

EBERHARD KARLS
UNIVERSITÄT
TÜBINGEN



SFB 833 Bedeutungskonstitution



Kompaktkurs Datenanalyse

Projekt Z2

Tübingen, Mittwoch, 18. und 20. März 2015

Messen und Skalen

Relativ (Relationensystem): Menge A von Objekten und eine oder mehrere Relationen R_1, \dots, R_n , mit denen die Beziehungen der Objekte untereinander charakterisiert wird

$$\langle A, R_1, \dots, R_n \rangle$$

Empirisches Relativ: Menge A von Objekten des Untersuchungsgegenstands und eine (oder mehrere) interessierende Relationen R_1, \dots, R_n , zwischen (Eigenschaften von) ihnen

Numerisches Relativ: Menge R der reellen Zahlen und eine oder mehrere gültige Relationen S_1, \dots, S_n , zwischen ihnen, z.B. gleich/ungleich ($=, \neq$) oder größer/kleiner-als ($<, >$)

Messen und Skalen

Messen: homomorphe Abbildung von einem empirischen Relativ in ein numerisches Relativ

Eine Abbildung ist z.B. dann homomorph, wenn für alle Paare $a, b \in A$ und Messwerte (bzw. Skalenwerte) $\varphi(a), \varphi(b) \in \mathbb{R}$ gilt:

$$a \succcurlyeq b \Leftrightarrow \varphi(a) \geq \varphi(b)$$

Skala: empirisches Relativ, numerisches Relativ plus homomorphe Abbildungsfunktion



beantwortet die Frage, welche Relationen im numerischen Relativ gültige Relationen sind

Messen und Skalen

Nominalskala (klassifikatorische Messstruktur)

gültige Relation im empirischen Relativ: Äquivalenz \sim

- $a \sim a$ Reflexivität
- $a \sim b \rightarrow b \sim a$ Symmetrie
- $a \sim b \wedge b \sim c \rightarrow a \sim c$ Transitivität

$$a \sim b \Leftrightarrow \varphi(a) = \varphi(b)$$

gültige Relation im numerischen Relativ: $=, \neq$

Beispiel: Satz ist grammatisch versus ungrammatisch

Messen und Skalen

Ordinalskala bzw. Rangskala

gültige Relation im empirischen Relativ: schwache Ordnungsrelation \succsim

- $a \succsim b \vee b \succsim a$ Konnexität
- $a \succsim b \wedge a \succsim b \rightarrow a \succsim b$ Transitivität

$$a \succsim b \Leftrightarrow \varphi(a) \geq \varphi(b)$$

gültige Relation im numerischen Relativ: $<, =, >$

Beispiel: Satz ist akzeptabler als, ebenso akzeptabel wie, weniger akzeptabel als ein Referenzsatz

Messen und Skalen

Intervallskala

gültige Relation im empirischen Relativ: schwache Ordnungsrelation \succsim für Differenzen von Paaren von Objekten (verkürzt)

- $ab \succsim cd \vee cd \succsim ab$ Konnexität der Differenzen
- $ab \succsim cd \wedge cd \succsim ef \rightarrow ab \succsim ef$ Transitivität der Differenzen

$$ab \succsim cd \Leftrightarrow \varphi(a) - \varphi(b) \geq \varphi(c) - \varphi(d)$$

gültige Relation im numerischen Relativ: $<$, $=$, $>$ für Differenzen

Beispiel: Satz bekommt auf einer Ratingskala zwischen 1 („inakzeptabel“) und 5 („völlig akzeptabel“) einen Wert zugeordnet; **Annahme:** die Punkte auf der Skala sind gleichabständig

Frage: ist die **Annahme** gerechtfertigt?

Messen und Skalen

Verhältnisskala

gültige Relation im empirischen Relativ: schwache Ordnungsrelation \succsim für
Verhältnisse von Paaren von Objekten: **Skala hat einen Nullpunkt!**

- ...

Beispiel? Reaktionszeiten

Frage: haben Reaktionszeiten einen Nullpunkt?

Messen und Skalen

Exkurs: haben Reaktionszeiten einen Nullpunkt?

Beispiel: Hypothese über Zugriff auf einen Eintrag im mentalen Lexikon

Test über lexikalische Entscheidungsaufgabe: Stimulus = String (Wort/Non-Wort)

Response: Antwort **JA-Taste** (Wort) oder **NEIN-Taste** (Non-Wort) drücken

AV: Zeit (RT) vom Onset der Stimulusdarbietung bis zur Response für Wort

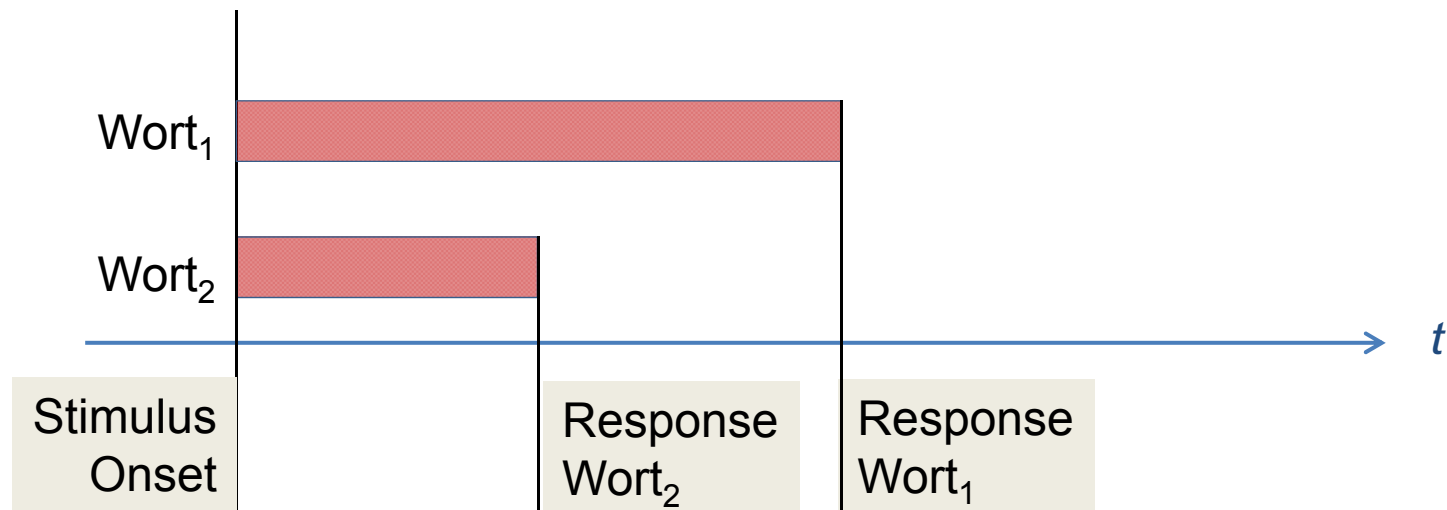
nehmen wir an: $RT(\text{Wort}_1) = 2 \cdot RT(\text{Wort}_2)$

Ist der Zugriff im mentalen Lexikon auf Wort_2 doppelt so schnell wie auf Wort_1 ?

Messen und Skalen

Exkurs: haben Reaktionszeiten einen Nullpunkt?

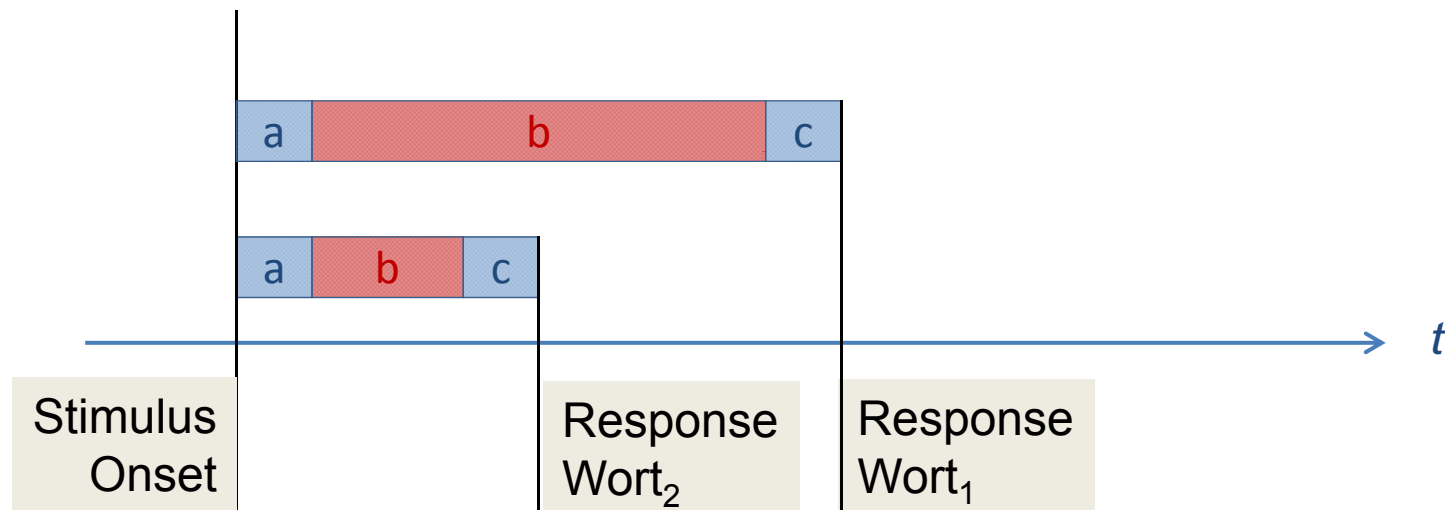
Ist der Zugriff im mentalen Lexikon auf Wort₂ doppelt so schnell wie auf Wort₁?



Messen und Skalen

Exkurs: haben Reaktionszeiten einen Nullpunkt?

Ist der Zugriff im mentalen Lexikon auf Wort₂ doppelt so schnell wie auf Wort₁?



- a Enkodierung des Stimulus
- b Zugriff im mentalen Lexikon
- c Response-Generierung

Messen und Skalen

Verhältnisskala

gültige Relation im empirischen Relativ: schwache Ordnungsrelation \succsim für
Verhältnisse von Paaren von Objekten: **Skala hat einen Nullpunkt!**

- ...

Beispiel? Reaktionszeiten

Frage: haben Reaktionszeiten einen Nullpunkt?


