

# Aufgabensammlung zur Übung „Statistische Messdatenauswertung für Biotechnologen“ Musterlösungen

Version 2012d

## Inhaltsverzeichnis

<b>1</b>	<b>Statistik-Grundlagen</b>	<b>2</b>
L 1	Lage- und Streuungsparameter . . . . .	2
L 2	Lage- und Streuungsparameter – Blattlängen . . . . .	3
L 3	Gaußsche Normalverteilung – Vertrauensbereich . . . . .	4
L 4	Fadenlänge von Seidenkokons . . . . .	5
<b>2</b>	<b>Abweichungsfortpflanzung</b>	<b>7</b>
L 5	Zylindervolumen . . . . .	7
L 6	Unbekanntes Prüfteil . . . . .	8
L 7	Torsionsmodul Stahldraht . . . . .	10
<b>3</b>	<b>Student'scher t-Test</b>	<b>13</b>
3.1	t-Test für den Erwartungswert . . . . .	13
L 8	Gewicht von Kohlköpfen . . . . .	13
L 9	Ozongehalt der Luft . . . . .	14
3.2	t-Test für Vergleich zweier Erwartungswerte unabhängiger Stichproben . . . . .	15
L 10	Futtereinfluss auf Gewichtszunahme bei Schweinen . . . . .	15
L 11	Medikamenteneinfluss auf Tierwachstum . . . . .	16
L 12	Ertrag verschiedener Pilzarten . . . . .	17
3.3	t-Test für Vergleich zweier Erwartungswerte verbundener Stichproben . . . . .	18
L 13	Einfluss der Benzinqualität auf Treibstoffverbrauch . . . . .	18
L 14	Wirksamkeit von Schlafmitteln . . . . .	19
<b>4</b>	<b>Einfache Varianzanalyse (ANOVA)</b>	<b>21</b>
L 15	Wirkung von Fungiziden . . . . .	21
<b>5</b>	<b><math>\chi^2</math>-Test</b>	<b>23</b>
L 16	Unkrautzählung . . . . .	23
L 17	Milchleistung von Kühen . . . . .	25
L 18	Punktzahlen der Statistiklausur . . . . .	28
<b>6</b>	<b>Lineare Regression</b>	<b>29</b>
L 19	Ertrag von Sommerweizen . . . . .	29
L 20	Zusammenhang von Körpergröße und Gewicht . . . . .	31
<b>7</b>	<b>Aufgabenvarianten zur statistischen Sicherheit</b>	<b>35</b>
	Aufgabenvarianten zur statistischen Sicherheit . . . . .	35

# 1 Statistik-Grundlagen

## L 1 Lage- und Streuungsparameter

$n = 20$

arithmetisches Mittel:  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{20}(4 + 5 + \dots + 6 + 5) = 5,15$

Streuung:  $S = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} = \sqrt{\frac{1}{19} \cdot 68,55} = \sqrt{3,61} = 1,9$

Varianz:  $S^2 = 3,61$

$x_i$	3	3	4	4	4	4	4	5	5	5	5	5	5	5	5	6	6	6	7	12
$n$	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20

Modalwert:  $M = 5$  (8 Elemente)

Median:  $\tilde{x} = \frac{x_{10} + x_{11}}{2} = 5$


Spannweite:  $12 - 3 = 9$  unteres Quartil: 4

oberes Quartil: 5,5

Quartilsabstand: 1,5 (bzw. o. Quartil= 5 und Quartilsabstand= 1, wenn abgerundet wird (ist so in einigen Literaturstellen zu finden))

Klasse:	3	4	5	6	7	8	9	10	11	12
$n$ :	2	5	8	3	1	0	0	0	0	1

5 Klassen + 1 Ausreißer



## L 2 Lage- und Streuungsparameter – Blattlängen

(a)  $n = 40$

**Mittelwert:**  $\bar{x} = \sum_{i=1}^n \frac{x_i}{n} = 53,762 \text{ mm}$

**Varianz:**  $S^2 = \sum_{i=1}^n \frac{(x_i - \bar{x})^2}{n - 1} = 37,13 \text{ mm}^2$

**Streuung:**  $S = 6,0932 \text{ mm}$

**geordnete Stichprobe:**

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
39,5	42,5	43,5	45,5	48,5	48,5	49,0	49,0	49,5	49,5	49,5	50,5	50,5	50,5	51,5	51,5	52,5	52,5	53,5	53,5

21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40
54,0	54,5	55,0	55,5	56,0	56,0	56,0	56,0	56,5	56,5	57,0	58,5	59,0	59,0	59,0	59,5	62,5	65,0	66,0	68,0

**Modalwert:**  $M = 56,0 \text{ mm}$  (4 Elemente)

**Medianwert:**  $\tilde{x} = \frac{x_{20} + x_{21}}{2} = \frac{53,5 \text{ mm} + 54,0 \text{ mm}}{2} = 53,75 \text{ mm}$

**Spannweite:**  $68 \text{ mm} - 39,5 \text{ mm} = 28,5 \text{ mm}$

**unteres Quartil:**  $x_{10} = 49,5 \text{ mm}$  bzw.  $\frac{x_{10} + x_{11}}{2} = 49,5 \text{ mm}$

**oberes Quartil:**  $x_{30} = 56,5 \text{ mm}$  bzw.  $\frac{x_{30} + x_{31}}{2} = 56,75 \text{ mm}$

**Quartilsabstand:**  $56,5 \text{ mm} - 49,5 \text{ mm} = 7 \text{ mm}$  (bzw. 7,25 mm)

**Konfidenzintervall:**

Die Messgröße  $x$  ist normal verteilt,  $\sigma$  ist unbekannt:

$$\left[ \bar{x} - \frac{s}{\sqrt{n}} \cdot t_{n-1; 1-\frac{\alpha}{2}}, \bar{x} + \frac{s}{\sqrt{n}} \cdot t_{n-1; 1-\frac{\alpha}{2}} \right]$$

$$\alpha = 1 - 0,95 = 0,05$$

$$t_{n-1; 1-\frac{\alpha}{2}} = t_{39; 0,975} \approx t_{40; 0,975} = 2,02$$


# 1 Statistik-Grundlagen

$$\Rightarrow \left[ 53,762 - \frac{6,0932}{\sqrt{40}} \cdot 2,02; 53,762 + \frac{6,0932}{\sqrt{40}} \cdot 2,02 \right]$$

$\Rightarrow [51,82; 55,71]$  Damit können wir 95 % der Messwerte in dem obigen Bereich erwarten und auch der wahre Mittelwert wird hier zu finden sein.

## (b) 7 Klassen

Klasse	(37,5;42,5]	(42,5;47,5]	(47,5;52,5]	(52,5;57,5]	(57,5;62,5]	(62,5;67,5]	(67,5;72,5]
n	2	2	14	13	6	2	1



## L 3 Gaußsche Normalverteilung – Vertrauensbereich

### a) Schätzwerte des Erwartungswertes und Standardabweichung

$$\bar{x} = 80,019 \quad S = 0,517 \quad n = 26 \quad \Rightarrow \quad s = 25$$

### b) Vertrauensbereich

$$\text{Parameter } p = 0,995 = \left(1 - \frac{\alpha}{2}\right) = 1 - \frac{0,01}{2}$$

$$\Rightarrow t = 2,79$$

$$c = \frac{t}{\sqrt{n}} \cdot S = \frac{2,79}{\sqrt{26}} \cdot 0,517$$

$$c = 0,283$$

### c) Wahrscheinlichkeit zwischen 79,8 und 80,2

Wahrscheinlichkeiten aus der Summenfunktion der standardisierten Normalverteilung

$$\Phi(z) = f(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{t^2}{2}} dt \quad \text{mit} \quad z = \frac{x - \mu}{\sigma}$$

⇒ Die Werte erhält man z.B. aus der Tabelle im Anhang des Scriptes.

hier:  $z = \frac{x_i - \bar{x}}{S}$  mit  $x_{min} = 79,8$  und  $x_{max} = 80,2$

$$z_{min} = \frac{79,8 - 80,019}{0,517} = -0,424 \rightarrow \text{Tabelle} \rightarrow \Phi(z_{min}) = 1 - \Phi(-z_{min}) = 1 - 0,662757 = 0,3372$$

$$z_{max} = \frac{80,2 - 80,019}{0,517} = 0,350 \quad \Phi(z_{max}) = 0,636831$$

$$P = \Phi_{max} - \Phi_{min} = 0,636831 - 0,3372 = 0,2996 = 29,96 \% \approx \underline{30 \%}$$

## L 4 Fadenlänge von Seidenkokons

$X_1, X_2, \dots$  sei eine unabhängige Folge von

$N(\mu = 800 \text{ m}, \sigma^2 = 6400 \text{ m}^2)$ -verteilten Zufallsvariablen.

$$\Rightarrow \sigma = \sqrt{6400 \text{ m}^2} = 80 \text{ m}$$

**a)**

$$P(x) = \Phi\left(\frac{x - \mu}{\sigma}\right), \quad x \in \mathbb{R}$$

$$P(X_i \geq 700 \text{ m}) = 1 - \Phi\left(\frac{700 \text{ m} - 800 \text{ m}}{80 \text{ m}}\right) = 1 - \Phi(-1,25)$$

$$= 1 - (1 - \Phi(1,25)) = \Phi(1,25) = 0,89435 \approx 89,4 \%$$

$$P(X_i > 1000 \text{ m}) = 1 - \Phi\left(\frac{1000 \text{ m} - 800 \text{ m}}{80 \text{ m}}\right) = 1 - \Phi(2,5) = 0,00621 \approx 0,6 \%$$

**b)**

Die Gesamtlänge der von 100 000 Kokons abgewickelten verwertbaren Seidenfäden wird durch die Zufallsvariable  $X_{\text{ges}} = X_1 + \dots + X_{100000}$  beschrieben.  $X_{\text{ges}}$  ist ebenfalls normal verteilt, und zwar mit Erwartungswert  $\mu = 8 \cdot 10^7 \text{ m}$  ( $800 \text{ m} \cdot 100000$ ) und Varianz  $\sigma^2 = 640 \cdot 10^6 \text{ m}^2$  ( $6400 \text{ m}^2 \cdot 100000$ ).

