

Recap: Mittelwertvergleich durch Gruppierung

Ermittlung der Mittelwerte in den kategorien spezifischen Datensätzen bzw. Wertelisten

```
> mean(work$lezufr, na.rm = TRUE)
[1] 69.01923
> mean(nowork$lezufr, na.rm = TRUE)
[1] 63.33333
```

Ergebnis?

Die durchschnittliche Lebenszufriedenheit (Mittelwertdifferenz) oberhalb der von den nicht arbeitenden Studierenden ist mit ca.

Cohen's d effect size	Interpretation	Differences in SD
d=.0 – .19	Trivial effect	<1/5 from a SD
d=.20	Small effect	1/5 from a SD
d=.50	Medium effect	1/2 from a SD
d=.80 or higher	Large effect	8/10 from a SD

Interpretation of the results on d according to Cohen's (1992) recommendations

```
> sd(kursdaten)
[1] 21.046
```

Standardisierte Mittelwertdifferenz (Cohen's d):

Der durchschnittliche Zufriedenheitsüberhang arbeitender Studierender beträgt etwa ein Viertel (Cohen's d=0,27) der Standardabweichung der Lebenszufriedenheit.

2 Inferenzstatistik zur Mittelwertdifferenz per *t.test*

t-test mit R: Direkte Umsetzung

```
t.test(nowork$lezufr, work$lezufr, var.equal = TRUE)
```

Vergleiche die Mittelwerte der zuvor nach UV-Kategorien differenzierten Wertlisten

(Differenzierung der Werteliste erfolgte vorher, ausserhalb des Befehls)

Differenziere die Werteliste der Variable *vor* der Tilde nach Kategorien der Variable *hinter* der Tilde. Vergleiche dann die beiden Mittelwerte der Teillisten

(Differenzierung der Werteliste erfolgt innerhalb des Befehls)

Basisversion des t-tests

(mit Annahme, das Varianz in beiden Gruppen näherungsweise identisch ist)

```
t.test(formula = lezufr ~ sidejob, var.equal = TRUE, data = kursdata_anon)
```

t-test mit R: Standardumsetzung

2 Inferenzstatistik zur Mittelwertdifferenz per *t.test*

```
t.test(formula = lezufr ~ sidejob, var.equal = TRUE, data = kursdata_anon)
```

Two Sample t-test

```
data: lezufr by sidejob
t = -1.0363, df = 71, p-value = 0.3036
alternative hypothesis: true difference in means between group nein
and group ja is not equal to 0
95 percent confidence interval:
-16.62656 5.25476
sample estimates:
mean in group nein mean in group ja
63.33333      69.01923
```

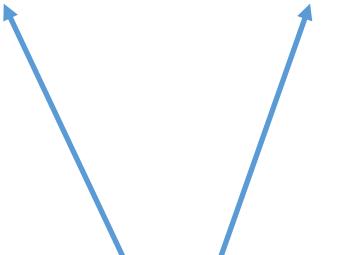
**Beschreibt die Elemente des Outputs zum t.test-Kommando
(ohne die konkreten Werte bereits zu interpretieren)**

2 Inferenzstatistik zur Mittelwertdifferenz per *t.test*

```
t.test(formula = lezufr ~ sidejob, var.equal = TRUE, data = kursdata_anon)
```

Two Sample t-test

```
data: lezufr by sidejob
t = -1.0363, df = 71, p-value = 0.3036
alternative hypothesis: true difference in means between group nein
and group ja is not equal to 0
95 percent confidence interval:
-16.62656 5.25476
sample estimates:
mean in group nein   mean in group ja
63.33333            69.01923
```



Die **Mittelwerte** entsprechen den manuell von uns berechneten Werten. Die von R abgeleitete Mittelwertdifferenz (Differenz zwischen erster und zweiter Gruppe) beträgt **-5,7**: *Nichterwerbstätige Studierende (hier Gruppe 1) sind im Mittel 5.7 Skalenpunkte weniger zufrieden als erwerbstätige Studierende*

2 Inferenzstatistik zur Mittelwertdifferenz per *t.test*

```
t.test(formula = lezufr ~ sidejob, var.equal = TRUE, data = kursdata_anon)
```

Two Sample t-test

```
data: lezufr by sidejob
t = -1.0363, df = 71, p-value = 0.3036
alternative hypothesis: true difference in means between group nein
and group ja is not equal to 0
95 percent confidence interval:
-16.62656 5.25476
sample estimates:
mean in group nein   mean in group ja
63.33333            69.01923
```

Wofür stehen in der Logik von R also **negative Mittelwertdifferenzen** in diesem empirischen Fall?