Häufigkeitsverteilungen: statistische Kennwerte

Häufigkeitsverteilungen: statistische Kennwerte

Charakterisierung einer Häufigkeitsverteilung durch statistische Kennwerte

- Maße der zentralen Tendenz
- Dispersionsmaße

Beispiel: Binomial-Verteilung bei zwei gleich wahrscheinlichen Ereignissen ($n=4$)




Achtung: tatsächlich handelt es sich um erwartete, nicht um beobachtete Häufigkeiten

Häufigkeitsverteilungen: statistische Kennwerte

Maße der zentralen Tendenz

- Modalwert (**Mo**)
- Median (**Md**)
- Arithmetisches Mittel (**AM**; Mittelwert)


Häufigkeit von Ereignis A ($p=0.5$)



Häufigkeitsverteilungen: statistische Kennwerte

Maße der zentralen Tendenz


- Modalwert (**Mo**) = Kategorie, die am häufigsten vorkommt; hier: **2x|4x** anwendbar auf **nominalskalierte** Daten



Häufigkeitsverteilungen: statistische Kennwerte

Maße der zentralen Tendenz

- Median (**Md**) = Wert, der bei Rangreihung aller Werte in der Mitte liegt; $N = 1251$; hier: der 626. Wert liegt in Kategorie **2x|4x**
anwendbar auf **ordinalskalierte** Daten

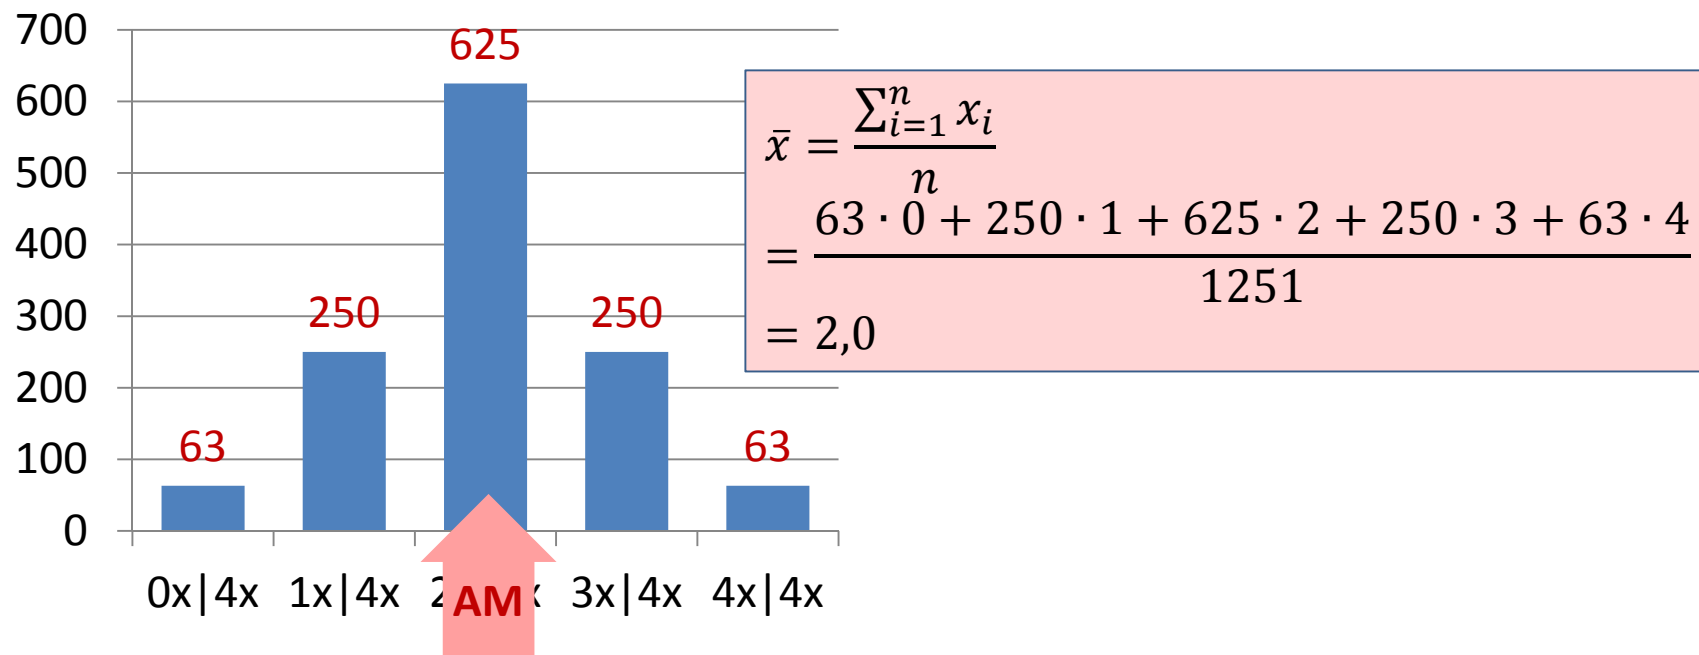


Häufigkeitsverteilungen: statistische Kennwerte

Maße der zentralen Tendenz

- Arithmetisches Mittel (**AM**) = Wert, dessen aufsummierten quadrierten Abweichungen ein Minimum ein Minimum ergibt
anwendbar auf **intervallskalierte** Daten

Häufigkeit von Ereignis A ($p=0.5$)

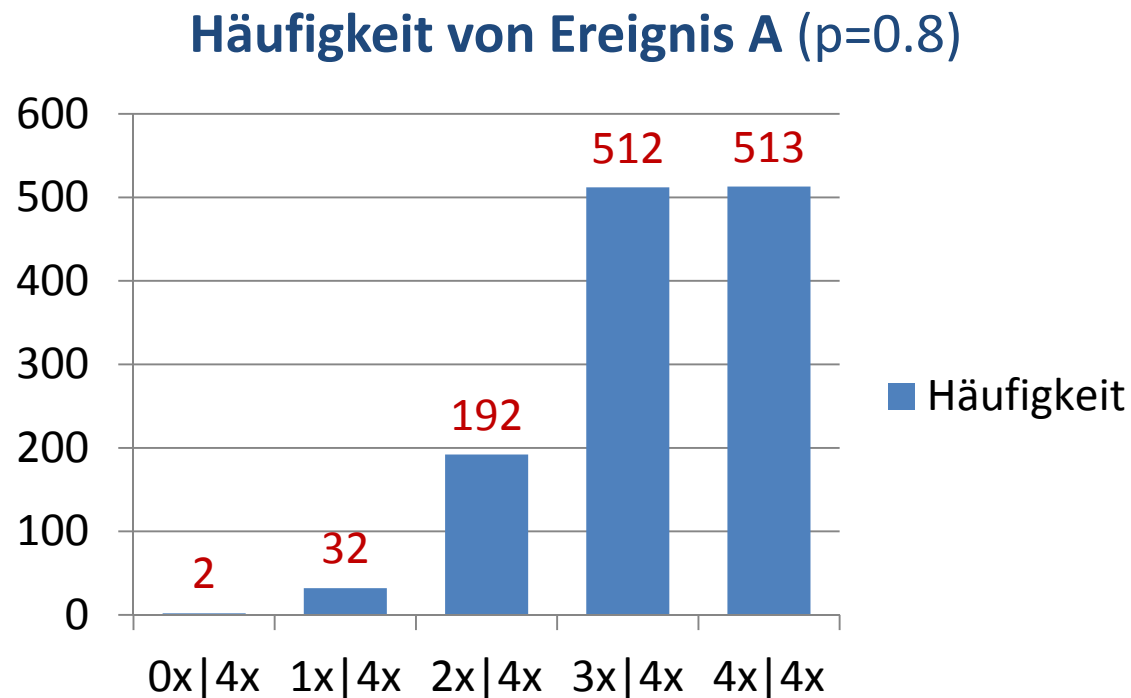


Häufigkeitsverteilungen: statistische Kennwerte

Charakterisierung einer Häufigkeitsverteilung durch statistische Kennwerte

- Maße der zentralen Tendenz
- Dispersionsmaße

Bsp.: Binomial-Verteilung bei zwei ungleich wahrscheinlichen Ereignissen ($n=4$)




Achtung: tatsächlich handelt es sich um erwartete, nicht um beobachtete Häufigkeiten

Häufigkeitsverteilungen: statistische Kennwerte

Maße der zentralen Tendenz

- Modalwert (**Mo**) = Kategorie, die am häufigsten vorkommt; hier: **4x|4x** anwendbar auf **nominalskalierte** Daten




Häufigkeitsverteilungen: statistische Kennwerte

Maße der zentralen Tendenz

- Median (**Md**) = Wert, der bei Rangreihung aller Werte in der Mitte liegt; $N = 1251$; hier: der 626. Wert liegt in Kategorie **3x|4x**
anwendbar auf **ordinalskalierte Daten**

Häufigkeit von Ereignis A ($p=0.8$)



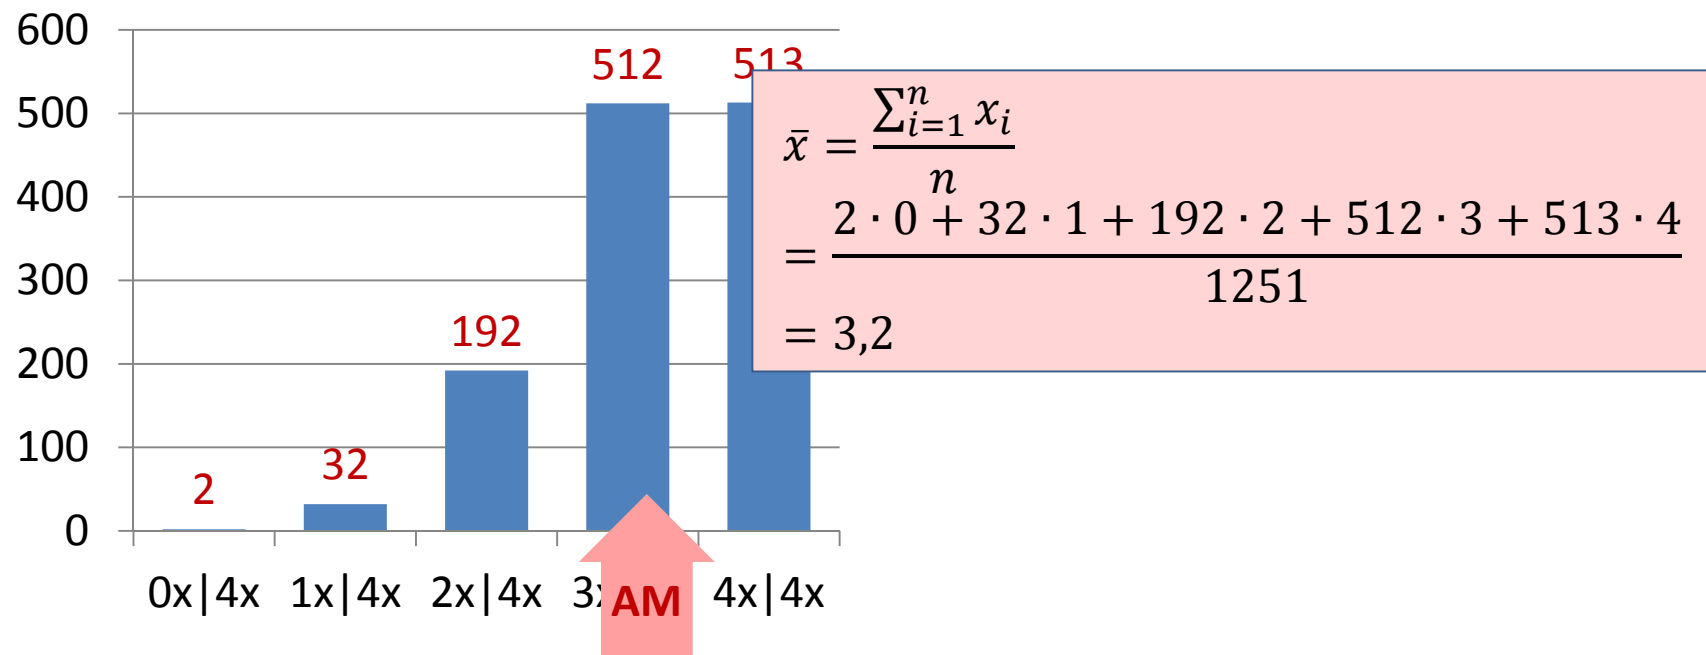
Linear interpolierter **Md** = 3.28
Kum. Häufigkeit bis 2x|4x: 226
400 aus 512 bis 626