Die gesuchten Grenzen  $x_u$  und  $x_o$  sollen die folgenden Bedingungen erfüllen:

$$P(x_u \leq S \leq x_o) = P(S \leq x_o) - P(S < x_u) = 0,95$$

$$P(S < x_u) = P(S > x_o) = 1 - P(S \leq x_o)$$

$$2 \cdot P(S \leq x_o) - 1 = 0,95$$

Mit der Formel aus (a) erhält man:

$$P(S \leq x_o) = \Phi\left(\frac{x_o - \mu}{\sqrt{\sigma^2}}\right) = 0,975$$

$$\Phi(z) = 97,5\%$$

$$z = \frac{x_o - \mu}{\sqrt{\sigma^2}} = 1,96$$

$$x_o = \mu + 1,96 \cdot \sqrt{\sigma^2}$$

$$y = 80049584,51 \text{ m}$$

Eine analoge Rechnung für  $x_u$  liefert:

$$x_u = \mu - 1,96 \cdot \sqrt{\sigma^2} = 79950415,49 \text{ m}$$

**(c)**

Die Zufallsvariable  $X_{\text{ges},n} = X_1 + \dots + X_n, n \in \mathbb{N}$ , ist  $N(n \cdot 800 \text{ m}, n \cdot 6400 \text{ m}^2)$ -verteilt. Gesucht sind alle  $n \in \mathbb{N}$ , für die gilt:

$$P(X_{\text{ges},n} \geq 10^8 \text{ m}) \geq 0,99 \quad (10^8 \text{ m} = 100000 \text{ km} = 100000 \text{ m} \cdot 1000)$$

Man erhält:

$$P(X_{\text{ges},n} \geq 10^8 \text{ m}) \geq 0,99$$

$$\Phi\left(\frac{10^8 \text{ m} - 800 \text{ m} \cdot n}{80 \text{ m} \cdot \sqrt{n}}\right) \leq 0,01 \quad \Phi(z) = 1\%$$

$$z = -2,326 \quad \rightarrow \text{ muss gleich sein: } \frac{10^8 \text{ m} - 800 \text{ m} \cdot n}{80 \text{ m} \cdot \sqrt{n}}$$

$$800 \text{ m} \cdot (\sqrt{n})^2 - 2,326 \cdot 80 \text{ m} \cdot \sqrt{n} - 10^8 \text{ m} \geq 0$$

(quadratische Gleichung in  $\xi$  für  $\xi = \sqrt{n}$ )

$$\underline{n \geq 125083}$$

## 2 Abweichungsfortpflanzung

### L 5 Zylindervolumen

Mittelwerte:	Streuungen:	$s = \frac{s}{n-1}$	$P/\alpha$	$p$	$t$
$\bar{d} = \frac{\sum_{i=1}^{n_d} d_i}{n_d} = 30 \text{ mm}$	$S_d = \sqrt{\frac{\sum_{i=1}^{n_d} (d_i - \bar{d})^2}{n_d - 1}} = 0,87 \text{ mm}$	9	95 %/0,05	0,975	2,26
$\bar{l} = \frac{\sum_{i=1}^{n_l} l_i}{n_l} = 400 \text{ mm}$	$S_l = \sqrt{\frac{\sum_{i=1}^{n_l} (l_i - \bar{l})^2}{n_l - 1}} = 7,65 \text{ mm}$	4	95 %/0,05	0,975	2,78

Der Erwartungswert des Volumens  $\mu_V$  liegt im Intervall:

$$\left[ V(\bar{d}, \bar{l}) - c_V; V(\bar{d}, \bar{l}) + c_V \right] \quad \text{mit} \quad c_V = \sqrt{\left( \frac{\partial V}{\partial d} \Big|_{\bar{d}, \bar{l}} c_d \right)^2 + \left( \frac{\partial V}{\partial l} \Big|_{\bar{d}, \bar{l}} c_l \right)^2}$$

$$V(\bar{d}, \bar{l}) = \frac{1}{4} \bar{d}^2 \pi \bar{l} = 282743,34 \text{ mm}^3$$

$$\frac{\partial V}{\partial d} \Big|_{\bar{d}, \bar{l}} = \frac{1}{2} \bar{d} \pi \bar{l} = 18849,56 \text{ mm}^2$$

$$\frac{\partial V}{\partial l} \Big|_{\bar{d}, \bar{l}} = \frac{1}{4} \bar{d}^2 \pi = 706,86 \text{ mm}^2$$

$c_d$  und  $c_l$  :

$$c_d = \frac{t_{n_d-1; 1-\alpha/2}}{\sqrt{n_d}} \cdot S_d = \frac{2,26}{\sqrt{10}} \cdot 0,87 = 0,62 \text{ mm}$$

$$c_l = \frac{t_{n_l-1; 1-\alpha/2}}{\sqrt{n_l}} \cdot S_l = \frac{2,78}{\sqrt{5}} \cdot 7,65 = 9,51 \text{ mm}$$

$$\begin{aligned} c_V &= \sqrt{\left( \frac{\partial V}{\partial d} \Big|_{\bar{d}, \bar{l}} c_d \right)^2 + \left( \frac{\partial V}{\partial l} \Big|_{\bar{d}, \bar{l}} c_l \right)^2} \\ &= \sqrt{(18849,56 \cdot 0,62)^2 + (706,86 \cdot 9,51)^2} \text{ mm}^3 \\ &= \underline{\underline{13530,8 \text{ mm}^3}} \end{aligned}$$

Das Vertrauensintervall ist:

$$\underline{\underline{\left[ 282743,34 \text{ mm}^3 - 13530,8 \text{ mm}^3 ; 282743,34 \text{ mm}^3 + 13530,8 \text{ mm}^3 \right] \quad P\% = 95 \%}}$$

### L 6 Unbekanntes Prüfteil

$$\bar{l} = 1 \text{ dm}$$

$$\text{Streuung: } S_l = 0,07071 \text{ dm}$$

$$\text{mit } s = 4 \text{ und } p = 0,975 \implies t = 2,78 \quad \left(1 - \frac{0,05}{2} = 1 - 0,025\right)$$

$$c_l = 0,08791 \text{ dm}$$

$$\underline{l = (1 \pm 0,08791) \text{ dm} \quad P = 95\%}$$

$$\bar{b} = 0,28 \text{ dm} \quad S_B = 0,04472 \text{ dm}$$

$$c_b = 0,0556 \text{ dm}$$

$$\underline{b = (0,28 \pm 0,0556) \text{ dm} \quad P = 95\%}$$

$$\bar{h} = 0,64 \text{ dm} \quad S_h = 0,05477 \text{ dm}$$

$$c_h = 0,06809 \text{ dm}$$

$$\underline{h = (0,64 \pm 0,06809) \text{ dm} \quad P = 95\%}$$

$$\rho = f(l,b,h,m) = \frac{m}{lbh}$$

$$\bar{\rho} = \frac{1,402 \text{ kg}}{1 \cdot 0,28 \cdot 0,64 \text{ dm}^3} = 7,824 \frac{\text{kg}}{\text{dm}^3}$$

$$\left. \frac{\partial \rho}{\partial m} \right|_{\bar{l}, \bar{b}, \bar{h}} = \frac{1}{lbh}$$

$$\left. \frac{\partial \rho}{\partial l} \right|_{\bar{m}, \bar{b}, \bar{h}} = -\frac{m}{l^2bh}$$

$$\left. \frac{\partial \rho}{\partial b} \right|_{\bar{m}, \bar{l}, \bar{h}} = -\frac{m}{lb^2h}$$

$$\left. \frac{\partial \rho}{\partial h} \right|_{\bar{m}, \bar{l}, \bar{b}} = -\frac{m}{lbh^2}$$

$$c_S = \sqrt{\left(\frac{0,041}{1 \cdot 0,28 \cdot 0,64}\right)^2 + \left(\frac{-1,402}{1 \cdot 0,28 \cdot 0,64} \cdot 0,08791\right)^2 + \left(\frac{-1,402}{1 \cdot 0,28^2 \cdot 0,64} \cdot 0,0556\right)^2 + \left(\frac{-1,402}{1 \cdot 0,28 \cdot 0,64^2} \cdot 0,06809\right)^2} \frac{\text{kg}}{\text{dm}^3}$$

$$c_S = \sqrt{3,632} \frac{\text{kg}}{\text{dm}^3} = 1,906 \frac{\text{kg}}{\text{dm}^3}$$

Übersicht:



## 2 Abweichungsfortpflanzung

i	$x_1(l)/\text{dm}$	$x_2(b)/\text{dm}$	$x_3(h)/\text{dm}$	$x_4(m)/\text{dm}$
1	1,0	0,3	0,7	-
2	1,0	0,3	0,6	-
3	0,9	0,3	0,6	-
4	1,0	0,2	0,7	-
5	1,0	0,3	0,6	-
Mittelwerte $\bar{x}_m$	1,0	0,28	0,64	1,402
Streuung $S_{x_m}$	0,0707	0,0447	0,0548	
$t_{4;0,975}$	2,78	2,78	2,78	
$c_{x_m}$	0,0879	0,0556	0,0681	0,041
Abl. $\rho$ bei Mittelwert	-7,824	-27,942	-12,224	5,580
$(c_{x_m} \cdot \text{Ableitung})^2$	0,4731	2,4137	0,6927	0,0523