Die **Mittelwerte** entsprechen den manuell von uns berechneten Werten. Die von R abgeleitete Mittelwertdifferenz (Differenz zwischen erster und zweiter Gruppe) beträgt **-5,7**: *Nichterwerbstätige Studierende (hier Gruppe 1) sind im Mittel 5.7 Skalenpunkte weniger zufrieden als erwerbstätige Studierende*

2 Inferenzstatistik zur Mittelwertdifferenz per *t.test*

```
t.test(formula = lezufr ~ sidejob, var.equal = TRUE, data = kursdata_anon)
```

Two Sample t-test

```
data: lezufr by sidejob
t = -1.0363, df = 71, p-value = 0.3036
alternative hypothesis: true difference in means between group nein
and group ja is not equal to 0
95 percent confidence interval:
-16.62656 5.25476
sample estimates:
mean in group nein    mean in group ja
63.33333               69.01923
```

Wofür stehen in der Logik von R also **negative Mittelwertdifferenzen** in diesem empirischen Fall?

- Negative Mittelwertdifferenzen zeigen einen **höheren Mittelwert der zweiten Gruppe** im Vergleich zur ersten Gruppe an
-verweisen also in diesem Fall auf einen mittleren Zufriedenheitsunterschied **zugunsten der erwerbstätigen Studierenden**

Die **Mittelwerte** entsprechen den manuell von uns berechneten Werten. Die von R abgeleitete Mittelwertdifferenz (Differenz zwischen erster und zweiter Gruppe) beträgt **-5,7**: *Nichterwerbstätige Studierende (hier Gruppe 1) sind im Mittel 5,7 Skalenpunkte weniger zufrieden als erwerbstätige Studierende*

2 Inferenzstatistik zur Mittelwertdifferenz per *t.test*

```
t.test(formula = lezufr ~ sidejob, var.equal = TRUE, data = kursdata_anon)
```

Two Sample t-test

```
data: lezufr by sidejob
t = -1.0363, df = 71, p-value = 0.3036
alternative hypothesis: true difference in means between group nein
and group ja is not equal to 0
95 percent confidence interval:
-16.62656 5.25476
sample estimates:
mean in group nein    mean in group ja
63.33333              69.01923
```

Wofür stehen in der Logik von R also **positive Mittelwertdifferenzen** in diesem empirischen Fall?

- Positive Mittelwertdifferenzen zeigen einen **tieferen Mittelwert der zweiten Gruppe** im Vergleich zur ersten Gruppe an
-verweisen also in diesem Fall auf einen mittleren Zufriedenheitsunterschied **zugunsten der nicht-erwerbstätigen Studierenden**

Die **Mittelwerte** entsprechen den manuell von uns berechneten Werten. Die von R abgeleitete Mittelwertdifferenz (Differenz zwischen erster und zweiter Gruppe) beträgt **-5,7**: **Nichterwerbstätige Studierende (hier Gruppe 1)** sind im Mittel 5,7 Skalenpunkte weniger zufrieden als **erwerbstätige Studierende**

2 Inferenzstatistik zur Mittelwertdifferenz per *t.test*

```
t.test(formula = lezufr ~ sidejob, var.equal = TRUE, data = kursdata_anon)
Two Sample t-test

data: lezufr by sidejob
t = -1.0363, df = 71, p-value = 0.3036
alternative hypothesis: true difference in means between group
and group ja is not equal to 0
95 percent confidence interval:
-16.62656 5.25476
sample estimates:
mean in group nein    mean in group ja
63.33333              69.01923
```

Sowohl ein wahrer Zufriedenheitsunterschied zugunsten der Erwerbstätigen als auch zugunsten der Nichterwerbstätigen liegt ausweislich des ermittelten Konfidenzintervalls im Bereich des Möglichen!

Wofür stehen in der Logik von R also **positive Mittelwertdifferenzen** in diesem empirischen Fall?