Häufigkeitsverteilungen: statistische Kennwerte

Maße der zentralen Tendenz

- Arithmetisches Mittel (**AM**) = Wert, dessen aufsummierten quadrierten Abweichungen ein Minimum ein Minimum ergibt
anwendbar auf **intervallskalierte** Daten

Häufigkeit von Ereignis A (p=0.8)




Häufigkeitsverteilungen: statistische Kennwerte

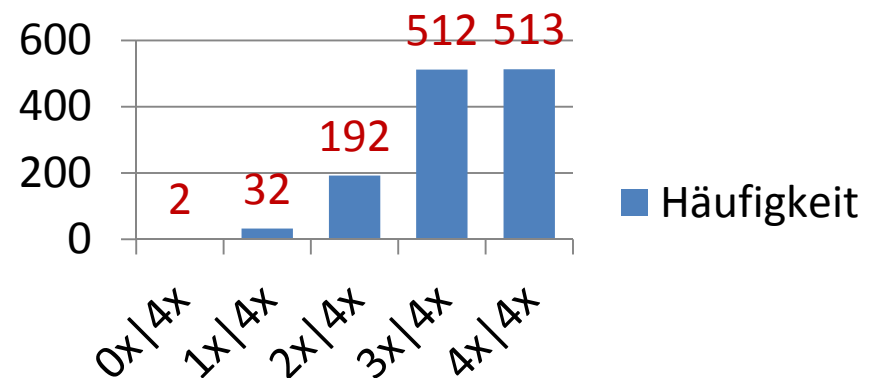
Maße der zentralen Tendenz: Zusammenfassung

- Für symmetrische Verteilungen fallen **Mo**, **Md** und **AM** zusammen
- Für asymmetrische Verteilungen (z.B. rechtsgipflig/linksschief) gilt:
 - linear interpolierter **Md** liegt näher am **Mo** als **AM** aufgrund der höheren Gewichtung größerer Abweichungen

Häufigkeit von Ereignis A
($p=0.5$)




Häufigkeit von Ereignis A
($p=0.8$)



Häufigkeitsverteilungen: statistische Kennwerte

Dispersionsmaße

- AD-Streuung (AD = average deviation)
- Varianz und Standardabweichung




Häufigkeitsverteilungen: statistische Kennwerte

Dispersionsmaße

- AD-Streuung (AD = average deviation): mittlere Abweichung (Distanz) vom arithmetischen Mittel
anwendbar auf **intervallskalierte** Daten

Häufigkeit von Ereignis A (p=0.5)




$$AD = \frac{\sum_{i=1}^n |x_i - \bar{x}|}{n} = \frac{63 \cdot |-2.0| + 250 \cdot |-1.0| + 250 \cdot |+1.0| + 63 \cdot |+2.0|}{1251} = 0.601$$

Häufigkeitsverteilungen: statistische Kennwerte

Dispersionsmaße

- Varianz s^2 (und Standardabweichung s): mittlere quadrierte Abweichung vom Mittel (und deren Quadratwurzel)
anwendbar auf **intervallskalierte** Daten


Häufigkeit von Ereignis A ($p=0.5$)



$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n} = \frac{63 \cdot (-2.0)^2 + 250 \cdot (-1.0)^2 + 250 \cdot (+1.0)^2 + 63 \cdot (+2.0)^2}{1251} = 0.803$$

$$s = \sqrt{s^2} = \sqrt{0.803} = 0.896$$

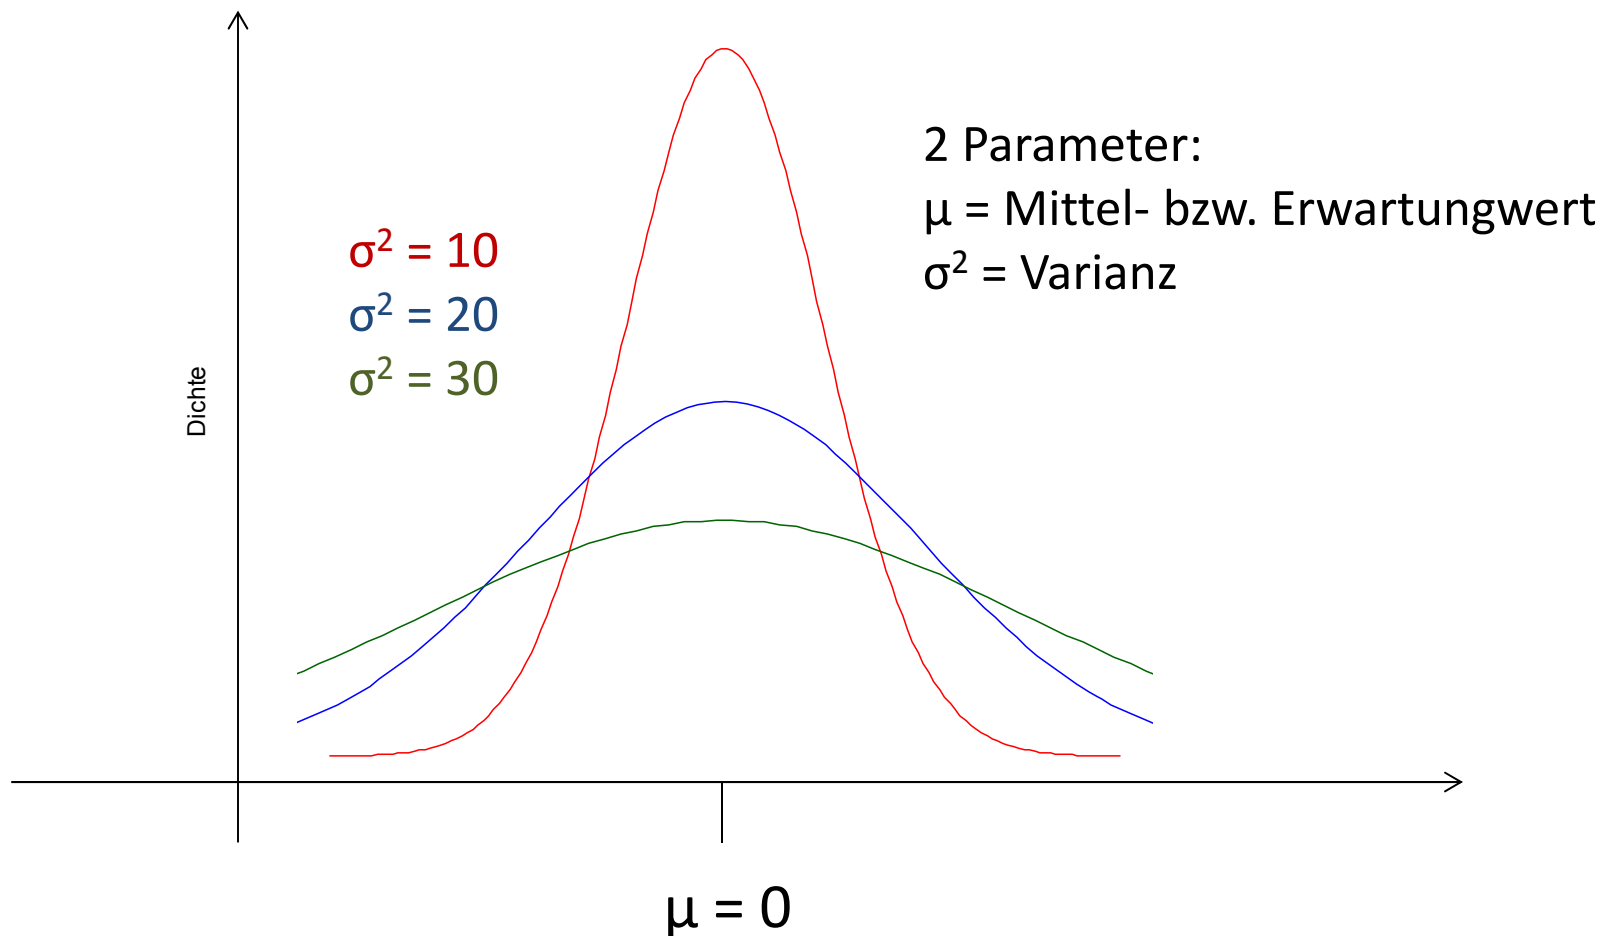
Häufigkeitsverteilungen: Normalverteilung