Erwartungswert und Konfidenzintervall der Dichte für statistische Sicherheit  $P\% = 95\%$ :

$$\underline{\rho = 7,824 \text{ kg/dm}^3 \pm 1,906 \text{ kg/dm}^3}$$

### L 7 Torsionsmodul Stahldraht

#### Vorgehen:

1. Formel für Torsionsmodul  $G$  aufstellen
2. sämtliche Vertrauensbereiche für *gleiche Aussagesicherheiten* berechnen  
(evtl. umrechnen)
3. Vertrauensintervall ermitteln

$$\text{Hier: } G = \frac{8\pi L\Theta}{R^4 T^2}$$

#### Periodendauer

$$\text{Mittelwert : } \bar{T} = 11,2 \text{ s} \quad \text{für } n = 7$$

$$S = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (T_i - \bar{T})^2} = \sqrt{\frac{1}{6} (0,04 + 0 + 0,04 + 0,04 + 0,09 + 0 + 0,01) \text{ s}}$$

$$S = \sqrt{\frac{1}{6} \cdot 0,22 \text{ s}^2} = 0,191485 \text{ s}$$

$$c = \frac{t}{\sqrt{n}} \cdot S \quad \text{mit } t = t_{s;p} \quad (s = \text{Freiheitsgrad und } p = \text{Wahrscheinlichkeit})$$

$$\text{hier: } s = n - 1 = 6$$

$$p = 1 - \alpha/2 \quad P = 95 \% \Rightarrow \alpha = 0,05$$

$$\Rightarrow p = 0,975$$

$$\Rightarrow \text{aus Tabelle: } t_{6;0,975} = 2,45$$

$$c_T = \frac{2,45}{\sqrt{7}} \cdot S = 0,926 \cdot 0,191485 \text{ s} = 0,1773 \text{ s} \quad (\approx 0,18 \text{ s})$$

$$\Rightarrow \underline{T = 11,2 \text{ s} \pm 0,1773 \text{ s} \quad P = 95 \%}$$

#### Radius

$$R = d/2, \quad \bar{d} = 0,4924 \text{ mm} \Rightarrow \bar{R} = 0,2462 \text{ mm}$$

$$\text{mit: } n = 5 \quad \text{Radien: } 0,245 \quad 0,2465 \quad 0,2455 \quad 0,2465 \quad 0,2475$$

## 2 Abweichungsfortpflanzung

---

$$S = \sqrt{\frac{1}{4} \cdot (1,14 \cdot 10^{-6} + 9 \cdot 10^{-8} + 4,9 \cdot 10^{-7} + 9 \cdot 10^{-8})} \text{ mm}$$

$$S = 9,75 \cdot 10^{-4} \text{ mm}$$

$$s = 4 \quad p = 0,975$$

$$\Rightarrow t = 2,78$$

$$c_R = \frac{t}{\sqrt{n}} \cdot S = \frac{2,78}{\sqrt{5}} \cdot 9,75 \cdot 10^{-4} \text{ mm}$$

$$\underline{c_R = 1,212 \cdot 10^{-3} \text{ mm}}$$

$$\Rightarrow R = 0,2462 \text{ mm} \pm 1,2 \cdot 10^{-3} \text{ mm} \quad P = 95 \%$$

### Länge

$$\bar{L} = 121,02 \text{ cm} \quad n = 5$$

$$S = \sqrt{\frac{1}{4} \cdot (0,0484 + 0,0004 + 0,0324 + 0,0144 + 0,0324)}$$

$$\underline{S = 0,18 \text{ cm}}$$

$$\Rightarrow t = 2,78$$

$$c_L = \frac{2,78}{\sqrt{5}} \cdot 0,18 \text{ cm}$$

$$\underline{c_L = 0,223 \text{ cm}}$$

$$\underline{L = 121,02 \text{ cm} \pm 0,223 \text{ cm} \quad P = 95 \%}$$

Wichtig: Einheit ist cm  $\Rightarrow$  beim Einsetzen berücksichtigen!

### Trägheitsmoment

$$\Theta = 1,3 \cdot 10^{-3} \text{ kg} \cdot \text{m}^2$$

$$n = 8 \quad c_{\Theta}(99\%) = 1,5 \%$$

Problem: Vertrauensbereich bezieht sich auf 99 % Aussagesicherheit  $\Rightarrow$  muss umgerechnet werden!

$$c_{\Theta}(99\%) = 1,5\% \equiv 1,3 \cdot 10^{-3} \text{ kg m}^2 \cdot 0,015 = 1,95 \cdot 10^{-5} \text{ kg m}^2$$

$$c_{\Theta}(99\%) = \frac{t_{n-1; 1-\alpha_1/2}}{\sqrt{n}} \cdot S$$

## 2 Abweichungsfortpflanzung

---

$$c_{\Theta}(95\%) = \frac{t_{n-1; 1-\alpha_2/2}}{\sqrt{n}} \cdot S$$

$S$  ist bei beiden gleich, da es der selbe Prozess ist.

$\alpha_1 \neq \alpha_2$  somit auch die  $t$ -Werte unterschiedlich

$$S = c_{\Theta}(95\%) \cdot \frac{\sqrt{n}}{t_{n-1; 0,975}} = c_{\Theta}(99\%) \cdot \frac{\sqrt{n}}{t_{n-1; 0,995}}$$

$$c_{\Theta}(95\%) = \frac{t_{7; 0,975}}{t_{7; 0,995}} \cdot c_{\Theta}(99\%)$$

$$c_{\Theta} = \frac{2,36}{3,50} \cdot 1,95 \cdot 10^{-5} \text{ kg m}^2$$

$$\underline{c_{\Theta} = 1,315 \cdot 10^{-5} \text{ kg m}^2} \quad (P=95\%)$$

Mit diesen Einzelmomenten ergibt sich das Torsionsmodul zu:

$$\bar{G} = \frac{8\pi \cdot \bar{L} \cdot \bar{\Theta}}{R^4 \cdot \bar{T}^2} = \frac{8\pi \cdot 121,02 \cdot 10^{-2} \text{ m} \cdot 1,3 \cdot 10^{-3} \text{ kg m}^2}{(0,2462 \cdot 10^{-3} \text{ m})^4 \cdot (11,2 \text{ s})^2}$$

$$\bar{G} = 8,579 \cdot 10^{10} \frac{\text{kg}}{\text{m} \cdot \text{s}^2} \quad [G] = \frac{\text{N}}{\text{m}^2} = \text{Pa}$$

$$\text{Dimensionskontrolle: } \frac{\text{kg m}^2 \cdot \text{m}}{\text{m}^4 \cdot \text{s}^2} = \frac{\text{kg}}{\text{m} \cdot \text{s}^2}$$

### Abweichungsfortpflanzung / Vertrauensbereich

$$\sigma = \sqrt{\sum_{i=1}^m \left( \frac{\partial f}{\partial x_i} \sigma_i \right)^2} \quad \text{bzw.} \quad c = \sqrt{\sum_{i=1}^m \left( \frac{\partial f}{\partial x_i} c_i \right)^2}$$

$$\begin{aligned} c_G &= \sqrt{\left( \frac{\partial G}{\partial L} \cdot c_L \right)^2 + \left( \frac{\partial G}{\partial R} \cdot c_R \right)^2 + \left( \frac{\partial G}{\partial T} \cdot c_T \right)^2 + \left( \frac{\partial G}{\partial \Theta} \cdot c_{\Theta} \right)^2} \\ &= \sqrt{\left( \frac{8\pi \cdot \bar{\Theta}}{R^4 \cdot \bar{T}^2} \cdot c_L \right)^2 + \left( -4 \cdot \frac{8\pi \cdot \bar{L} \cdot \bar{\Theta}}{R^5 \cdot \bar{T}^2} \cdot c_R \right)^2 + \left( -2 \cdot \frac{8\pi \cdot \bar{L} \cdot \bar{\Theta}}{R^4 \cdot \bar{T}^3} \cdot c_T \right)^2 + \left( \frac{8\pi \cdot \bar{L}}{R^4 \cdot \bar{T}^2} \cdot c_{\Theta} \right)^2} \\ &= \sqrt{(1,5723 \cdot 10^8)^2 + (1,6852 \cdot 10^9)^2 + (2,7162 \cdot 10^9)^2 + (8,698 \cdot 10^8)^2} \text{ Pa} \\ &= \sqrt{(2,472 \cdot 10^{16} + 2,8399 \cdot 10^{18} + 7,378 \cdot 10^{18} + 7,5657 \cdot 10^{17})} \text{ Pa} \\ &= 3,32 \cdot 10^9 \text{ Pa} \quad (\text{entspricht } 3,9\%) \end{aligned}$$

Das Produkt aus Ableitung und Vertrauensbereich muss für jedes  $x_i$  die gleiche Dimension der Endgröße haben (hier  $[G]=\text{Pa}$ )! Hier empfiehlt sich Dimensionskontrolle beim Einsetzen!

$$\underline{\underline{\text{Gesamtergebnis: } G = (8,579 \cdot 10^{10} \pm 3,32 \cdot 10^9) \text{ Pa} \quad P = 95\%}}$$

## 3 Student'scher t-Test

### 3.1 t-Test für den Erwartungswert

#### L 8 Gewicht von Kohlköpfen

##### Einseitiger Test

Der Test erfolgt einseitig, da (aus Sicht der Ladenkette) höhere Kopfgewichte natürlich zugelassen sind.

Nullhypothese:  $H_0: \mu = \mu_0 = 1000 \text{ g}$

Alternativhypothese:  $H_1: \mu < \mu_0 = 1000 \text{ g}$

##### Berechnete Statistiken

Mittelwert:  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = 960,7 \text{ g}$

Streuung:  $S = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} = 46,5 \text{ g}$

Die Testgröße:  $t_0 = \frac{\bar{x} - \mu_0}{s/\sqrt{n}} = \frac{960,7 \text{ g} - 1000 \text{ g}}{46,5 \text{ g}/\sqrt{7}} = -2,24$

Die Freiheitsgrade:  $df = n - 1 = 7 - 1 = 6$

Ablehnung von  $H_0$ , wenn  $t_0 < -t_{df; 1-\alpha}$

Den kritischen t-Wert ( $t_{df; 1-\alpha}$ ) aus Tabelle:  $t_{6; 0,95} = 1,94$

In unserem Beispiel:  $t_0 = -2,24 < -t_{6; 0,95} = -1,94$

Damit wird  $H_0$  auf dem Signifikanzniveau  $\alpha = 0,05$  abgelehnt.