- Positive Mittelwertdifferenzen zeigen einen **tieferen Mittelwert der zweiten Gruppe** im Vergleich zur ersten Gruppe an
-verweisen also in diesem Fall auf einen mittleren Zufriedenheitsunterschied **zugunsten der nicht-erwerbstätigen Studierenden**

Die **Mittelwerte** entsprechen den manuell von uns berechneten Werten. Die von R abgeleitete Mittelwertdifferenz (Differenz zwischen erster und zweiter Gruppe) beträgt **-5,7**: **Nichterwerbstätige Studierende (hier Gruppe 1)** sind im Mittel 5,7 Skalenpunkte weniger zufrieden als erwerbstätige Studierende

2 Inferenzstatistik zur Mittelwertdifferenz per *t.test*

```
t.test(formula = lezufr ~ sidejob, var.equal = TRUE, data = kursdata_anon)
```

Two Sample t-test

```
data: lezufr by sidejob
t = -1.0363, df = 71, p-value = 0.3036
alternative hypothesis: true difference in means between group nein
and group ja is not equal to 0
95 percent confidence interval:
-16.62656 5.25476
sample estimates:
mean in group nein    mean in group ja
63.33333              69.01923
```

Konkret: Mit 95% Sicherheit liegt der wahre mittlere Unterschied der Lebenszufriedenheit zwischen 16.6 Punkten zugunsten der Erwerbstätigen und 5.2 Punkten zugunsten der Nicht-Erwerbstätigen.

Wofür stehen in der Logik von R also **positive Mittelwertdifferenzen** in diesem empirischen Fall?

- Positive Mittelwertdifferenzen zeigen einen **tieferen Mittelwert der zweiten Gruppe** im Vergleich zur ersten Gruppe an
-verweisen also in diesem Fall auf einen mittleren Zufriedenheitsunterschied **zugunsten der nicht-erwerbstätigen Studierenden**

Die **Mittelwerte** entsprechen den manuell von uns berechneten Werten. Die von R abgeleitete Mittelwertdifferenz (Differenz zwischen erster und zweiter Gruppe) beträgt **-5,7**: **Nichterwerbstätige Studierende (hier Gruppe 1)** sind im Mittel 5.7 Skalenpunkte weniger zufrieden als erwerbstätige Studierende

2 Inferenzstatistik zur Mittelwertdifferenz per *t.test*

```
t.test(formula = lezufr ~ sidejob, var.equal = TRUE, data = kursdata_anon)
```

Two Sample t-test

```
data: lezufr by sidejob
t = -1.0363, df = 71, p-value = 0.3036
alternative hypothesis: true difference in means between group nein
and group ja is not equal to 0
95 percent confidence interval:
-16.62656 5.25476
sample estimates:
mean in group nein    mean in group ja
63.33333            69.01923
```

Oder: Mit 95% Sicherheit sind die Erwerbstätigen in der Population zwischen 16.6 Skalenpunkte zufriedener und 5.3 Skalenpunkten unzufriedener als die Nicht-Erwerbstätigen.

Wofür stehen in der Logik von R also **positive Mittelwertdifferenzen** in diesem empirischen Fall?

- Positive Mittelwertdifferenzen zeigen einen **tieferen Mittelwert der zweiten Gruppe** im Vergleich zur ersten Gruppe an
-verweisen also in diesem Fall auf einen mittleren Zufriedenheitsunterschied **zugunsten der nicht-erwerbstätigen Studierenden**

Die **Mittelwerte** entsprechen den manuell von uns berechneten Werten. Die von R abgeleitete Mittelwertdifferenz (Differenz zwischen erster und zweiter Gruppe) beträgt **-5,7**: **Nichterwerbstätige Studierende (hier Gruppe 1)** sind im Mittel 5.7 Skalenpunkte weniger zufrieden als erwerbstätige Studierende

2 Inferenzstatistik zur Mittelwertdifferenz per *t.test*

Die Wahrscheinlichkeit, dass eine Population ohne Mittelwertdifferenz ein Stichprobenergebnis erzeugt, welches mindestens eine so hohe Mittelwertdifferenz wie unsere Stichprobe aufweist, liegt bei etwa 30,4%

```
t.test(formula = lezufr ~ sidejob, var.equal = TRUE, data = kursdata_anon)
```

Two Sample t-test

```
data: lezufr by sidejob
t = -1.0363, df = 71, p-value = 0.3036
alternative hypothesis: true difference in means between group nein
and group ja is not equal to 0
95 percent confidence interval:
-16.62656 5.25476
sample estimates:
mean in group nein    mean in group ja
63.33333            69.01923
```

Oder: Mit 95% Sicherheit sind die Erwerbstätigen in der Population zwischen 16,6 Skalenpunkten zufriedener und 5,3 Skalenpunkten unzufriedener als die Nicht-Erwerbstätigen.