Häufigkeitsverteilungen: Normalverteilung

Dichtefunktion der Normalverteilung

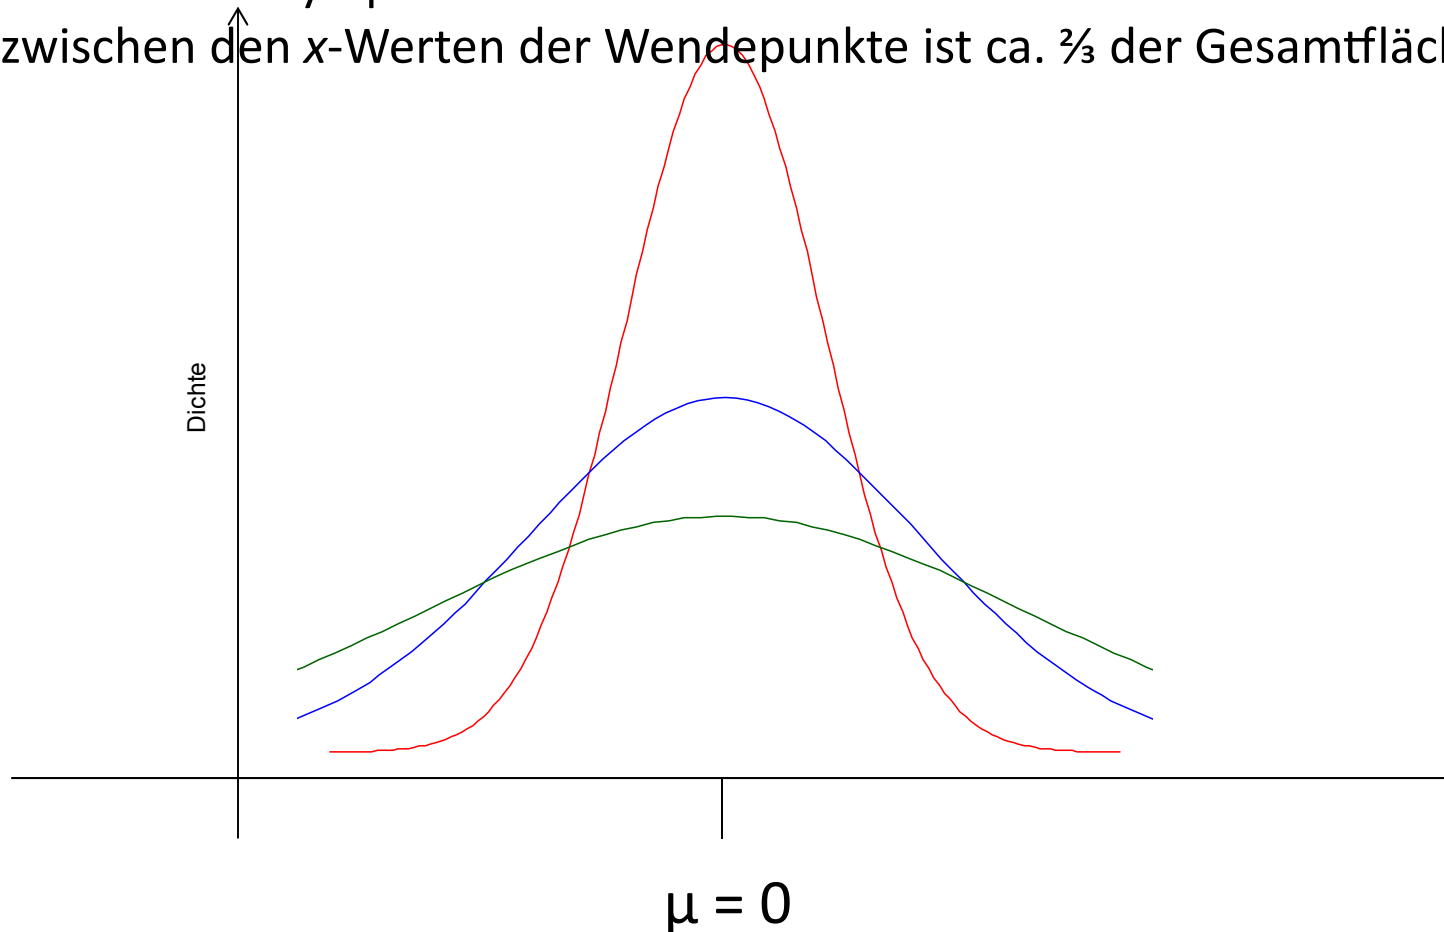
$$f(x) = \frac{1}{\sqrt{2\pi \cdot \sigma^2}} \cdot e^{-(x-\mu)^2/2\sigma^2}$$



Häufigkeitsverteilungen: Normalverteilung

Eigenschaften von Normalverteilungen:


- glockenförmiger Verlauf
- symmetrisch
- nähert sich asymptotisch der x-Achse
- zwischen den x-Werten der Wendepunkte ist ca. $\frac{2}{3}$ der Gesamtfläche



Häufigkeitsverteilungen: Standard-Normalverteilung

Dichtefunktion der Standard-Normalverteilung (z-Verteilung)


$$f(z) = \frac{1}{\sqrt{2\pi}} \cdot e^{-z^2/2}$$



Häufigkeitsverteilungen: Standard-Normalverteilung

Dichtefunktion der Standard-Normalverteilung (z-Verteilung)

Standardisierung von Werten x_i aus beliebiger Normalverteilung durch **z-Transformation**:



Häufigkeitsverteilungen: Normalverteilung

Bedeutung von Normalverteilungen:

- Beobachteter Wert aus einer Population mit dem Erwartungswert μ setzt sich zusammen aus dem Erwartungswert und einem Fehler ε

$$x_i = \mu + \varepsilon$$

- Annahme: ε ist normalverteilt
- Schlussfolgerung: für n Beobachtungen aus der Population sind die Beobachtungen für $n \rightarrow \infty$ normalverteilt

Probabilistische Unterschiedshypothese H1

H1: Ein Satz, der Bedingung A erfüllt, ist akzeptabler als ein entsprechender Satz, der Bedingung B erfüllt

Bsp.: Bedingung A: SVO-Abfolge; Bedingung B: OVS-Abfolge

„entsprechender Satz“ = minimales Paar, d.h., übereinstimmende Lexikalisierung

z.B.:

Bedingung A: Der Trainer beleidigte den Schiedsrichter.


Bedingung B: Den Schiedsrichter beleidigte der Trainer.

H1 behauptet, dass einander entsprechende Sätze aus Bedingung A und Bedingung B aus verschiedenen Populationen stammen mit

$$\mu_A > \mu_B$$

Probabilistische Unterschiedshypothese H1


H1: Ein Satz, der Bedingung A erfüllt, ist akzeptabler als ein entsprechender Satz, der Bedingung B erfüllt



- H1 ist eine gerichtete bzw. einseitig formulierte Hypothese
- H1 formuliert keine Annahme über die Distanz zwischen μ_A und μ_B
→ keine Annahme über die zu erwartende Effektstärke
- H1 formuliert keine Annahmen über die Varianz der Verteilungen
→ Populationsparameter müssen aus Stichprobe(n) geschätzt werden

Probabilistische Unterschiedshypothese H1

H0: Ein Satz, der Bedingung A erfüllt, ist ebenso akzeptabel wie ein entsprechender Satz, der Bedingung B erfüllt

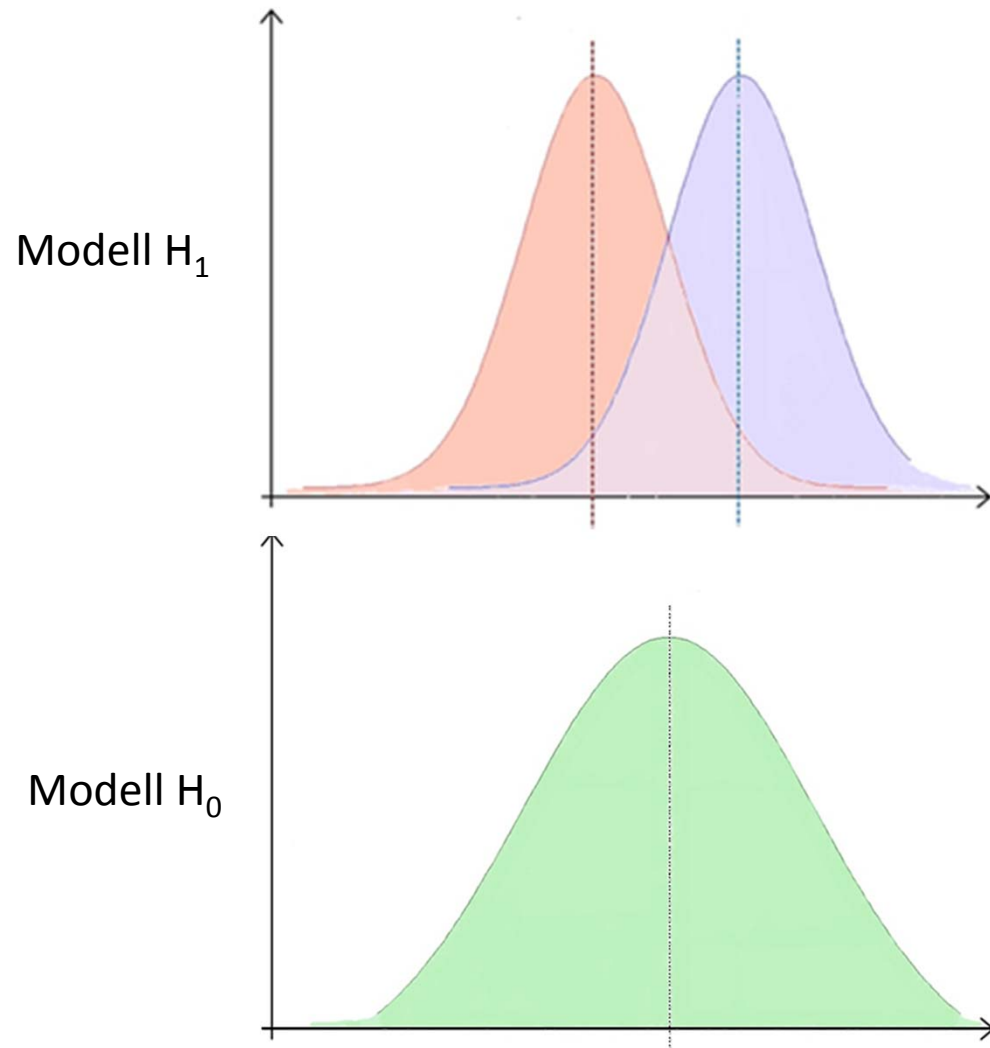


H0 behauptet, dass einander entsprechende Sätze aus Bedingung A und Bedingung B aus derselben Population stammen mit

$$\mu_A = \mu_B$$

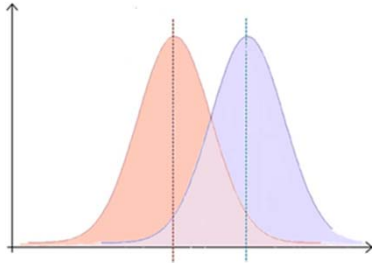
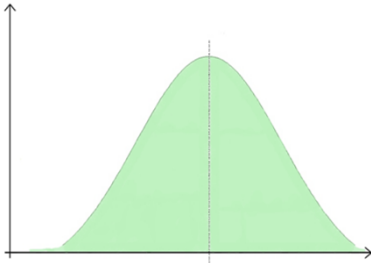
Probabilistische Unterschiedshypothese H_1

Inferenzstatistik: können wir H_0 verwerfen?