(Wichtig: Die ursprüngliche Aufgabenstellung beantworten!)  $\Rightarrow$  **Die Chinakohlköpfe des Lieferanten sind signifikant zu leicht.**

##### Zweiseitiger Test

Der Test erfolgt zweiseitig, wenn wir die Frage so formulieren, daß auch die höheren Kopfgewichte nicht zugelassen sind. (z.B. die Verbraucher tolerieren auch die höhere Kopfgewichte nicht, weil die sich nicht gut in den Kühlschrank legen lassen)

Nullhypothese:  $H_0: \mu = \mu_0 = 1000 \text{ g}$

Alternativhypothese:  $H_1: \mu \neq \mu_0 = 1000 \text{ g}$

#### Berechnete Statistiken:

$$\text{Mittelwert: } \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = 960,7 \text{ g}$$

$$\text{Streuung: } S = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} = 46,5 \text{ g}$$

$$\text{Die Testgröße: } t_0 = \frac{\bar{x} - \mu_0}{s/\sqrt{n}} = \frac{960,7 \text{ g} - 1000 \text{ g}}{46,5 \text{ g}/\sqrt{7}} = -2,24$$

$$\text{Die Freiheitsgrade: } df = n - 1 = 7 - 1 = 6$$

Ablehnung von  $H_0$ , wenn  $|t_0| > t_{df; 1-\alpha/2}$

Der kritische t-Wert ( $t_{df; 1-\alpha/2}$ ) aus Tabelle:  $t_{6; 0,975} = 2,45$

In unserem Beispiel:

$$|t_0| = 2,24 < t_{6; 0,975} = 2,45$$

Es besteht kein Grund  $H_0$  auf dem Signifikanzniveau  $\alpha = 0,05$  abzulehnen.

**Das beobachtete „Untergewicht“ liegt also noch im Rahmen der erwarteten statistischen Schwankung.**

#### L 9 Ozongehalt der Luft

##### Testproblem:

$$H_0 : \mu_x = \mu_0 \quad \text{gegen } H_1 : \mu_x > \mu_0$$

$$H_0 : \mu_x = 120 \mu\text{g}/\text{m}^3 \quad \text{gegen } H_1 : \mu_x > 120 \mu\text{g}/\text{m}^3$$

##### Statistiken:

$$\bar{x} = \sum_{i=1}^n \frac{x_i}{n} = \frac{613}{5} = 122,6 \frac{\mu\text{g}}{\text{m}^3}$$

$$S = +\sqrt{S^2} = \sqrt{\sum_{i=1}^n \frac{(x_i - \bar{x})^2}{n-1}} = \sqrt{\frac{179,2}{4}} = 6,69 \frac{\mu\text{g}}{\text{m}^3}$$

$$\mu_0 = 120 \frac{\mu\text{g}}{\text{m}^3}$$

**Die Anzahl der Freiheitsgrade ist:**

### 3 Student'scher t-Test

---

$$df = n - 1 = 5 - 1 = 4$$

**Die Testgröße:**

$$t_0 = \frac{\bar{x} - \mu_0}{S} \cdot \sqrt{n} = \frac{(122,6 - 120) \mu\text{g}/\text{m}^3}{6,69 \mu\text{g}/\text{m}^3} \sqrt{5} = 0,8686$$

$$t_{n-1; 1-\alpha} = t_{4; 0,95} = 2,13$$

$$t_0 = 0,8686 < 2,13 = t_{4; 0,95}$$

Die Nullhypothese kann auf einem Signifikanzniveau von 5 % nicht abgelehnt werden.

**Man kann also nicht behaupten, dass der Ozongehalt signifikant größer ist als der Grenzwert von  $120 \mu\text{g}/\text{m}^3$ .**

### 3.2 t-Test für Vergleich zweier Erwartungswerte unabhängiger Stichproben

#### L 10 Futtereinfluss auf Gewichtszunahme bei Schweinen

Da interessiert, ob das Futter mit hohem Proteingehalt höhere Gewichtszunahme liefert, wird die **einseitige Alternativhypothese** gewählt.

Nullhypothese:  $H_0 : \mu_H = \mu_N$

Alternativhypothese:  $H_1 : \mu_H > \mu_N$

**Statistiken:**

Mittelwerte:  $\bar{H} = 697,3 \text{ g}$      $\bar{N} = 628,5 \text{ g}$

Streuungen:  $S_H = 36,8 \text{ g}$      $S_N = 47,4 \text{ g}$

**Die Testgröße:**

Weil der Umfang  $n$  der beiden Stichproben gleich ist, kann man die einfachere Gleichungsform für  $t_0$  verwenden:

$$t_0 = \sqrt{n} \frac{\bar{H} - \bar{N}}{\sqrt{S_H^2 + S_N^2}} = \sqrt{8} \frac{697,3 \text{ g} - 628,5 \text{ g}}{\sqrt{36,8^2 \text{ g}^2 + 47,4^2 \text{ g}^2}} = 3,24$$

Freiheitsgrade:  $df = n_H + n_N - 2 = 8 + 8 - 2 = 14$

### 3 Student'scher t-Test

---

Entscheidung: Ablehnung von  $H_0$ , wenn  $t_0 > t_{df; 1-\alpha}$

Der kritische t-Wert ( $t_{df; 1-\alpha}$ ) aus Tabellen:  $t_{14; 0,99} = 2,62$

In unserem Beispiel:  $t_0 = 3,24 > t_{14; 0,99} = 2,62$

Also wird  $H_0$  auf dem Signifikanzniveau  $\alpha = 0,01$  abgelehnt und die Alternativhypothese  $H_1$  wird angenommen.

**Das Futtermittel mit dem höheren Proteingehalt liefert höhere Gewichtszunahme.**

#### L 11 Medikamenteneinfluss auf Tierwachstum

Zweiseitiger t-Test für den Vergleich zweier Erwartungswerte.

**Die Nullhypothese lautet:**

$$H_0 : \mu_x = \mu_y \quad H_1 : \mu_x \neq \mu_y$$

**Die Mittelwerte lauten:**

$$\bar{x} = 72 \text{ cm} \qquad \bar{y} = 75 \text{ cm}$$

**Die Streuungen sind:**

$$S_x = S_y = 3,9279 \text{ cm} \quad (\text{nur zufällig gleich})$$

**Die Anzahl der Freiheitsgrade ist:**

$$df = n_x + n_y - 2 = 16 - 2 = 14$$

**zweiseitiger t-Test:**

$$t_0 = \frac{\bar{x} - \bar{y}}{\sqrt{S_x^2 + S_y^2}} \cdot \sqrt{n} = \frac{(72 - 75) \text{ cm}}{\sqrt{30,8568} \text{ cm}} \cdot \sqrt{8} = -1,5275$$

$$t_{df; 1-\frac{\alpha}{2}} = t_{14; 0,975} = 2,15$$

$$|t_0| = 1,5275 < 2,15 = t_{14; 0,975}$$

Die Hypothese  $H_0$  kann auf dem Signifikanzniveau von  $\alpha = 0,05$  nicht abgelehnt werden.

**Das Medikament hat somit keinen signifikanten Einfluss auf das Wachstum.**



#### L 12 Ertrag verschiedener Pilzarten

Das Testproblem ist:

$$H_0 : \mu_x = \mu_y \quad \text{gegen} \quad H_1 : \mu_x \neq \mu_y$$

Die Mittelwerte sind:

$$\bar{x} = \sum_{i=1}^n \frac{x_i}{n} = \frac{62,1}{10} = 6,21 \text{ kg} \quad \bar{y} = \sum_{i=1}^n \frac{y_i}{n} = \frac{62,7}{12} = 5,225 \text{ kg}$$

Die Streuungen lauten:

$$S_x = +\sqrt{S_x^2} = \sqrt{\sum_{i=1}^n \frac{(x_i - \bar{x})^2}{n-1}} = \sqrt{\frac{16,929}{9}} = \sqrt{1,881} = 1,37 \text{ kg}$$

$$S_y = +\sqrt{S_y^2} = \sqrt{\sum_{i=1}^n \frac{(y_i - \bar{y})^2}{n-1}} = \sqrt{\frac{1,7025}{11}} = \sqrt{0,155} = 0,393 \text{ kg}$$

$$S = \sqrt{\frac{(n-1)S_x^2 + (m-1)S_y^2}{n+m-2}} = \sqrt{\frac{18,63}{20}} \approx 0,965 \text{ kg}$$

( $S \hat{=}$  gewichtete Streuung)

Die Anzahl der Freiheitsgrade beträgt:

$$df = n + m - 2 = 10 + 12 - 2 = 20$$

Die Testgröße ist:

$$t_0 = \frac{\bar{x} - \bar{y}}{S} \sqrt{\frac{n \cdot m}{n+m}} = \frac{0,985 \text{ kg}}{0,965 \text{ kg}} \sqrt{\frac{120}{22}} = 2,38$$

$$t_{n+m-2; 1-\frac{\alpha}{2}} = t_{20; 0,975} = 2,09$$

$$t_0 = 2,38 > 2,09 = t_{20; 0,975}$$

Damit kann die Nullhypothese zum Signifikanzniveau abgelehnt werden und wir können sagen, dass die Erträge der beiden Pilze auf einem Signifikanzniveau von 5% unterschiedlich sind.

## 3.3 t-Test für Vergleich zweier Erwartungswerte verbundener Stichproben

### L 13 Einfluss der Benzinqualität auf Treibstoffverbrauch

Die Stichproben sind in diesem Fall verbunden, weil der Verbrauch eines Autotyps mit beiden Benzinmarken in der gleichen Größenordnung liegt, die Unterschiede zwischen verschiedenen Autotypen sind jedoch groß. Aus den beiden Stichproben  $E_i$  und  $A_i$  werden die Differenzen  $d_i = E_i - A_i$  gebildet und man testet die Hypothese, ob die Grundgesamtheit, aus der diese Differenz  $d_i$  stammt, den Erwartungswert  $\mu_d = 0$  besitzt (in diesem Falle sind natürlich die Stichprobenumfänge automatisch gleich groß,  $n_E = n_A = n$ ).

