

Ein wenig Statistik

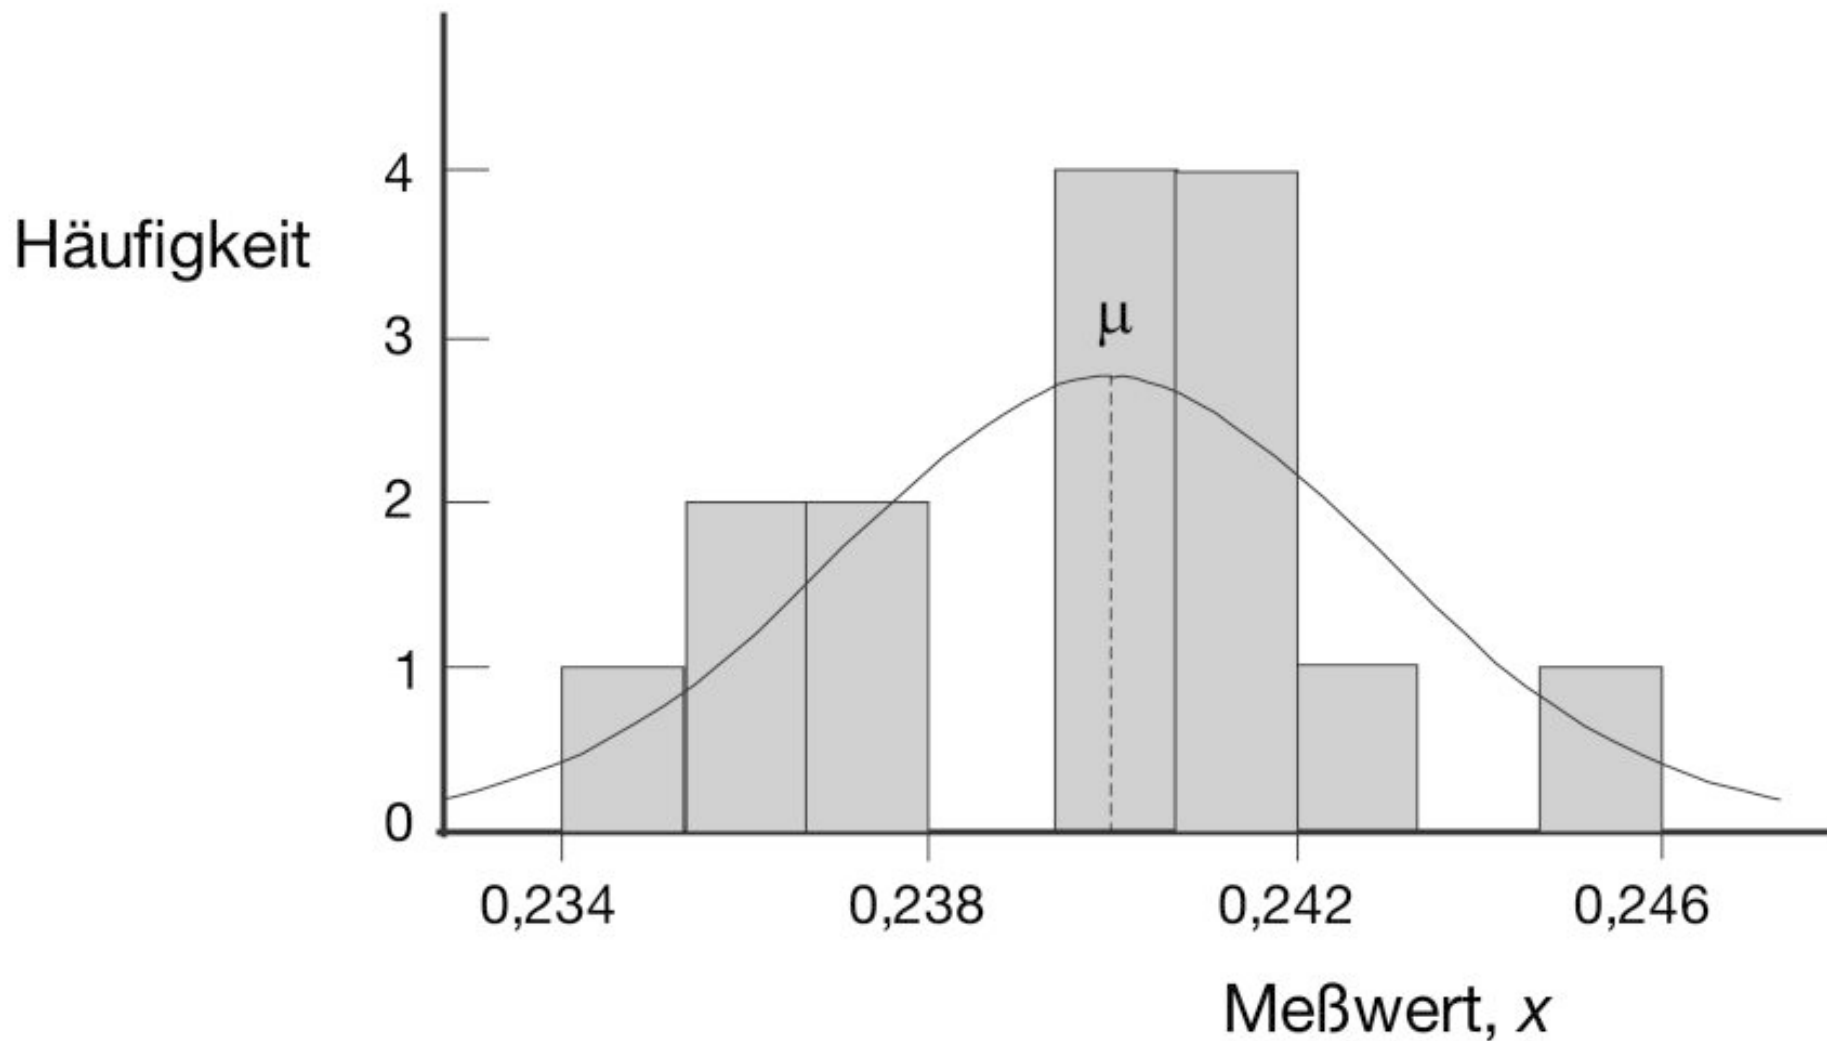
Messwertverteilung

- Misst man eine Probe mehrfach, so erhält man - in Abhängigkeit des Präzision des Verfahrens - verschiedene Messwerte.
- Die Aufgabe des Analytikers ist, aus **dieser begrenzten Zahl von Messungen** einen verlässlichen Wert abzuleiten.

Messung	Messwert	Messung	Messwert
1	0,235	9	0,241
2	0,24	10	0,2419
3	0,2379	11	0,241
4	0,24	12	0,243
5	0,236	13	0,2418
6	0,237	14	0,236
7	0.24	15	0,24
8	0,245		

Häufigkeitsverteilung


Messbereich	Häufigkeit	Messbereich	Häufigkeit
0,234 – 0,2353	1	0,2407 – 0,2420	4
0,2353 – 0,2367	2	0,2420 – 0,2433	1
0,2367 – 0,2380	2	0,2433 – 0,2447	0
0,2380 – 0,2393	0	0,2477 – 0,2460	1
0,2393 – 0,2407	4		



Normalverteilung

- Man findet, dass die Verteilung wiederholter Analysen die Form der Gauß – Verteilung annimmt.
- Idealerweise sind die Werte symmetrisch um den Mittelwert (häufigster Wert) angeordnet

Häufigkeit, $f(x)$



Normalverteilung

- Dieser Mittelwert entspricht dem Analysenwert und bei genügend großer Datenmenge auch dem „wahren“ Wert.

Gaußfunktion

- Für die Häufigkeit $f(x)$ des Auftretens eines Messwerts x bei ein und derselben Probe gilt:

$$f_g(x) = \frac{dn}{n} = \frac{1}{\sigma\sqrt{2\Pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx$$