Probabilistische Unterschiedshypothese H1

Inferenzstatistik: minimiere α -Fehler
Entscheidung für H1 gdw. α -Fehler < 5%

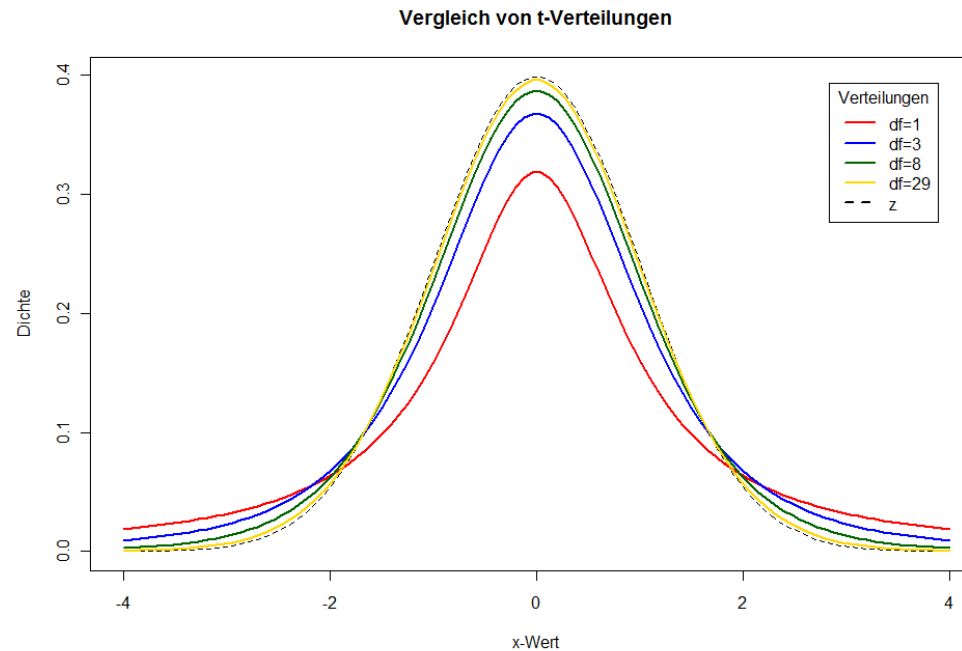
		Es gilt	
			
Entscheidung für	Modell H ₁	HIT	α -Fehler
	Modell H ₀	β -Fehler	CORRECT REJECTION

(Student's) t -Verteilung



t -Verteilung mit $n - 1$ Freiheitsgraden (degrees of freedom: df) ist die Zufallsverteilung der Mittelwerte von Stichproben des Umfangs n aus einer normalverteilten Population mit $\mu = 0$

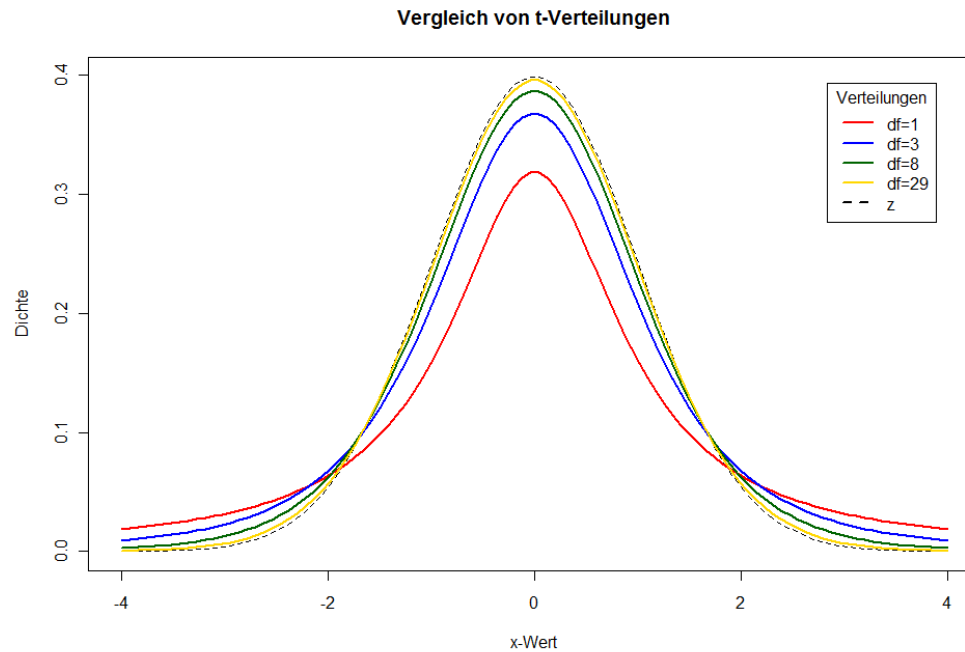
(Student's) t -Verteilung



Eigenschaften der t -Verteilung:

- symmetrisch um 0
- eignet sich zum Vergleich der Mittelwerte zweier Verteilungen
- parametrisch für Freiheitsgrade: $df = n - 1$
vgl. F -Statistik: Zähler-df von t immer 1; $df(t) = \text{Nenner-df}(F)$
- approximiert Standard-Normalverteilung für $n \rightarrow \infty$
ab ca. $n = 30$; Achtung: Standard-Normalverteilung ist parameter-frei!

(Student's) *t*-Verteilung



df 1-seitig df 2-seitig	$\alpha = 5\%$ $\alpha = 10\%$	$\alpha = 2.5\%$ $\alpha = 5\%$	$\alpha = 1\%$ $\alpha = 2\%$	$\alpha = 0,5\%$ $\alpha = 1\%$
1	6.314	12.706	31.821	63.657
3	2.353	3.182	4.541	5.841
8	1.860	2.306	2.896	3.355
29	1.699	2.045	2,462	2.756
z	1.645	1.960	2,326	2.576

(Student's) t -Verteilung

Grundsätzliches Vorgehen beim t -Test:

- Man vergleicht die Mittelwerte von 2 Stichproben oder den Mittelwert von 1 Stichprobe mit dem Mittelwert einer theoretischen Population
- Man bestimmt die Abweichung des Mittelwerts der Stichprobe vom theoretisch begründeten Mittelwert (**t -Test für eine Stichprobe**) oder bestimmt die Abweichung der Mittelwerte der Stichproben durch willkürliche Subtraktion einer der beiden Stichprobenwerte vom anderen (t -Verteilung symmetrisch): **t -Test für unabhängige Stichproben**
- Man schätzt mittels der verfügbaren Stichproben den Standard-Fehler des Mittelwerts (basierend auf der geschätzten Varianz der Verteilung)
- Man bestimmt mittels t -Wert die Wahrscheinlichkeit, dass der Mittelwert der (2.) Stichprobe aus der t -Verteilung stammt (H0-Test)
- Ist die Wahrscheinlichkeit, dass der Mittelwert aus derselben Population stammt $< 5\%$ erachtet man den Mittelwert-Unterschied als statistisch bedeutsam (signifikant) und nimmt die H1 an

t-Test

t-Test für unabhängige Stichproben

$$t = \frac{\bar{x}_1 - \bar{x}_2}{\hat{\sigma}_{(\bar{x}_1 - \bar{x}_2)}}$$

$$\hat{\sigma}^2_{(\bar{x}_1 - \bar{x}_2)} = \frac{\sum_{i=1}^{n_1} (x_{i1} - \bar{x}_1)^2 + \sum_{i=1}^{n_2} (x_{i2} - \bar{x}_2)^2}{(n_1 - 1) + (n_2 - 1)}$$

t-Test

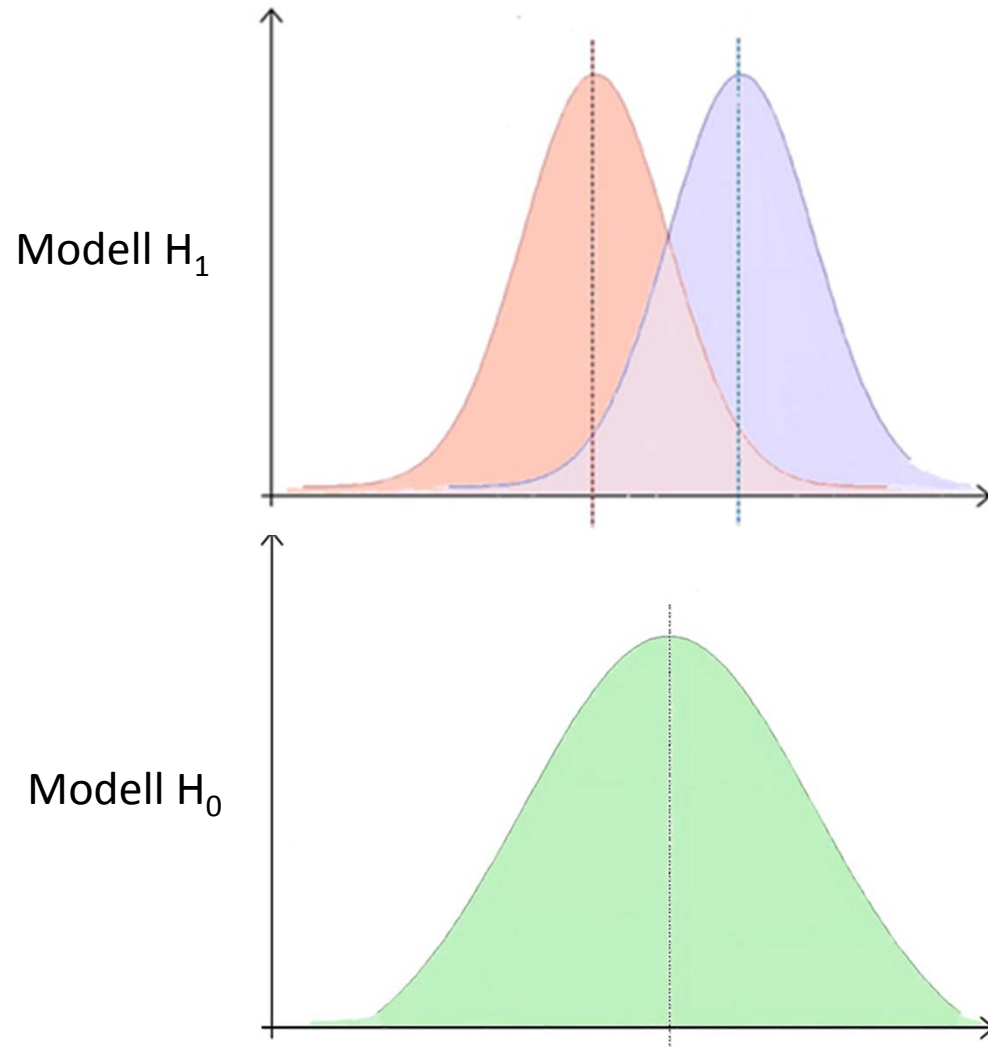
t-Test für abhängige Stichproben

$$t = \frac{\bar{x}_d}{\hat{\sigma}_{\bar{x}_d}}$$

$$\hat{\sigma}_{\bar{x}_d}^2 = \frac{\sum_{i=1}^{n_1} (d_i - \bar{x}_d)^2}{(n - 1)}$$

Varianzanalyse

Wird die Fehlervarianz in H_0 durch die Annahme von H_1 signifikant reduziert?