Da interessiert, ob ein Unterschied in beiden Richtungen entsteht, oder nicht, wird ein **zweiseitiger Test** durchgeführt.

Nullhypothese:  $H_0 : \mu = \mu_d = 0$

Alternativhypothese:  $H_1 : \mu = \mu_d \neq 0$

Der Test läuft weiter, wie beim einfachen t-Test für den Erwartungswert.

#### Berechnete Statistiken:

Mittelwert:  $\bar{d} = -0,32 \text{ L}/100 \text{ km}$

Streuung:  $S_d = 0,217 \text{ L}/100 \text{ km}$

#### Die Testgröße:

$$t_0 = \frac{\bar{d}}{S_d/\sqrt{n}} = \frac{-0,32}{0,217/\sqrt{5}} = -3,3$$

#### Die Freiheitsgrade:

$$df = n - 1 = 5 - 1 = 4$$

#### Die Entscheidung:

Ablehnung von  $H_0$ , wenn  $|t_0| > t_{df; 1-\alpha/2}$

Der kritische t-Wert ( $t_{df; 1-\alpha/2}$ ) aus Tabellen:  $t_{krit} = t_{4; 0,975} = 2,78$

Hier:  $|t_0| = 3,3 > t_{4; 0,975} = 2,78$

Also wird  $H_0$  auf dem Signifikanzniveau  $\alpha = 0,05$  abgelehnt, und die Alternativhypothese  $H_1$  wird angenommen.

Anders formuliert: **Die Benzinsorten haben einen signifikanten Qualitätsunterschied.**

#### L 14 Wirksamkeit von Schlafmitteln

Diese Messungen sind verbundene Stichproben, da die Versuchspersonen individuell verschieden auf Medikamente reagieren. In diesem Fall kann man den Einfluss der Variabilität der Individuen, also deren unterschiedliche Reaktion auf Medikamente, eliminieren. Dies ist der Vorteil des Paarvergleichs. Wird die Gruppe jedoch in zwei Hälften geteilt, wobei jede Hälfte ausschließlich das eine Medikament erhält, dann sind die Stichproben unabhängig.

**Vermutung:** Die Erwartungswerte der Schlafverlängerung durch das Mittel A und das Mittel B sind gleich.

Nullhypothese:  $H_0 : \mu_A = \mu_B$

Alternativhypothese:  $H_1 : \mu_A \neq \mu_B$

**Die Anzahl der Freiheitsgrade ist:**

$$df = 10 - 1 = 9$$

Patient i	A <sub>i</sub>	B <sub>i</sub>	d <sub>i</sub> = A <sub>i</sub> - B <sub>i</sub>	d <sub>i</sub> <sup>2</sup>
1	1,9	0,7	1,2	1,44
2	0,8	-1,6	2,4	5,76
3	1,1	-0,2	1,3	1,69
4	0,1	-1,2	1,3	1,69
5	-0,1	-0,1	0,0	0,00
6	4,4	3,4	1,0	1,00
7	5,5	3,7	1,8	3,24
8	1,6	0,8	0,8	0,64
9	4,6	0,0	4,6	21,16
10	3,4	2,0	1,4	1,96
$\Sigma$	23,3	7,5	15,8	38,58
$\Sigma / 10$	$\bar{A} = 2,33$	$\bar{B} = 0,75$	$\bar{d} = 1,58$	

**Die Streuung der Differenzen lautet:**

$$S_d^2 = \frac{1}{9} \cdot \left( 38,58 - \frac{1}{10} \cdot 15,8^2 \right) = 1,513$$

$$\Rightarrow S_d \approx 1,23$$

**Die Testgröße ist dann:**

$$t_0 = \frac{\bar{d}}{S_d} \cdot \sqrt{n} = \frac{1,58}{1,23} \cdot \sqrt{10} = 4,06$$

### 3 Student'scher t-Test

---

Mit  $\alpha = 0,01 = 1\%$  erhält man  $t_{9;0,995} = 3,25$ .

$$|t| = 4,06 > 3,25 = t_{9;0,995}$$

Die Nullhypothese über die Gleichheit der beiden Mittel wird auf dem 1%-Signifikanzniveau abgelehnt.

#### **Die Schlafmittel unterscheiden sich signifikant in ihrer Wirksamkeit.**

Es soll an dieser Stelle ausdrücklich darauf hingewiesen werden, dass ein Testergebnis kein Beweis für eine Theorie ist. Es kommt sehr stark auf die Formulierung der Hypothesen, die unterstellten Voraussetzungen und die Versuchsdurchführung an. Das zuerst verabreichte Medikament kann im vorliegenden Fall noch in der folgenden Nacht wirksam sein und so eine Schlaf verlängernde Wirkung des zweiten Medikaments vortäuschen. Dieser Effekt ist der sog. **carry-over**. Es wird also eine Wirkung in eine folgende Versuchsperiode mit hinübertragen. Es wäre eventuell sinnvoll, eine Pause zwischen der ersten und zweiten Verabreichung einzulegen, um einen **wash-out** zu erreichen. Dies könnte allerdings wiederum zur Folge haben, dass die Versuchspersonen nach dieser Zeitspanne physisch und psychisch anders reagieren als unmittelbar nach der ersten Nacht.

## 4 Einfache Varianzanalyse (ANOVA)

### L 15 Wirkung von Fungiziden

Die Gesamtvariation wird durch die Summe der quadrierten Abweichungen aller 15 Beobachtungen von Gesamtmittel  $\bar{x}$  erfasst, und mit  $SQ_{total}$  bezeichnet. Sie wird in zwei Komponenten zerlegt:

1. Die quadrierten Abweichungen **zwischen** den Gruppen ( $SQZ$ ) (Abweichungen der Gruppenmittelwerte vom Gesamtmittelwert)
2. Die quadrierten Abweichungen **innerhalb** der Gruppen ( $SQI$ )

		Behandlung (Gruppe) $j = 1 \dots k$			
		1	2	3	
Wiederholungen $i$	1	5,2	3,9	2,2	
	2	5,2	3,4	2,6	
	3	2,5	2,5	3,4	
	4	4,4	2	4,4	
	5	6,2	1,2	3,4	Gesamt:
$\bar{x}_j$		<b>4,7</b>	<b>2,6</b>	<b>3,2</b>	$\bar{x} = 3,5$

Die folgende Gleichung ermöglicht es,  $SQI$  als Differenz von  $SQ_{total}$  und  $SQZ$  zu berechnen, was u. U. schneller geht, wenn Statistikfunktionen des Taschenrechners verwendet werden.

$$SQ_{total} = SQZ + SQI$$

$$\sum_{j=1}^k \sum_{i=1}^{n_j} (x_{ij} - \bar{x})^2 = \sum_{j=1}^k n_j (\bar{x}_j - \bar{x})^2 + \sum_{j=1}^k \sum_{i=1}^{n_j} (x_{ij} - \bar{x}_j)^2$$

Hilfsgrößen:

$$n = k \cdot n_j \quad (\text{nur hier!}) \quad \bar{x} = \frac{1}{n} \sum_{j=1}^k \sum_{i=1}^{n_j} x_{ij} \quad \bar{x}_j = \frac{1}{n_j} \sum_{i=1}^{n_j} x_{ij}$$

$$SQ_{total} = 26,92 \quad (= S^2 \cdot (n - 1) = 1,38667^2 \cdot 14 = 1,923 \cdot 14)$$

$$SQZ = 11,70 \quad (= 5 \cdot (4,7 - 3,5)^2 + 5 \cdot (2,6 - 3,5)^2 + 5 \cdot (3,2 - 3,5)^2)$$

## 4 Einfache Varianzanalyse (ANOVA)

---

$$SQI = 15,22$$

Der Schätzwert  $S_z^2$  für die Varianz zwischen den Gruppen ergibt sich:

$$S_z^2 = MQZ = \frac{SQZ}{FGZ} = \frac{SQZ}{k-1} = \frac{11,70}{3-1} = 5,85$$

Der Schätzwert  $S_i^2$  für die Varianz innerhalb der Gruppen ergibt sich (unter der Annahme, dass die drei Verteilungen die gleiche Varianz besitzen):

$$S_i^2 = MQI = \frac{SQI}{FGI} = \frac{SQI}{n-k} = \frac{15,22}{15-3} = 1,27$$

### Statistischer Test

Hypothese: Alle Stichproben (Behandlungen) haben den gleichen Erwartungswert

$$\text{Testgröße: } F_0 = \frac{MQZ}{MQI} = \frac{5,85}{1,27} = 4,61$$

Bestimmung des kritischen Werts:

$$\text{Anzahl der Freiheitsgrade: } FGZ = k - 1 = 2 \quad FGI = n - k = 12$$

Das geforderte Signifikanzniveau:  $\alpha = 0,05$

$$F_{kritisch} = F_{FGZ; FGI; 1-\alpha} = F_{2; 12; 0,95} = 3,89$$

Die Entscheidung: Hypothese wird angenommen falls  $F_0 < F_{kritisch}$ !

In unserem Fall  $F_0 = 4,61 > F_{kritisch} = 3,89$ , also können wir die Hypothese bei  $\alpha = 0,05$  nicht annehmen.