Wofür stehen in der Logik von R also **positive Mittelwertdifferenzen** in diesem empirischen Fall?

- Positive Mittelwertdifferenzen zeigen einen **tieferen Mittelwert der zweiten Gruppe** im Vergleich zur ersten Gruppe an
-verweisen also in diesem Fall auf einen mittleren Zufriedenheitsunterschied **zugunsten der nicht-erwerbstätigen Studierenden**

Die **Mittelwerte** entsprechen den manuell von uns berechneten Werten. Die von R abgeleitete Mittelwertdifferenz (Differenz zwischen erster und zweiter Gruppe) beträgt **-5,7**: **Nichterwerbstätige Studierende (hier Gruppe 1)** sind im Mittel 5,7 Skalenpunkte weniger zufrieden als erwerbstätige Studierende

2 Inferenzstatistik zur Mittelwertdifferenz per *t.test*

...die Nullhypothese, dass arbeitende und nicht-arbeitende Soziologiestudierende sich in der Population nicht in der mittleren Lebenszufriedenheit unterscheiden, kann also wegen $p>0.05$ nicht abgelehnt werden

```
t.test(formula = lezufr ~ sidejob, var.equal = TRUE, data = kursdata_anon)
```

Two Sample t-test

```
data: lezufr by sidejob
t = -1.0363, df = 71, p-value = 0.3036
alternative hypothesis: true difference in means between group nein
and group ja is not equal to 0
95 percent confidence interval:
-16.62656 5.25476
sample estimates:
mean in group nein    mean in group ja
63.33333            69.01923
```

Oder: Mit 95% Sicherheit sind die Erwerbstätigen in der Population zwischen 16.6 Skalenpunkte zufriedener und 5.3 Skalenpunkten unzufriedener als die Nicht-Erwerbstätigen.

Wofür stehen in der Logik von R also **positive Mittelwertdifferenzen** in diesem empirischen Fall?

- Positive Mittelwertdifferenzen zeigen einen **tieferen Mittelwert der zweiten Gruppe** im Vergleich zur ersten Gruppe an
-verweisen also in diesem Fall auf einen mittleren Zufriedenheitsunterschied **zugunsten der nicht-erwerbstätigen Studierenden**

Die **Mittelwerte** entsprechen den manuell von uns berechneten Werten. Die von R abgeleitete Mittelwertdifferenz (Differenz zwischen erster und zweiter Gruppe) beträgt **-5,7**: **Nichterwerbstätige Studierende (hier Gruppe 1)** sind im Mittel 5.7 Skalenpunkte weniger zufrieden als erwerbstätige Studierende

2

Vergleich: Unterschiedliche Varianten des *t.test*-Kommandos

```
t.test(formula = lezufr ~ sidejob, var.equal = TRUE, data = kursdata_anon)
data: lezufr by sidejob
t = -1.0363, df = 71, p-value = 0.3036
alternative hypothesis: true difference in means between group nein
and group ja is not equal to 0
95 percent confidence interval:
 -16.62656 5.25476
sample estimates:
mean in group nein mean in group ja
 63.33333      69.01923
```

Unterschiede im Ergebnisoutput zwischen den beiden R-basierten *t.test* - Umsetzungsvarianten?