Varianzanalyse (ANOVA)

Beispiel: 1-faktorielle (p Stufen) Varianzanalyse mit Messwiederholung

Varianzanalyse (ANOVA)

Beispiel: 1-faktorielle (p Stufen) Varianzanalyse mit Messwiederholung

		Faktorstufen						
		1	2	...	i	p	Σ_i	
Pbn	1	x_{11}	x_{12}	...	x_{1i}	x_{1p}	P_1	
	2	x_{21}	x_{22}	...	x_{2i}	x_{2p}	P_2	
	:	:	:		:	:	:	
	m	x_{m1}	x_{m2}	...	x_{mi}	...	x_{mp}	P_m
	:	:	:		:	:	:	
	n	x_{n1}	x_{n2}	...	x_{ni}	...	x_{np}	P_n
Σ_m		A_1	A_2	...	A_i	...	A_p	G

p = Anzahl der Faktorstufen

x_{mi} = Messwert von V_p m unter Faktorstufe i

A_i = Summe aller Messwerte unter Faktorstufe i

P_m = Summe aller Messwerte von V_p m

G = Gesamtsumme aller Messwerte x_{mi}

Varianzanalyse (ANOVA)

Beispiel: 1-faktorielle (4 Stufen) Varianzanalyse mit Messwiederholung

accept_daten.F1.sav [DatenSet1] - IBM SPSS Statistics Daten-Editor

Datei Bearbeiten Ansicht Daten Transformieren Analysieren Direktmarketing Diagramme Extras Fenster Hilfe

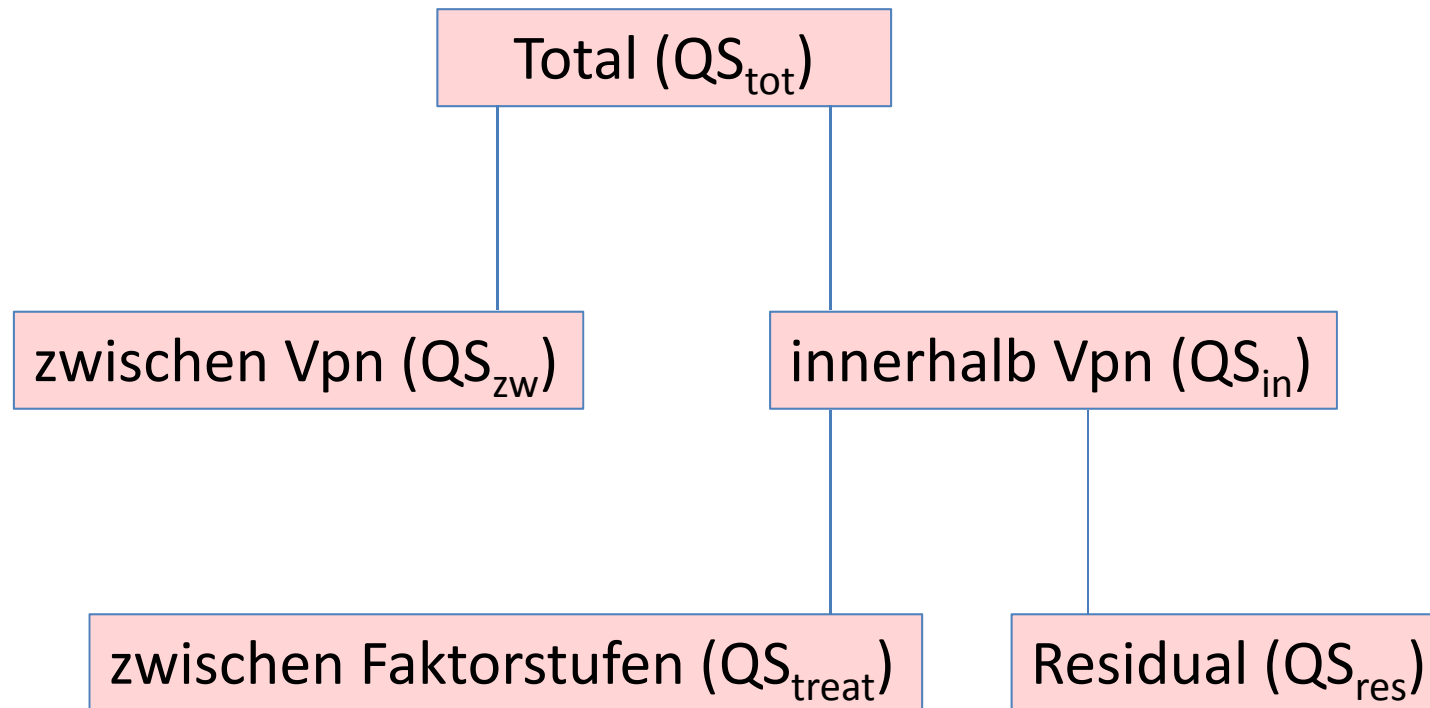
1:

	vp	cond.1	cond.2	cond.3	cond.4	xm1	xm2	xm3	xm4	var
16	16	A	B	C	D	4,75	4,75	4,75	4,63	
17	17	A	B	C	D	4,63	4,13	4,88	4,88	
18	18	A	B	C	D	4,13	3,50	3,38	3,38	
19	19	A	B	C	D	5,00	3,75	4,88	4,88	
20	20	A	B	C	D	4,38	3,38	3,00	3,13	
21	21	A	B	C	D	5,00	4,75	5,00	5,00	
22	22	A	B	C	D	4,50	3,63	4,00	4,38	
23	23	A	B	C	D	4,00	3,63	3,88	4,13	
24	24	A	B	C	D	4,25	4,75	4,13	4,00	
25	25	A	B	C	D	4,50	3,75	4,50	3,75	
26	26	A	B	C	D	4,88	4,75	4,38	4,88	
27	27	A	B	C	D	5,00	5,00	3,25	3,38	
28	28	A	B	C	D	5,00	4,63	4,00	3,63	
29	29	A	B	C	D	4,00	3,75	4,25	4,75	
30	30	A	B	C	D	4,63	3,88	4,00	4,38	
31	31	A	B	C	D	4,13	3,63	4,38	4,13	
32	32	A	B	C	D	4,75	5,00	4,75	4,88	
33	33	A	B	C	D	3,50	3,25	3,63	4,00	
34	34	A	B	C	D	4,63	4,13	4,25	4,00	
35	35	A	B	C	D	4,63	4,63	5,00	4,88	
36	36	A	B	C	D	3,50	3,75	4,13	3,13	
37	37	A	B	C	D	4,13	4,00	4,38	4,13	
38	38	A	B	C	D	5,00	4,75	4,25	4,75	
39	39	A	B	C	D	5,00	4,88	5,00	5,00	
40	40	A	B	C	D	4,13	3,88	3,50	3,13	
41	41	A	B	C	D	4,63	4,00	4,50	4,25	
42	42	A	B	C	D	4,63	4,63	3,75	4,38	
43	43	A	B	C	D	4,88	4,13	5,00	5,00	
44	44	A	B	C	D	5,00	4,50	5,00	4,88	
45	45	A	B	C	D	3,75	3,50	3,88	3,88	
46	46	A	B	C	D	5,00	5,00	4,75	4,88	
47	47	A	B	C	D	4,88	4,13	5,00	4,75	
48	48	A	B	C	D	2,75	3,00	2,00	2,88	
49										
50										
51										

Datenansicht Variablenansicht

Varianzanalyse (ANOVA)

Zerlegung der Quadratsummen: Übersicht



Varianzanalyse (ANOVA)

Zerlegung der Quadratsummen: Übersicht


$$QS_{tot} = \sum_i \sum_m (x_{mi} - \bar{G})^2$$

$$QS_{zw} = p \cdot \sum_m (\bar{P}_m - \bar{G})^2$$

$$QS_{in} = \sum_i \sum_m (x_{mi} - \bar{P}_m)^2$$

$$QS_{treat} = n \cdot \sum_i (\bar{A}_i - \bar{G})^2$$

$$QS_{res} = \sum_i \sum_m (x_{mi} - \bar{A}_i - \bar{P}_m + \bar{G})^2$$



Varianzanalyse (ANOVA)

Zerlegung der Quadratsummen: Übersicht

$$\bar{G} = \frac{G}{192} = \frac{815.13}{192} = 4.25$$

$$\bar{A}_1 = \frac{A_1}{48} = \frac{215.50}{48} = 4.90$$

$$\bar{A}_2 = \frac{A_2}{48} = \frac{195.50}{48} = 4.07$$

$$\bar{A}_3 = \frac{A_3}{48} = \frac{202.13}{48} = 4.21$$

$$\bar{A}_4 = \frac{A_4}{48} = \frac{202.00}{48} = 4.21$$

$$\bar{P}_1 = \frac{P_1}{4} = \frac{10.75}{4} = 2.69$$

$$\bar{P}_2 = \frac{P_2}{4} = \frac{16.63}{4} = 4.16$$

...

$$\bar{P}_{48} = \frac{P_{48}}{4} = \frac{10.63}{4} = 2.66$$

		Faktorstufen (p=4)				
		1	2	3	4	Σ_i
Pbn	1	$x_{1.1}$	$x_{1.2}$	$x_{1.3}$	$x_{1.4}$	$P_1 = 10.75$
n=48	2	$x_{2.1}$	$x_{2.2}$	$x_{2.3}$	$x_{2.4}$	$P_2 = 16.63$
	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
	48	$x_{48.1}$	$x_{48.2}$	$x_{48.3}$	$x_{48.4}$	$P_{48} = 10.63$
	Σ_m	$A_1 =$ 215.50	$A_2 =$ 195.50	$A_3 =$ 202.13	$A_4 =$ 202.00	$G =$ 815.13