D. h., mindestens ein Fungizid beeinflusst das Pilzwachstum.

5  $\chi^2$ -Test

## L 16 Unkrautzählung

$i$	$X_i$	$n_i$	$X_i n_i$	$(X_i - \bar{x})^2$	$(X_i - \bar{x})^2 n_i$
1	0	3	0	13,84	41,52
2	1	9	9	7,40	66,59
3	2	15	30	2,96	44,38
4	3	21	63	0,52	10,89
5	4	19	76	0,08	1,49
6	5	15	75	1,64	24,58
7	6	10	60	5,20	51,98
8	7	5	35	10,76	53,79
9	8	3	24	18,32	54,96
$K = 9$	$n = \sum n_i = 100$	<b>372</b>	<b>60,71</b>	<b>350,16</b>	

$i$  Nummer der Klasse

$K$  Anzahl der Klassen ( $K = 9$ )

$X_i$  Anzahl der gefundenen Unkrautpflanzen für Klasse  $i$

$n_i$  Anzahl der Teilflächen, die der Klasse  $X_i$  zugeordnet werden

$\Delta x$  Klassenbreite ( $\Delta x = X_{i+1} - X_i = 1$ )

Nullhypothese  $H_0$ :  $u$  ist Poisson-verteilt

Berechnete Statistiken:

$$\text{Mittelwert: } \bar{x} = \frac{\sum (X_i n_i)}{\sum n_i} = 3,72$$

$$\text{Empirische Varianz: } S^2 = \frac{\sum (X_i - \bar{x})^2 n_i}{n - 1} = 3,54$$

$$\text{Empirische Streuung: } S = +\sqrt{S^2} = 1,88$$

Die Poisson-Verteilung  $h(x)_{\text{Poisson}} = \lambda^x \frac{e^{-\lambda}}{x!}$  enthält den Parameter  $\lambda$ , der aus den Messwerten geschätzt wird:  $\lambda = \bar{x} = 3,72$

Mit diesen Werten erhalten wir für die jeweiligen  $X_i$  folgende Werte der Poisson-Verteilung:

$X_i$	$H_e(X_i)$	$h(X_i)_{Poisson}$	$H_t(X_i)$	$H_e(X_i)$	relative Häufigkeit für Klasse $i \Rightarrow H_e(X_i) = n_i/n$ .
0	0,03	0,024	0,024		
1	0,09	0,090	0,090		
2	0,15	0,168	0,168		Dieser Wert wird im
3	0,21	0,208	0,208		weiteren aber nicht be-
4	0,19	0,193	0,193		nötigt und dient nur der
5	0,15	0,144	0,144		Gegenüberstellung zur
6	0,10	0,089	0,089		theoretischen Verteilung
7	0,05	0,047	0,047		
8	0,03	0,022	0,022		
$\Sigma$	<b>1,00</b>		<b>0,986</b>	$h(X_i)_{Poisson}$	Wert der Poisson-Verteilung mit Parameter $\mu = \bar{x}$ an der Stelle $X_i$
				$H_t(X_i)$	relative Häufigkeit für Klasse $i \Rightarrow H_t(X_i) = h(x)_{Poisson} \Delta x$ mit $\Delta x = 1$

Die Testgröße  $\chi^2 = \sum_{i^*=1}^{K^*} \frac{(B_{i^*} - E_{i^*})^2}{E_{i^*}} = \sum_{i^*=1}^{K^*} \frac{(B_{i^*} - nH_t(X_{i^*}))^2}{nH_t(X_{i^*})}$  ist  $\chi^2_{(p;df)}$ -verteilt, wenn  $H_0$  zutrifft.

$nH_t(X_i)$	$i^*$	$B_{i^*}$	$nH(X_{i^*}) \geq 10$	$B_{i^*} - nH_t(X_{i^*})$	$\frac{(B_{i^*} - nH_t(X_{i^*}))^2}{nH_t(X_{i^*})}$
2,42					
9,02	1	12	11,44	0,56	0,03
16,77	2	15	16,77	-1,77	0,19
20,79	3	21	20,79	0,21	0,00
19,34	4	19	19,34	-0,34	0,01
14,39	5	15	14,39	0,61	0,03
8,92	6	18	15,86	2,14	0,29
4,74					
2,20					
$K^* = 6$					$\chi^2 = 0,54$

$i^*$  Nummer der Klassen nach Zusammenlegung besetzungsschwacher Klassen (In diesem Beispiel sei eine Mindestbesetzung von 10 gefordert)

$K^*$  Reduzierte Zahl der Klassen

$df$  Anzahl Freiheitsgrade  $df = K^* - p - 1$  (in unserem Beispiel:  $df = 6 - 1 - 1 = 4$ )

$p$  Anzahl Parameter (in unserem Beispiel:  $p = 1$  ( $\lambda$ ))



Wenn wir bei einem Signifikanzniveau  $\alpha = 0,05$  eine Entscheidung treffen wollen:

Aus Tabellen: Kritisches  $\chi^2_{(p=0,95; df=4)} = 9,49$

Schlussfolgerung:  $\chi^2 < \chi^2_{(0,95; 4)} = 9,49$

$\Rightarrow$  Auf dem Signifikanzniveau  $\alpha = 0,05$  ist es nicht gerechtfertigt, die Hypothese  $H_0$  zu verwerfen.

D.h., die Anzahl der Unkrautpflanzen pro Fläche ist vermutlich Poisson-verteilt.

### L 17 Milchleistung von Kühen

Messergebnisse und Hilfsgrößen

$i$	$X_i$	$n_i$	$X_i n_i$	$(X_i - \bar{x})^2$	$(X_i - \bar{x})^2 n_i$
1	37,5	5	187,5	211,70	1058,51
2	42,5	9	382,5	91,20	820,82
3	47,5	25	1187,5	20,70	517,56
4	52,5	22	1155,0	0,20	4,46
5	57,5	33	1897,5	29,70	980,18
6	62,5	2	125,0	109,20	218,41
7	67,5	4	270,0	238,70	954,81
<b>K=7</b>		<b><math>n = \sum n_i = 100</math></b>	<b>5205</b>	<b>701,42</b>	<b>4554,75</b>

- $i$  Nummer der Klasse
- $K$  Anzahl der Klassen ( $K = 7$ )
- $X_i$  Klassenmitte der Milchleistung von Kühen in dt/a
- $n_i$  Beobachtete Klassenhäufigkeiten
- $\Delta x$  Klassenbreite ( $\Delta x = X_{i+1} - X_i = 5 \text{ dt/a}$ )

Nullhypothese  $H_0$ : Milchleistung ist normalverteilt

Berechnete Statistiken:

$$\text{Mittelwert: } \bar{x} = \frac{\sum (X_i n_i)}{\sum n_i} = 52,05 \text{ dt/a}$$

$$\text{Empirische Varianz: } S^2 = \frac{\sum (X_i - \bar{x})^2 n_i}{n - 1} = 46,01 \text{ dt}^2/\text{a}^2$$

$$\text{Empirische Streuung: } S = +\sqrt{S^2} = 6,78 \text{ dt/a}$$

## 5 $\chi^2$ -Test

Die Normal-Verteilung  $h(x)_{Normal} = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$  enthält die Parameter  $\mu$  und  $\sigma$ , die aus den Messwerten geschätzt werden:

$$\mu = \bar{x} = 52,05 \text{ dt/a} \qquad \sigma = S = 6,78 \text{ dt/a}$$

**Variante 1** (bei kontinuierlichen Verteilungen empfohlen):

Die Testgröße  $\chi^2 = \sum_{i=1}^{K^*} \frac{(B_i - E_i)^2}{E_i}$  ist  $\chi^2_{(p; df)}$ -verteilt, wenn  $H_0$  zutrifft.

$i$	$x_{g_i}$	$\Phi(x_{g_i})$	$\Phi(x_{g_i}) - \Phi(x_{g_{i-1}})$	$E_i = n(\Phi(x_{g_i}) - \Phi(x_{g_{i-1}}))$	$i^*$	$E_{i^*} > 5$	$B_{i^*}$	$B_{i^*} - E_{i^*}$	$\frac{(B_{i^*} - E_{i^*})^2}{E_{i^*}}$
1	35	0,00587							
2	40	0,03754	0,0317	3,17					
3	45	0,14917	0,1116	11,16	1	14,33	14	-0,33	0,01
4	50	0,38239	0,2332	23,32	2	23,32	25	1,68	0,12
5	55	0,67003	0,2876	28,76	3	28,76	22	-6,76	1,59
6	60	0,87900	0,209	20,9	4	20,9	33	12,1	7,01
7	65	0,97193	0,0929	9,29	5	11,7	6	-5,7	2,78
8	70	0,99598	0,0241	2,41					
$K^* = 5$									$\chi^2 = 11,51$

$x_{g_i}$  Intervallgrenzen der jeweiligen Klasse, hier z.B.  $37,5 \pm 2,5$  usw.

$i^*$  Nummer der Klassen nach Zusammenlegung besetzungsschwacher Klassen

$K^*$  Reduzierte Zahl der Klassen

$df$  Anzahl Freiheitsgrade  $df = K^* - s - 1$  (in unserem Beispiel:  $df = 5 - 2 - 1 = 2$ )

$s$  Anzahl Parameter (in unserem Beispiel:  $s = 2 (\mu, \sigma)$ )

Für Signifikanzniveau von  $\alpha = 0,05$  aus Tabellen:

Kritisches  $\chi^2_{(p=0,95; df=2)} = 5,99$

Schlussfolgerung:  $\chi^2 = 11,51 > \chi^2_{(0,95; 2)} = 5,99$

$\Rightarrow$  Bei einem Signifikanzniveau  $\alpha = 0,05\%$  können wir die Hypothese  $H_0$  nicht akzeptieren, d.h. die Stichprobe kommt nicht von einer normalverteilten Grundgesamtheit.

**Variante 2:**

Es wird folgender vereinfachter Ansatz gemacht:

$$H_t(X_i) = h(X_i)\Delta x \quad \text{mit} \quad \Delta x = 5 \text{ dt/a}$$

Es wird also die Verteilungsdichte in der Intervallmitte mit der Intervallbreite multipliziert, um die Fläche unter der Verteilungsdichtefunktion, und somit die relativen Häufigkeiten  $H_t$  in diesem Intervall, anzunähern. **Dieses Verfahren sollte vermieden werden** und die Variante 1 verwendet werden. Es wird aber trotzdem kurz erläutert, da es in einigen Übungsaufgaben und alten Klausuren zu finden ist.