$$f_r(x) = \frac{\Delta n}{n} = \frac{1}{s\sqrt{2\Pi}} e^{-\frac{(x-\bar{x})^2}{2s^2}} dx$$

Normalverteilung

- Messwerte können sehr eng um einen Mittelwert liegen oder weit verstreut.
- Zwei solcher Messreihen unterscheiden sich nur in der Größe der Standardabweichung.

Wahrscheinlichkeitsdichtefunktion

$f(x)$

0,5
0,4
0,3
0,2
0,1
0

$\mu - 2\sigma$

$\mu - \sigma$

μ

$\mu + \sigma$

$\mu + 2\sigma$

x


Wertebereich

$\sigma < 1$

$\sigma = 1$

$\sigma > 1$

Normalverteilungskurven



Stichprobe und Grundgesamtheit

- Statistisch sind die analytisch gewonnenen Daten eine *Stichprobe* einer (theoretisch) unbegrenzten Menge von Daten (Grundgesamtheit)
- Ist die Stichprobe repräsentativ, gelten die Gesetze der Statistik.

Stichprobe und Grundgesamtheit

- Konkret wird der **Mittelwert** der Stichprobe als **Analysenwert** angegeben
- Seine Güte ist abhängig von Probenzahl und Standardabweichung: bei hoher Standardabweichung kann der Mittelwert nur bei hoher Probenzahl genügend genau angegeben werden

Begrifflichkeiten

- In der Statistik werden die Größen der Population mit griechischen Buchstaben, die der realen Stichprobe mit lateinischen Buchstaben gekennzeichnet.