Varianzanalyse (ANOVA)

$$QS_{tot} = \sum_i \sum_m (x_{mi} - \bar{G})^2$$

```
COMPUTE G.MEAN = 4,24544.
```

Berechne für jede Vp für jede Faktorstufe die quadrierte Abweichung von meanG

```
COMPUTE qAbw_xm1_G = (xm1 - G.MEAN)**2.  
COMPUTE qAbw_xm2_G = (xm2 - G.mean)**2.  
COMPUTE qAbw_xm3_G = (xm3 - G.mean)**2.  
COMPUTE qAbw_xm4_G = (xm4 - G.mean)**2.
```

Summiere über die 4 Faktorstufen (Index i)

```
COMPUTE qAbw_xmi_G.SUM = qAbw_xm1_G + qAbw_xm2_G + qAbw_xm3_G + qAbw_xm4_G.
```

Summiere über die 48 Vpn (Index m)

```
AGGREGATE  
  /OUTFILE=„aggr“  
  /BREAK=  
  /qAbw_xm1_G.SUM_sum=SUM(qAbw_xmi_G.SUM).
```

$$QS_{tot} = 82.3848$$

Varianzanalyse (ANOVA)

$$QS_{zw} = p \cdot \sum_m (\bar{P}_m - \bar{G})^2$$

Berechne für jede Vp den Mittelwert P.MEAN über Faktorstufen

```
COMPUTE P.MEAN = mean(xm1, xm2, xm3, xm4) .
```

Berechne für jede Vp die quadrierte Abweichung für P.MEAN von G.MEAN

```
COMPUTE qAbw_P_G = (P.MEAN - G.MEAN)**2 .
```

Summiere über die 48 Vpn (Index m)

```
AGGREGATE  
  /OUTFILE= 'aggr'  
  /BREAK=  
  /qAbw_P_G_sum=SUM(qAbw_P_G) .
```

Multipliziere mit 4 (= Anzahl der Faktorstufen)

```
COMPUTE QSzw = qAbw_P_G_sum * 4 .
```

$$QS_{zw} = 62.1874$$

Varianzanalyse (ANOVA)

$$QS_{in} = \sum_i \sum_m (x_{mi} - \bar{P}_m)^2$$

Berechne für jede Vp die quadrierte Abweichung für xmi von P.MEAN

```
COMPUTE qAbw_xm1_P = (xm1 - P.MEAN)**2.  
COMPUTE qAbw_xm2_P = (xm2 - P.MEAN)**2.  
COMPUTE qAbw_xm3_P = (xm3 - P.MEAN)**2.  
COMPUTE qAbw_xm4_P = (xm4 - P.MEAN)**2.
```

Summiere für jede Vp m über die 4 Faktorstufen (Index i)

```
COMPUTE qAbw_xmi_P.SUM = qAbw_xm1_P + qAbw_xm2_P + qAbw_xm3_P + qAbw_xm4_P.
```

Summiere über die 48 Vpn (Index m)

```
AGGREGATE  
  /OUTFILE='aggr'  
  /BREAK=  
  /QSin=SUM(qAbw_xmi_P.SUM).
```

$$QS_{in} = 26,2773$$

Varianzanalyse (ANOVA)

$$QS_{treat} = n \cdot \sum_i (\bar{A}_i - \bar{G})^2$$

Berechne für jede Faktorstufe den Mittelwert Ai.MEAN über Vpn

```
AGGREGATE  
  /OUTFILE= 'aggr '  
  /BREAK=  
  /A1_mean=MEAN(xm1 )  
  /A2_mean=MEAN(xm2 )  
  /A3_mean=MEAN(xm3 )  
  /A4_mean=MEAN(xm4 ) .
```

Berechne für jede Faktorstufe die quadrierte Abweichung für Ai_mean von G.MEAN

```
COMPUTE qAbw_A1_G = (A1_mean - G.MEAN)** 2.  
COMPUTE qAbw_A2_G = (A2_mean - G.MEAN)** 2.  
COMPUTE qAbw_A3_G = (A3_mean - G.MEAN)** 2.  
COMPUTE qAbw_A4_G = (A4_mean - G.MEAN)** 2.
```

Summiere über die 4 Faktorstufen (Index i) und multipliziere mit 48

```
COMPUTE QStreat = (qAbw_A1_G +  
                  qAbw_A2_G +  
                  qAbw_A3_G +  
                  qAbw_A4_G +) * 48.
```

$$QS_{treat} = 4,4130$$

Varianzanalyse (ANOVA)

$$QS_{res} = \sum_i \sum_m (x_{mi} - \bar{A}_i - \bar{P}_m + \bar{G})^2$$

```
COMPUTE A1.MEAN = 4.4896.  
COMPUTE A2.MEAN = 4.0729.  
COMPUTE A3.MEAN = 4.2109.  
COMPUTE A4.MEAN = 4.2083.
```

Subtrahiere für jede Vp für jede Faktorstufe Ai.MEAN & P.MEAN, addiere G.MEAN

```
COMPUTE q_xm1_minusA_minusP_plusG = (xm1 - A1.MEAN - P.MEAN + G.MEAN)** 2.  
COMPUTE q_xm2_minusA_minusP_plusG = (xm2 - A2.MEAN - P.MEAN + G.MEAN)** 2.  
COMPUTE q_xm3_minusA_minusP_plusG = (xm3 - A3.MEAN - P.MEAN + G.MEAN)** 2.  
COMPUTE q_xm4_minusA_minusP_plusG = (xm4 - A4.MEAN - P.MEAN + G.MEAN)** 2.
```

Summiere über die 4 Faktorstufen

```
COMPUTE q_xmi_minusA_minusP_plusG.SUM =  
  q_xm1_minusA_minusP_plusG +  
  q_xm2_minusA_minusP_plusG +  
  q_xm2_minusA_minusP_plusG +  
  q_xm2_minusA_minusP_plusG.
```

Summiere über die 48 Vpn

```
AGGREGATE  
  /OUTFILE='aggr'  
  /BREAK=  
  /q_xmi_minusA_minusP_plusG.SUM_sum=SUM(q_xmi_minusA_minusP_plusG.SUM).
```

$$QS_{res} = 25,5286$$

Varianzanalyse (ANOVA)

Zerlegung der Quadratsummen: Übersicht

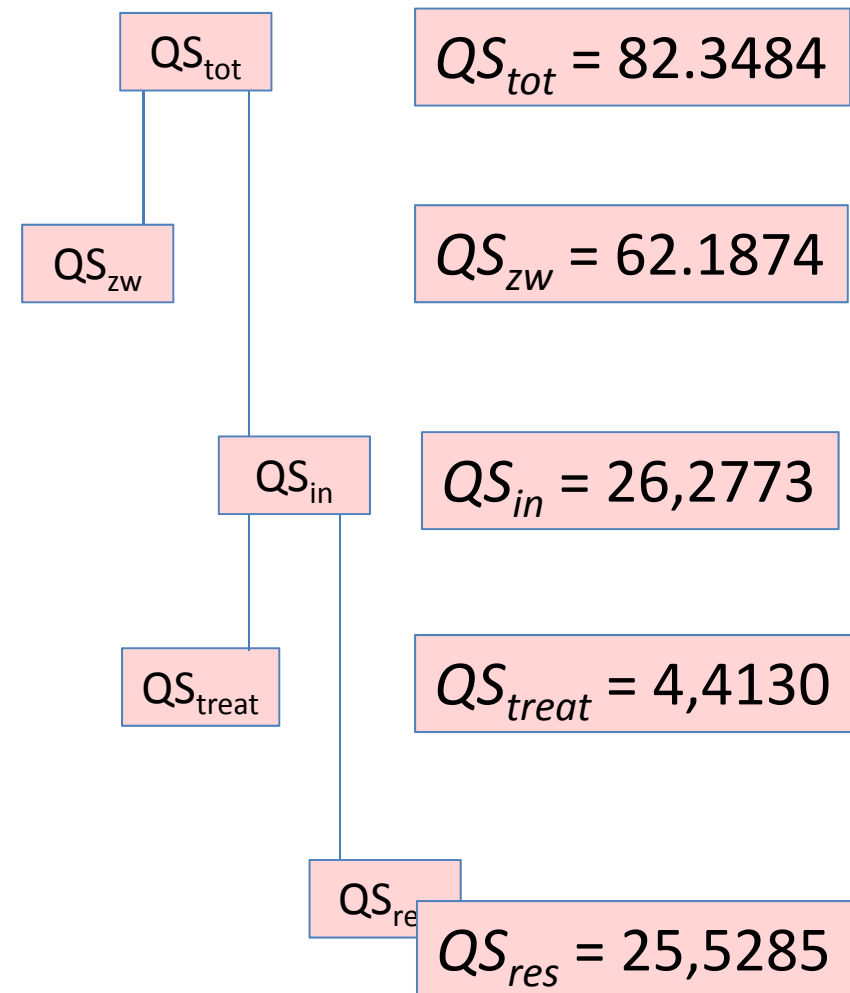
$$QS_{tot} = \sum_i \sum_m (x_{mi} - \bar{G})^2$$

$$QS_{zw} = p \cdot \sum_m (\bar{P}_m - \bar{G})^2$$

$$QS_{in} = \sum_i \sum_m (x_{mi} - \bar{P}_m)^2$$

$$QS_{treat} = n \cdot \sum_i (\bar{A}_i - \bar{G})^2$$

$$QS_{res} = \sum_i \sum_m (x_{mi} - \bar{A}_i - \bar{P}_m + \bar{G})^2$$



Varianzanalyse (ANOVA)