Mit den zuvor berechneten Werten für Mittelwert und Streuung ergeben sich folgende Werte  $h(x)$  der Normalverteilung:

$X_i$	$H_e(X_i)$	$h(X_i)_{Normal}$	$H_t(X_i)$	
37,5	0,05	0,0058	0,029	$H_e(X_i)$ relative empirische Häufigkeit für Klasse $i$ $\Rightarrow H_e(X_i) = n_i/n$
42,5	0,09	0,0218	0,109	
47,5	0,25	0,0469	0,235	$h(X_i)_{Normal}$ Wert der Normalverteilung mit Parametern $\mu = \bar{x}, \sigma = s$ an der Stelle $X_i$
52,5	0,22	0,0587	0,294	
57,5	0,33	0,0426	0,213	
62,5	0,02	0,0179	0,090	
67,5	0,04	0,0043	0,022	
$\sum$	<b>1,00</b>		<b>0,992</b>	$H_t(X_i)$ relative theoretische Häufigkeit für Klasse $i$ $\Rightarrow H_t(X_i) = h(X_i)_{Normal}\Delta x$ mit $\Delta x = 5 \text{ dt/a}$

Die Testgröße  $\chi^2 = \sum_{i^*=1}^{K^*} \frac{(B_i - E_i)^2}{E_i} = \sum_{i^*=1}^{K^*} \frac{(B_{i^*} - nH_t(X_{i^*}))^2}{nH_t(X_{i^*})}$  ist  $\chi^2_{(p; df)}$ -verteilt, wenn  $H_0$  zutrifft.

$nH_t(X_i)$	$i^*$	$B_{i^*}$	$nH_t(X_{i^*}) > 5$	$B_{i^*} - nH_t(X_{i^*})$	$\frac{(B_{i^*} - nH_t(X_{i^*}))^2}{nH_t(X_{i^*})}$
2,94					
10,91	1	14	13,85	0,148	0,002
23,49	2	25	23,49	1,512	0,097
29,36	3	22	29,36	-7,356	1,843
21,30	4	33	21,30	11,702	6,429
8,97	5	6	11,16	-5,163	2,388
2,19					
$K^* = 5$					$\chi^2 = 10,76$

Für Signifikanzniveau von  $\alpha = 0,05$  aus Tabellen:

Kritisches  $\chi^2_{(p=0,95; df=2)} = 5,99$

Schlussfolgerung:  $\chi^2 = 10,76 > \chi^2_{(0,95;2)} = 5,99$

$\Rightarrow$  Bei einem Signifikanzniveau  $\alpha = 0,05$  können wir die Hypothese  $H_0$  nicht akzeptieren, d.h. die Stichprobe kommt nicht von einer normalverteilten Grundgesamtheit.

### L 18 Punktzahlen der Statistikklausur

Hier ist die Verteilungsfunktion nicht als Formel, sondern als Tabelle mit der relativen Häufigkeit gegeben.

$H_0$ : Punktzahl ist kryptonormativ-polydiskrimalverteilt :c)

$B_i$	$H_t$	$H_t \cdot n = E_i$	$B_i - E_i$	$(B_i - E_i)^2$	$\frac{(B_i - E_i)^2}{E_i}$
6	0,1	10	4	16	1,60
15	0,2	20	5	25	1,25
39	0,3	30	9	81	2,70
40	0,4	40	0	0	0
					$\chi_0^2 = 5,55$

Die Verteilungsfunktion hat keine Parameter.

$$\Rightarrow s = 4 - 1 = 3$$

$$p = 0,95$$

$$\chi_{krit}^2 = 7,81$$

$$\chi_0^2 < \chi_{krit}^2$$

$\Rightarrow H_0$  ist nicht abzulehnen.

$\Rightarrow$  K. hat recht, Punktzahl ist k.-p.-verteilt.

## 6 Lineare Regression

### L 19 Ertrag von Sommerweizen

$i$	$x_i$	$y_i$	$x_i^2$	$y_i^2$	$x_i \cdot y_i$
1	80	56,2	6400	3158,44	4496
2	90	55,7	8100	3102,49	5013
3	110	75,5	12100	5700,25	8305
4	90	55,7	8100	3102,49	5013
5	110	68,4	12100	4678,56	7524
6	130	67,7	16900	4583,29	8801
7	90	63,3	8100	4006,89	5697
8	110	58,3	12100	3398,89	6413
9	130	80,8	16900	6528,64	10504
10	70	52,1	4900	2714,41	3647
11	150	87,3	22500	7621,29	13095
$\Sigma$	1160	721,0	128200	48595,64	78508

Die Mittelwerte sind:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{11} \cdot 1160 = 105,5 \frac{\text{kg}}{\text{ha}}$$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i = \frac{1}{11} \cdot 721 = 65,5 \frac{\text{dt}}{\text{ha}}$$

Die Streuungen sind:

$$S_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} = \sqrt{\frac{1}{10} 5872,75} = 24,233 \frac{\text{kg}}{\text{ha}}$$

$$S_y = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2} = \sqrt{\frac{1}{10} 1337,39} = 11,565 \frac{\text{dt}}{\text{ha}}$$

Nach der Methode der kleinsten quadratischen Abweichungen geht die Gerade durch den Schwerpunkt der Punkte  $(x_i; y_i)$

$$(y - \bar{y}) = b(x - \bar{x})$$

$$\Rightarrow Y_i = b(x_i - \bar{x}) + \bar{y}$$

Geschätzter Regressionskoeffizient  $b$  (Gleichung aus Formelsammlung umgeformt):

$$\frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2} = \frac{78508 - 11 \cdot 105,5 \cdot 65,5}{128200 - 11 \cdot 105,5^2} = 0,421 \frac{dt}{kg}$$

Der Ordinatenabschnitt der Regressionsgeraden ist:

$$y_0 = \bar{y} - b_1 \bar{x} = 65,5 - 0,421 \cdot 105,5 \frac{dt}{ha} = 21,1 \frac{dt}{ha}$$

Die Regressionsgerade lautet also:

$$Y_i = 21,1 \frac{dt}{ha} + 0,421 \frac{dt}{kg} \cdot x_i$$

Die Restvarianz  $\hat{\sigma}^2$  (ein Schätzwert für  $\sigma^2$ ):

$$\hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n (y_i - Y_i)^2 = \frac{1}{9} \cdot 294,1022 = 32,678 \left( \frac{dt}{ha} \right)^2$$

$$\Rightarrow \hat{\sigma} = +\sqrt{\hat{\sigma}^2} = 5,72 \frac{dt}{ha}$$

Bestimmung der Vertrauensgrenze für diese Schätzung des Steigungsmaßes  $b$ : (die geforderte statistische Sicherheit  $P\% = (1 - \alpha) = 0,99$ )

$$\left[ b - \frac{\hat{\sigma} \cdot t_{n-2; 1-\frac{\alpha}{2}}}{\sqrt{n} \cdot S_x}; b + \frac{\hat{\sigma} \cdot t_{n-2; 1-\frac{\alpha}{2}}}{\sqrt{n} \cdot S_x} \right]$$

In unserem Beispiel:

$$\left[ 0,421 \frac{dt}{kg} - \frac{5,72 \cdot t_{9; 0,995}}{\sqrt{11} \cdot 24,233} \frac{dt}{kg}; 0,421 \frac{dt}{kg} + \frac{5,72 \cdot t_{9; 0,995}}{\sqrt{11} \cdot 24,233} \frac{dt}{kg} \right]$$

Aus Tabellen:  $t_{9; 0,995} = 3,25$

$$\left[ (0,421 - 0,231) \frac{dt}{kg}; (0,421 + 0,231) \frac{dt}{kg} \right]$$

$$\left[ 0,19 \frac{dt}{kg}; 0,652 \frac{dt}{kg} \right]$$

Der Erwartungswert  $\beta$  liegt mit der statistischen Sicherheit von  $P\% = 0,99$  in diesem Intervall.

Der Vertrauensbereich für  $Y$ :

Durch die errechnete Gerade können wir einem beliebig gewählten  $x^*$ -Wert den  $Y^* = b(x^* - \bar{x}) + \bar{y}$  zuordnen.

$$Y^* - \frac{\hat{\sigma} \cdot t_{n-2; 1-\frac{\alpha}{2}}}{\sqrt{n}} \sqrt{1 + \frac{(x^* - \bar{x})^2}{S_x^2}}; Y^* + \frac{\hat{\sigma} \cdot t_{n-2; 1-\frac{\alpha}{2}}}{\sqrt{n}} \sqrt{1 + \frac{(x^* - \bar{x})^2}{S_x^2}}$$

In unserem Beispiel:

$$P\% = 0,99 \quad t_{9; 0,995} = 3,25$$

$$x_1^* = 70 \frac{\text{kg}}{\text{ha}} \quad x_2^* = 150 \frac{\text{kg}}{\text{ha}}$$

$$Y_1^* = 50,57 \quad Y_2^* = 84,25$$

Vertrauensbereich 1:

$$[(50,57 - 9,942) \text{ kg}; (50,57 + 9,942) \text{ kg}]$$

$$[40,628 \text{ kg}; 60,512 \text{ kg}]$$

Vertrauensbereich 2:

$$[(84,25 - 11,72) \text{ kg}; (84,25 + 11,72) \text{ kg}]$$

$$[72,53 \text{ kg}; 95,97 \text{ kg}]$$

### L 20 Zusammenhang von Körpergröße und Gewicht

Nach der Methode der kleinsten quadratischen Abweichungen geht diese Gerade durch den Schwerpunkt  $(\bar{x}; \bar{y})$  der Punkte  $(x_i; y_i)$ .

$$(Y - \bar{y}) = b(x - \bar{x})$$

$$Y_i = b(x_i - \bar{x}) + \bar{y}$$

$b$ : Regressionskoeffizient (Steigung der Geraden)

$Y_i$ : der berechnete Gleichungswert an der Stelle  $x_i$

## 6 Lineare Regression

---

Regressionskoeffizient:

$$b = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

Restvarianz:

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n (y_i - Y_i)^2}{n - 2}$$

Berechnete Statistiken:

Mittelwerte:

$$\bar{x} = \frac{\sum x_i}{n} = \frac{3460}{20} = 173 \text{ cm}$$

$$\bar{y} = \frac{\sum y_i}{n} = \frac{1359}{20} = 67,95 \text{ kg}$$

Streuungen:

$$S_x = \frac{442}{20 - 1} = 4,82 \text{ cm}$$

$$S_y = \frac{1036,95}{20 - 1} = 7,39 \text{ kg}$$

Zunächst weitere Hilfsgrößen berechnen...