Mittelwert

- Population:

$$\mu = \lim(n \rightarrow \infty) \frac{\sum_{i=1}^n x_i}{n}$$

- Stichprobe

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$$

Standardabweichung

- Population:

$$\sigma = \sqrt{\lim_{(n \rightarrow \infty)} \frac{\sum_{i=1}^n (x_i - \mu)^2}{n}}$$

- Stichprobe

$$s = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}}$$

Gaußkurve

- **Das Kurvenmaximum μ ist das Mittel der Messwerte (Merkmalsverteilung)**
- Im Bereich $\mu \pm \sigma$ liegen 68% aller Werte
- Im Bereich $\mu \pm 2\sigma$ liegen 95% aller Werte
- Im Bereich $\mu \pm 3\sigma$ liegen 99,7% aller Werte

Gaußkurve

- **Mittelwert** und **Standardabweichung** einer Messreihe sind die Abschätzungen für den betrachteten Parameter (**Messgröße**) und den **Zufallsfehler**.

Normierte Gaußverteilung

- Wiederholte Messungen, die durch zufällige Fehler beeinflusst werden, gehorchen der Gauß-Statistik.
- Für den untersuchten Teil der Population dn/n im Werteintervall x bis $x+dx$ gilt

$$\frac{dn}{n} = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx$$

Normierte Gaußverteilung

- Die Abweichung $(x - \mu)$ der Messwerte x vom Mittelwert μ bezogen auf die Standardabweichung σ kann als neue Variable definiert werden:

$$z = (x - \mu) / \sigma$$

$$dz = dx / \sigma$$

Normierte Gaußverteilung

- Daraus ergibt sich eine von den individuellen Mittelwerten und Standardabweichungen unabhängige normierte Funktion.

$$\frac{dn}{n} = \frac{1}{\sqrt{2\pi}} e^{-z^2/2} dz$$

Fehlerverteilung

- Die Funktion erlaubt Aussagen über den Gesamtzufallsfehler – vorausgesetzt, die *Standardabweichung = Fehlergröße*, ist bekannt.
- Da jede Abweichung vom *Mittelwert = wahrer Wert*, ein Fehler ist, gilt:

Fehlerverteilung

- 68% der Messungen haben einen Fehler kleiner $\pm\sigma$
- 95% der Messungen haben einen Fehler kleiner $\pm 2\sigma$
- 99,7% der Messungen haben einen Fehler kleiner $\pm 3\sigma$

Standardfehler des Mittelwerts

- Dies gilt für die Fehlerwahrscheinlichkeit einer Messung
- Wird eine Reihe von Stichproben (Messreihen) mit je n Werten (Einzelmessungen) vorgenommen, nimmt die Streuung jedes μ mit zunehmendem n ab.

Standardfehler des Mittelwerts

- Werden aus einer Grundgesamtheit (Probenmatrix) mehrere Stichproben (Messreihen) mit je n Werten (Messungen) unternommen, so ergeben sich für die einzelnen Messreihen unterschiedliche Mittelwerte und Standardabweichungen.


Standardfehler des Mittelwerts

- Für die Standardabweichung des Mittelwerts der Mittelwerte = **Standardfehler des Mittelwerts** s_m läßt sich zeigen, dass er mit der Wurzel der Datenmenge abnimmt

$$s_m = s / \sqrt{n}$$

Fehlerverteilung

- Ab $n = 20$ stellt s eine gute Näherung für σ dar



Geeinte Standardabweichung

- Hohe Zahlen von Einzelmessungen lassen sich nicht immer verifizieren.
- Für eine Reihe von Stichproben (Messreihen) mit je n_i Messwerten lässt sich eine geeinte Schätzung der Standardabweichung geben

Geeinte Standardabweichung

- Für jede der N Messreihen mit je n_i Messungen wird die Quadratsumme der Abweichung vom Mittelwert gebildet.

$$\sum_N \sum_i (x_{i,N_i} - \bar{x}_{i,N_i})^2$$

Geeinte Standardabweichung

- Die Wurzel aus der Summe aller Quadratsummen dividiert durch die Differenz Messungen und Messreihen gibt das geeinte s

$$s_{\text{geeint}} = \sqrt{\frac{\sum_N \sum_i (x_{N_i} - \bar{x}_N)^2}{(\sum_{i;N} n_i) - N}}$$

Fallbeispiel

Baum	Proben	Linolsäure- Gehalte (%)
1	3	10,6; 12,4;10,2
2	4	8,6; 9,1; 7,9; 10,0
3	5	8,1; 7,5; 6,9; 7,9; 8,6
4	6	11,3;11,6; 10,4; 9,6; 8,9; 10,0