Zerlegung der Quadratsummen: Übersicht

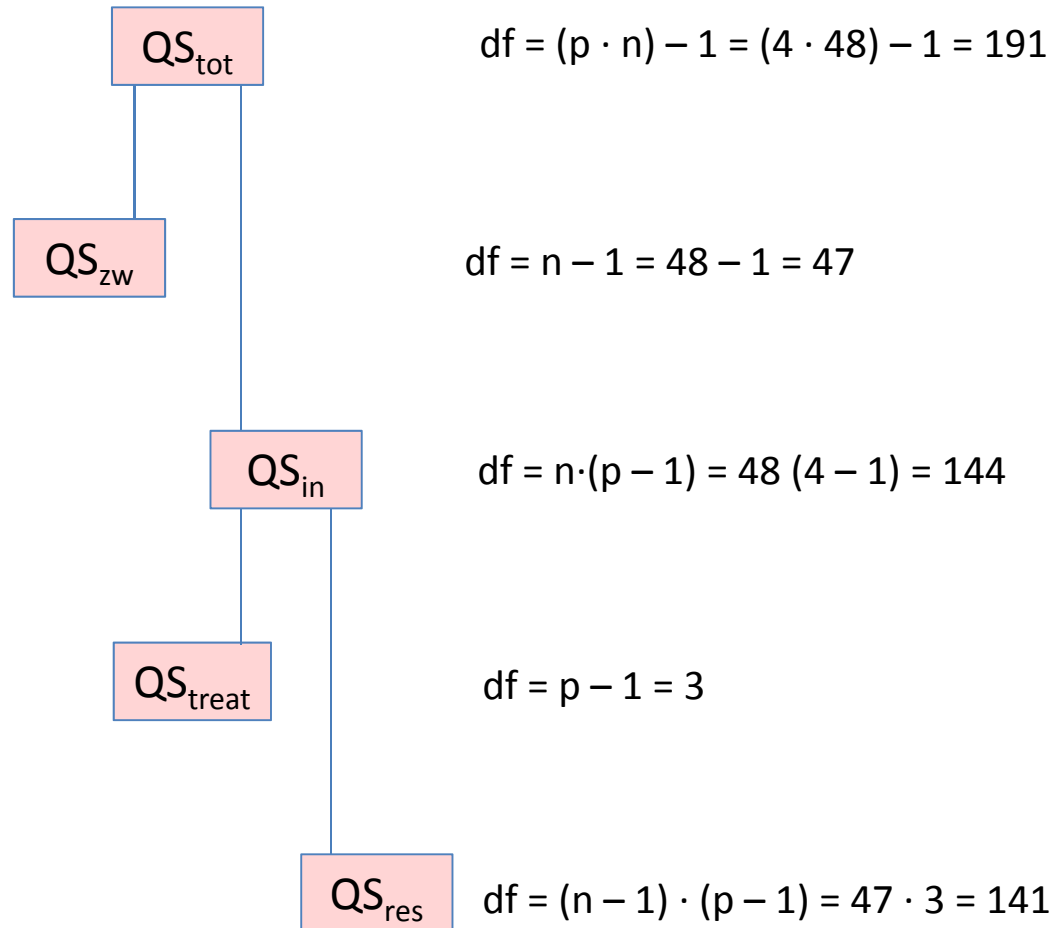
$$\sigma^2_{\text{tot}} = \text{QS}_{\text{tot}} / \text{df}_{\text{tot}} = \dots$$

$$\sigma^2_{\text{zw}} = \text{QS}_{\text{zw}} / \text{df}_{\text{zw}} = \dots$$

$$\sigma^2_{\text{in}} = \text{QS}_{\text{in}} / \text{df}_{\text{in}} = \dots$$

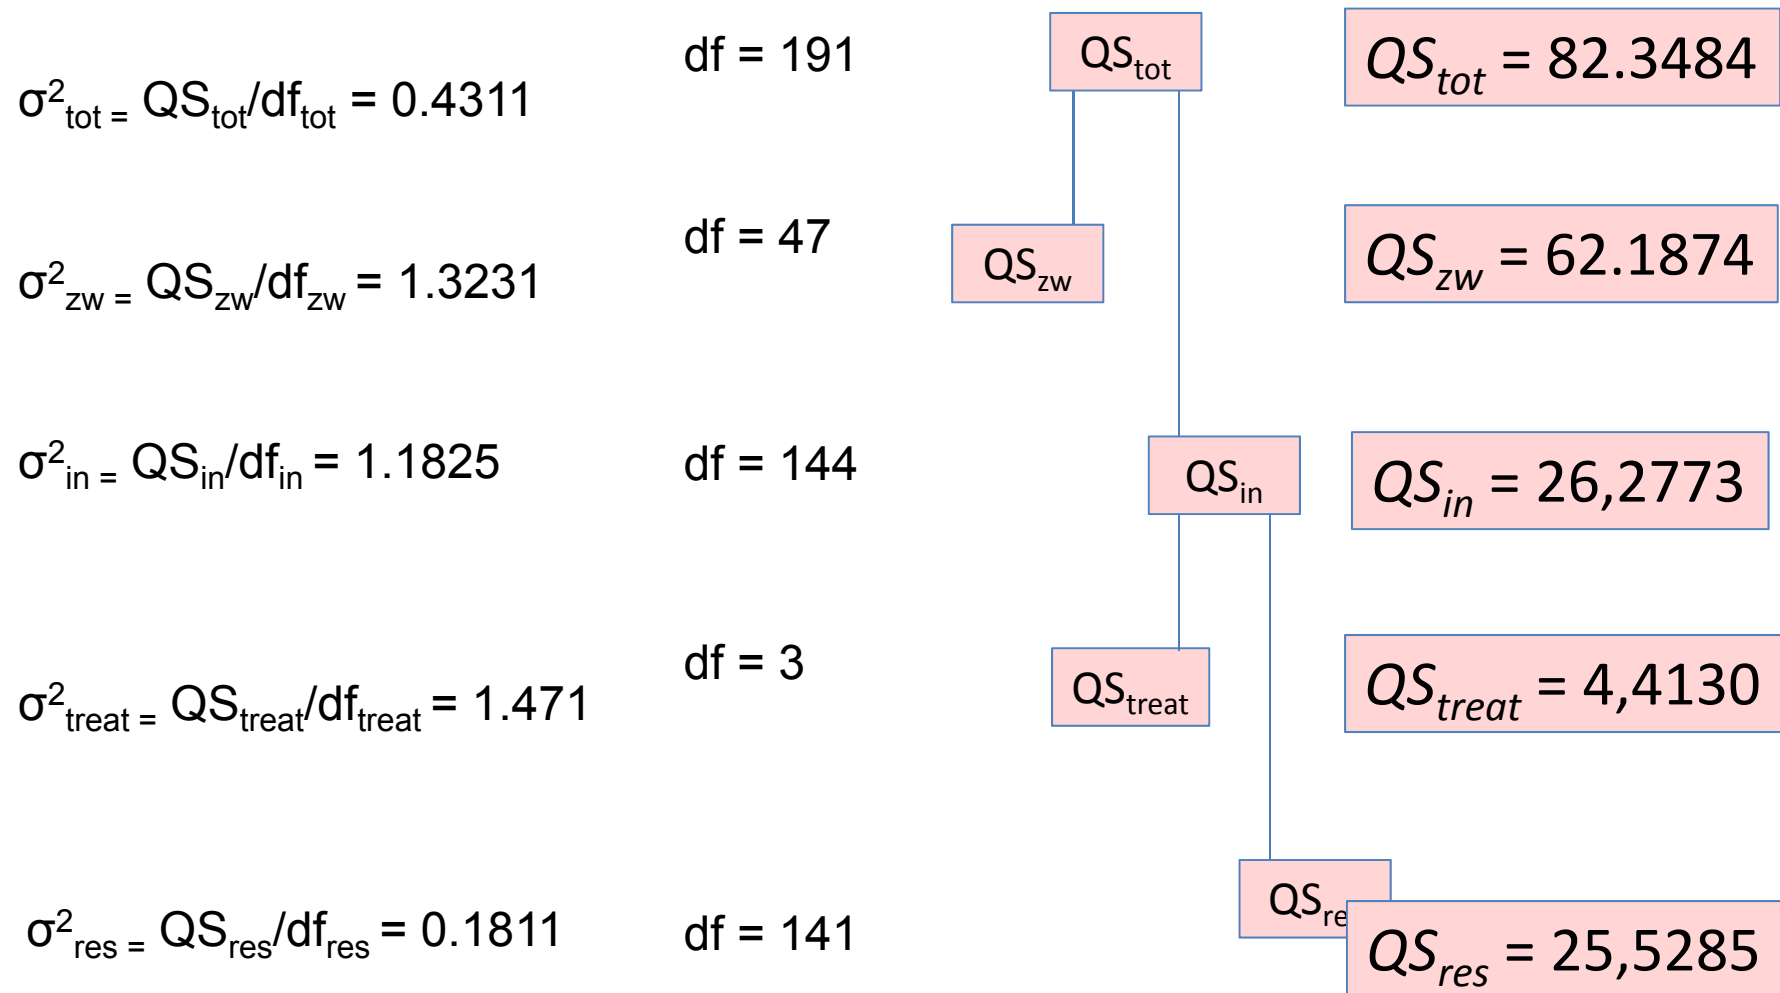
$$\sigma^2_{\text{treat}} = \text{QS}_{\text{treat}} / \text{df}_{\text{treat}} = \dots$$

$$\sigma^2_{\text{res}} = \text{QS}_{\text{res}} / \text{df}_{\text{res}} = \dots$$



Varianzanalyse (ANOVA)

Zerlegung der Quadratsummen: Übersicht



Varianzanalyse (ANOVA)

Zerlegung der Quadratsummen: Übersicht

$$\sigma^2_{\text{tot}} = \text{QS}_{\text{tot}}/\text{df}_{\text{tot}} = 0.4311$$

$$\sigma^2_{\text{zw}} = \text{QS}_{\text{zw}}/\text{df}_{\text{zw}} = 1.3231$$

$$\sigma^2_{\text{in}} = \text{QS}_{\text{in}}/\text{df}_{\text{in}} = 1.1825$$

$$H_0: \hat{\sigma}^2_{\text{treat}} = \hat{\sigma}^2_{\text{res}}$$

$$\sigma^2_{\text{treat}} = \text{QS}_{\text{treat}}/\text{df}_{\text{treat}} = 1.471$$

$$F(\text{df}_{\text{treat}}, \text{df}_{\text{res}}) = \frac{\hat{\sigma}^2_{\text{treat}}}{\hat{\sigma}^2_{\text{res}}} = \frac{1.471}{0.1811} = 8.12$$

$$\sigma^2_{\text{res}} = \text{QS}_{\text{res}}/\text{df}_{\text{res}} = 0.1811$$

Varianzanalyse (ANOVA)

Kontraste

Quelle	cond	df	Mittel der Quadrate	F(1,47)	Sig.	Partielles Eta-Quadrat
cond	L1	1	,985	1,085	,303	,023
	L2	1	8,438	19,041	,000	,288
	L3	1	8,229	25,512	,000	,352
Fehler(cond)	L1	47	,908			
	L2	47	,443			
	L3	47	,323			

Quelle	df	Mittel der Quadrate	F(1,47)	Sig.	Partielles Eta-Quadrat
Faktor1	1	,246	1,085	,303	,023
Fehler(Faktor1)	47	,227			
Faktor2	1	2,109	19,041	,000	,288
Fehler(Faktor2)	47	,111			
Faktor1 * Faktor2	1	2,057	25,512	,000	,352
Fehler(Faktor1*Faktor2)	47	,081			