## 6 Lineare Regression

Die Urliste und die berechneten Hilfsgrößen tabellarisch dargestellt:

i	Größe		Hilfsgrößen						
	$x_i$	$y_i$	$x_i - \bar{x}$	$(x_i - \bar{x})^2$	$y_i - \bar{y}$	$(y_i - \bar{y})^2$	$(x_i - \bar{x})(y_i - \bar{y})$	$Y_i$	$(y_i - Y_i)^2$
1	165	56	-8,00	64,00	-11,95	142,80	95,60	55,95	0,0025
2	176	75	3,00	9,00	7,05	49,70	21,15	72,45	6,5025
3	175	70	2,00	4,00	2,05	4,20	4,10	70,95	0,9025
4	168	61	-5,00	25,00	-6,95	48,30	34,75	60,45	0,3025
5	167	61	-6,00	36,00	-6,95	48,30	41,70	58,95	4,2025
6	172	63	-1,00	1,00	-4,95	24,50	4,95	66,45	11,9025
7	175	72	2,00	4,00	4,05	16,40	8,10	70,95	1,1025
8	180	80	7,00	49,00	12,05	145,20	84,35	78,45	2,4025
9	179	76	6,00	36,00	8,05	64,80	48,30	76,95	0,9025
10	173	68	0,00	0,00	0,05	0,00	0,00	67,95	0,0025
11	166	57	-7,00	49,00	-10,95	119,90	76,65	57,45	0,2025
12	178	76	5,00	25,00	8,05	64,80	40,25	75,45	0,3025
13	169	60	-4,00	16,00	-7,95	63,20	31,80	61,95	3,8025
14	169	64	-4,00	16,00	-3,95	15,60	15,80	61,95	4,2025
15	170	63	-3,00	9,00	-4,95	24,50	14,85	63,45	0,2025
16	176	71	3,00	9,00	3,05	9,30	9,15	72,45	2,1025
17	180	78	7,00	49,00	10,05	101,00	70,35	78,45	0,2025
18	169	62	-4,00	16,00	-5,95	35,40	23,80	61,95	0,0025
19	177	75	4,00	16,00	7,05	49,70	28,20	73,95	1,1025
20	176	71	3,00	9,00	3,05	9,30	9,15	72,45	2,1025
$\Sigma$	<b>3460</b>	<b>1359</b>	<b>0,00</b>	<b>442,00</b>	<b>0,00</b>	<b>1036,95</b>	<b>663,00</b>		<b>42,45</b>

Geschätzter Regressionskoeffizient  $b$ :

$$b = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{663}{442} = 1,5 \frac{\text{kg}}{\text{cm}}$$

Die Restvarianz  $\hat{\sigma}^2$  (ein Schätzwert für  $\sigma^2$ )

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n (y_i - Y_i)^2}{n - 2} = \frac{42,45 \text{ kg}^2}{20 - 2} = 2,36 \text{ kg}^2 \Rightarrow \hat{\sigma} = \sqrt{\hat{\sigma}^2} = 1,54 \text{ kg}$$

Bestimmung der Vertrauensgrenze für diese Schätzung des Steigungsmaßes  $b$ : (die geforderte statistische Sicherheit  $P\% = 1 - \alpha = 0,95$ )

$$\left[ b - \frac{\hat{\sigma} t_{n-2; 1-\alpha/2}}{\sqrt{n} S_x}; b + \frac{\hat{\sigma} t_{n-2; 1-\alpha/2}}{\sqrt{n} S_x} \right]$$

In unserem Beispiel:

$$\left[ 1,5 - \frac{1,54 \cdot t_{18; 0,975}}{\sqrt{20} \cdot 4,82}; 1,5 + \frac{1,54 \cdot t_{18; 0,975}}{\sqrt{20} \cdot 4,82} \right]$$

## 6 Lineare Regression

Aus Tabellen:  $t_{18;0,975} = 2,10$

$$\left[ (1,5 - 0,15) \frac{\text{kg}}{\text{cm}}; (1,5 + 0,15) \frac{\text{kg}}{\text{cm}} \right]$$

Der Erwartungswert  $\beta$  für den Regressionskoeffizienten  $b$  liegt also mit der statistischen Sicherheit  $P\% = 0,95$  in diesem Intervall.

b)


$$Y^* = b(x^* - \bar{x}) + \bar{y}$$

Der Vertrauensbereich für  $Y^*$  zur statischen Sicherheit  $P\% = 1 - \alpha$ :

$$\left[ Y^* - \frac{\hat{\sigma} t_{n-2;1-\alpha/2}}{\sqrt{n}} \sqrt{1 + \frac{(x^* - \bar{x})^2}{S_x^2}}; Y^* + \frac{\hat{\sigma} t_{n-2;1-\alpha/2}}{\sqrt{n}} \sqrt{1 + \frac{(x^* - \bar{x})^2}{S_x^2}} \right]$$

In unserem Beispiel:  $P\% = 0,95$      $t_{18;0,975} = 2,1$      $x_1^* = 170,00 \text{ cm}$      $Y_1^* = 63,45 \text{ kg}$  Vertrauensbereich:  $[(63,45 - 0,85) \text{ kg}; (63,45 + 0,85) \text{ kg}]$

$x_2^* = 172,00 \text{ cm}$      $Y_2^* = 66,45 \text{ kg}$  Vertrauensbereich:  $[(66,45 - 0,74) \text{ kg}; (66,45 + 0,74) \text{ kg}]$



**Bild 1:** Vertrauensbereiche

## 7 Aufgabenvarianten zur statistischen Sicherheit

### Aufgabenvarianten zur statistischen Sicherheit

**Gegeben:**  $\mu, \sigma$  (Erwartungswert und Standardabweichung)

**Mit welcher Wahrscheinlichkeit liegt ein nächster Messwert in einem Intervall  $[a; b]$ ?**

$$\Phi(z(b)) - \Phi(z(a)) \text{ mit } z = \frac{x - \mu}{\sigma} \quad (\text{z.B. } z = \frac{a - \mu}{\sigma})$$

**Mit welcher Wahrscheinlichkeit ist ein nächster Messwert größer als  $a$ ?**  $1 - \Phi(a)$

**In welchem Intervall  $[\mu \pm c]$  liegt ein nächster Messwert mit stat. Sicherheit  $p = 1 - \alpha$ ?**

$c = k \cdot \sigma$   $k$  ist abhängig von  $p$  (Tab. 2.2),  $c$  entspricht dem  $x - \mu \Rightarrow k = z$

### Aufgabenvarianten zur statistischen Sicherheit

**Gegeben:**  $x, \sigma$  (ein Messwert und Standardabweichung)

**In welchem Intervall  $[x \pm c]$  liegt  $\mu$  mit stat. Sicherheit  $p = 1 - \alpha$ ?**

$c = k \cdot \sigma$   $k$  ist abhängig von  $p$  (Tab. 2.2),  $c$  entspricht dem  $x - \mu \Rightarrow k = z$

### Aufgabenvarianten zur statistischen Sicherheit

**Gegeben:**  $x_1 \dots x_n \rightarrow \bar{x}, \sigma$  (Mittelwert aus Stichprobe mit  $n$  Elementen und Standardabweichung)

**In welchem Intervall  $[\bar{x} \pm c]$  liegt  $\mu$  mit stat. Sicherheit  $p = 1 - \alpha$ ?**  $c = k \cdot \sigma_{\bar{x}} = k \cdot \frac{\sigma}{\sqrt{n}}$   $k$

ist abhängig von  $p$  (Tab. 2.2)

**Wie viele Messungen sind notwendig, damit das Vertrauensintervall  $c < c_k$  ist ( $p = 0,95$ )?**

$$c = 1,96 \cdot \frac{\sigma}{\sqrt{n}} < c_k \quad \rightarrow \quad n > \left( \frac{1,96 \cdot \sigma}{c_k} \right)^2$$

**Wie viele Messungen sind notwendig, damit  $\mu$  mit einer statistischen Sicherheit von**

**mindestens  $p = 0,95$  im Intervall  $[\bar{x} \pm c]$  liegt?**  $c = k \cdot \frac{\sigma}{\sqrt{n}} \quad \rightarrow \quad n > \left( \frac{1,96 \cdot \sigma}{c} \right)^2$

### Aufgabenvarianten zur statistischen Sicherheit

**Gegeben:**  $x_1 \dots x_n \rightarrow \bar{x}, S$  (Mittelwert und Streuung aus Stichprobe mit  $n$  Elementen)

**In welchem Intervall  $[\bar{x} \pm c]$  liegt  $\mu$  mit stat. Sicherheit  $p = 1 - \alpha$ ?  $c = \frac{t_{n-1; \frac{\alpha}{2}} \cdot S}{\sqrt{n}}$   $t$  ist abhängig von  $p$  (bzw.  $\alpha$ ) und  $n$  **Warum  $\frac{\alpha}{2}$ ?** Aus Symmetrie folgt Wahrscheinlichkeit  $p$ , dass ein Wert im Intervall  $\mu \pm c$  ist:**

$$z_c = \frac{c - \mu}{\sigma}$$

$$p = \Phi(z) - \Phi(-z) = 1 - \Phi(-z) - \Phi(-z) = 1 - 2\Phi(-z)$$

mit  $p = 1 - \alpha$  folgt:  $\alpha = 2\Phi(-z)$  und damit  $\Phi(-z) = \alpha/2$

$\Phi(-z)$  ist jetzt genau die Fläche an einer Seite außerhalb des Vertrauensbereiches  $\mu \pm z$ .