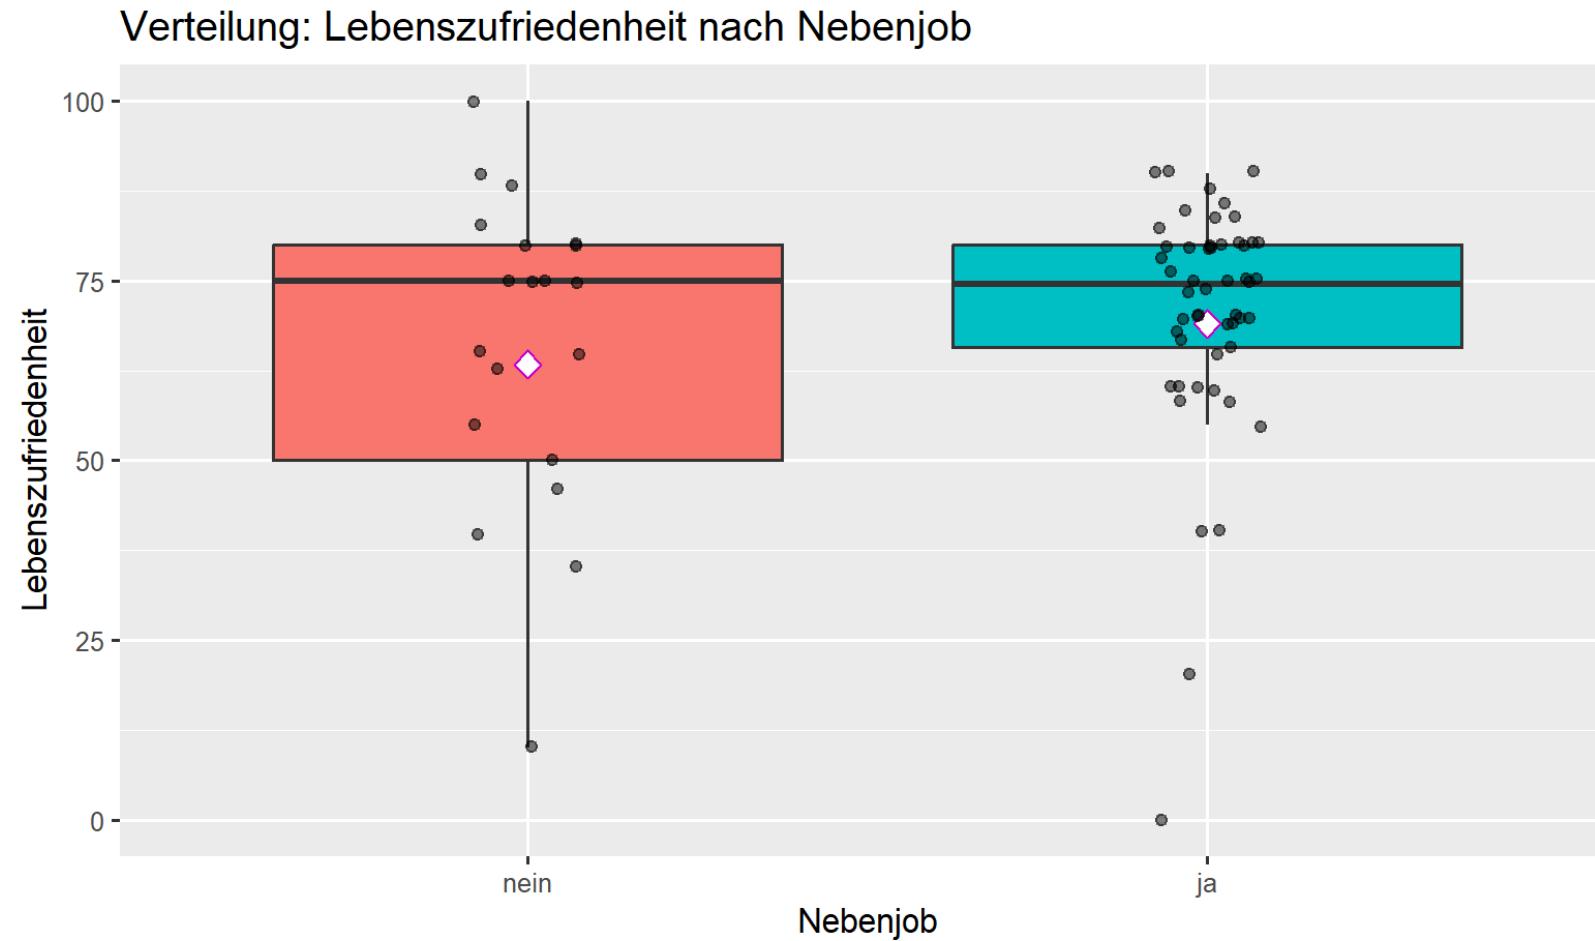
- Ergebnisdarstellung weitgehend identisch
- Kategorienspezifische Mittelwerte sind in der Standardvariante (**oben**) mit Kategoriennamen gelabelt, in der direkten Variante (**unten**) dagegen abstrakt mit x / y (Positionen korrespondieren dabei zur Reihenfolge unter «data: ... and ...»)

```
t.test(nowork$lezufr, work$lezufr, var.equal = TRUE)
data: nowork$lezufr and work$lezufr
t = -1.0363, df = 71, p-value = 0.3036
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 -16.62656 5.25476
sample estimates:
mean of x mean of y
 63.33333      69.01923
```

3

Visualisierung von Mittelwertvergleichen

Siehe Homepage...



Quelle: Kursbefragung Statistik I (n = 73)