Fallbeispiel

\bar{x}	$(x_i - \bar{x})$	$(x_i - \bar{x})^2$	$\sum_i (x_i - \bar{x})^2$
11,07	0,47; 1,33; 0,87	0,22; 1,77; 0,77	2,76
8,9	0,3; 0,2; 1,0; 1,1	0,09; 0,04; 1,0; 1,21	2,34
7,8	0,3; 0,3; 0,9; 0,1; 0,8	0,09; 0,09; 0,81; 0,01; 0,64	1,64
10,3	1,0; 1,3; 0,1; 0,7; 1,4; 0,3	1,0; 1,69; 0,01; 0,49; 1,96; 0,09	5,24

Fallbeispiel

- Die Summe der Quadratsummen

$$\sum_N \sum_i (x_{N_i} - \bar{x}_N)^2 = 11,98$$


$$s_{\text{geeint}} = \sqrt{\frac{\sum_N \sum_i (x_{N_i} - \bar{x}_N)^2}{(\sum_{i;N} n_i) - N}} = (11,98 / 18-4)^{1/2}$$

$$s_{\text{geeint}} = \sqrt{0,8557} = \mathbf{0.925}$$

Vertrauensgrenzen

- Vertrauensgrenzen definieren Bereiche, innerhalb derer ein Analysenwert (= wahrer Mittelwert) mit gegebener Wahrscheinlichkeit erwartet werden kann.
- Sie hängen davon ab, wie sicher s bestimmt werden kann.
- **Je näher s an σ liegt**, um so enger können die Grenzen gezogen werden

Vertrauensniveau



Vertrauensgrenzen

- An der Gauß-Verteilung ist ersichtlich, dass z. B. mit 80%iger Sicherheit erwarten werden kann, dass ein Messwert innerhalb von $\pm 1,29\sigma$ liegt.
- Für den *Vertrauensbereich* $\pm z\sigma = \pm 1,29\sigma$ ist das *Vertrauensniveau* 80%

Vertrauensgrenzen

- Ist **s** als gute **Näherung von σ** bekannt, sind die CL (confidence limit) leicht berechenbar.
- **CL für eine Einzelmessung: $\mu = x \pm z s$ (σ)**
 - Wahrer Wert = Messwert \pm Vertrauensbereich

Vertrauensgrenzen

- Es läßt sich zeigen, daß der Vertrauensbereich um \sqrt{n} bei n Messungen enger wird
- Für eine Messreihe gilt entsprechend mit $s = s/\sqrt{n}$

$$\mu = \bar{x} \pm \frac{zS}{\sqrt{n}}$$

Vertrauensgrenzen

- Die Vertrauensniveaus für verschiedene z sind tabelliert:

%	z	%	z
50	0,67	96	2,00
68	1,00	99	2,58
80	1,29	99,7	3,00
90	1,64	99,9	3,29
95	1,96		

Fallbeispiel

- Vertrauensgrenzen 50% und 95% für Messung 3 [$\bar{x} = 7,8$; $n = 5$; $s = 0,925$] der Linolsäure-Bestimmung:
- $\mu_{50\%CL} = 7,8 \pm 0,67 \times 0,925 / \sqrt{5} = 7,8 \pm 0,28$
- $\mu_{95\%CL} = 7,8 \pm 1,96 \times 0,925 / \sqrt{5} = 7,8 \pm 0,81$

Fallbeispiel

- Wie viele Wiederholungsmessungen sind nötig, um den 95% Vertrauensbereich auf $\pm 0,25$ zu verringern:
- $\pm 0,25 = \pm 1,96 \times 0,925 / \sqrt{n}$
- $\sqrt{n} = \pm 1,96 \times 0,925 / 0,25 = 7,25$
 - **$n = 53$!!**

Vertrauensgrenzen

- Kann nur eine Folge von Wiederholungsmessungen durchgeführt werden, **ist s keine gute Schätzung von σ** und mit erheblichen Unsicherheiten behaftet.

Vertrauensgrenzen

- Der Unsicherheit kann statistisch Rechnung getragen werden; man verwendet den Parameter t .
 - $t = (x - \mu) / s$
- Man vergleiche mit der Definition von z !
- Notwendigerweise erweitern sich die Vertrauensgrenzen.

Vertrauensgrenzen

- Die t-Werte sind tabelliert (Bücher für Statistik) in Abhängigkeit der Freiheitsgrade, d.h. der unabhängigen Variablen der Messung
- Für unendlich viele unabhängige Variable wird $s = \sigma$ und $t = z$!

Vertrauensgrenzen

- Die Vertrauensgrenzen CL für einen Mittelwert aus N Wiederholungsmessungen ergeben

- sich
$$\mu = \bar{x} \pm \frac{ts}{\sqrt{n}}$$