



Verteilungen & Bestimmungen

Inhalt:

- Bernoulli und die zwei Möglichkeiten
- Von der Datenmenge zur Erkenntnis
- Doch ganz dicht! Kontinuierliche Verteilungen
- In vielen Dimensionen: Fehlerfortpflanzung, Korrelationen etc.



Bernoulli und die 2 Möglichkeiten

**Kopf oder Zahl?
Sein oder nicht sein?
Im Tor oder vorbei?**



Jacob Bernoulli
(1655 -1705)

Wenn 90 % der Strafstöße
verwandelt werden,
wie groß ist die
Wahrscheinlichkeit,
dass von 20 genau 17
drin sind?

Wenn ich n mal
mit der
Wahrscheinlichkeit p
teste,
wie groß ist dann die
Wahrscheinlichkeit,
genau k gute Ergebnisse
zu bekommen?



Bernoulli und die 2 Möglichkeiten



Ergebnisenge für 3 Würfe:

$$\omega = (000), (001), (010), (011), (100), (101), (110), (111)$$

Wahrscheinlichkeiten, sortiert:

$$0 \text{ Köpfe } P(000) = (1-p)^3$$

$$1 \text{ Kopf } P(001) = P(010) = P(100) = p \cdot (1-p)^2$$

$$2 \text{ Köpfe } P(110) = P(101) = P(011) = p^2 \cdot (1-p)$$

$$3 \text{ Köpfe } P(111) = p^3$$



Bernoulli und die 2 Möglichkeiten



Ergebnisenge für 3 Würfe:

$$\omega = (000), (001), (010), (011), (100), (101), (110), (111)$$

Wahrscheinlichkeiten, summiert:

$$0 \text{ Köpfe } P(k=0) = (1-p)^3$$

$$1 \text{ Kopf } P(k=1) = 3 \cdot p \cdot (1-p)^2$$

$$2 \text{ Köpfe } P(k=2) = 3 \cdot p^2 \cdot (1-p)$$

$$3 \text{ Köpfe } P(k=3) = p^3$$



Bernoulli und die 2 Möglichkeiten

Verallgemeinerung 3 → n

Jedes Elementarereignis mit k Köpfen hat die Wahrscheinlichkeit

$$P_i(k) = p^k \cdot (1-p)^{(n-k)}$$

Aber zu jeder Anzahl von k gibt es viele Elementarereignisse:

$$\binom{n}{k} = \frac{n \cdot (n-1) \cdot \dots \cdot (n-k+1)}{1 \cdot 2 \cdot \dots \cdot k}$$

$$\binom{n}{k} = \frac{n!}{k! \cdot (n-k)!}$$



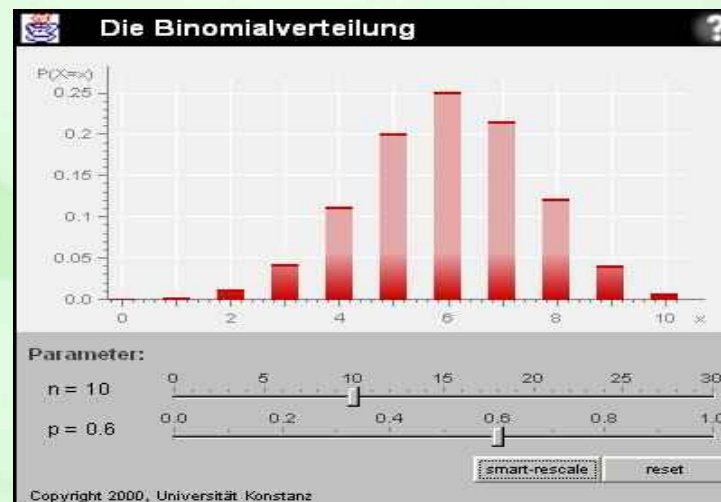


Bernoulli und die 2 Möglichkeiten

Binomialverteilung

Alle Elementarereignisse mit der gleichen Kopfzahl:

$$P(n, k) = \binom{n}{k} \cdot p^k (1-p)^{(n-k)}$$



(Applet der Uni Konstanz)



Bernoulli und die 2 Möglichkeiten

Binomialverteilung

Relevanz der allgemeinen Formel

$$P(n, k) = \binom{n}{k} \cdot p^k (1-p)^{(n-k)}$$



Zu jeder ja/nein Entscheidung
Verteilungsfunktion bekannt!

Mächtiges Werkzeug zur
Bestimmung und Eingrenzung von
Wahrscheinlichkeiten



Bernoulli und die 2 Möglichkeiten

Derivate der Binomialverteilung

Original **Binomialverteilung**:

Wahrscheinlichkeit für k bei
gegebenem n

$$P_{original}(n, k) = \binom{n}{k} \cdot p^k (1-p)^{(n-k)}$$

negative Binomialverteilung

Wahrscheinlichkeit für n bei
gegebenem k

$$P_{negativ}(n, k) = \binom{n-1}{k-1} \cdot p^k (1-p)^{(n-k)}$$



Bernoulli und die 2 Möglichkeiten

Derivate der Binomialverteilung

„Wie groß ist die Wahrscheinlichkeit, 3 Hauptgewinne im Lotto mit genau 7 abgegebenen Scheinen zu bekommen?“

negative Binomialverteilung

Wahrscheinlichkeit für n bei gegebenem k

$$P_{\text{negativ}}(n, k) = \binom{n-1}{k-1} \cdot p^k (1-p)^{(n-k)}$$

Normierung (Summe über $n!$): $\sum_{n=1}^{\infty} P(n, k) \rightarrow 1$

Vorsicht: subtile Formulierungsunterschiede!... denn



Bernoulli und die 2 Möglichkeiten

Derivate der Binomialverteilung

„Wie groß ist die Wahrscheinlichkeit, mit 7 abgegebenen Scheinen genau 3 Hauptgewinne im Lotto zu bekommen?“

ergibt die **Original- Binomialverteilung**

Wahrscheinlichkeit für k bei gegebenem n

$$P_{\text{original}}(n, k) = \binom{n}{k} \cdot p^k (1-p)^{(n-k)}$$

Normierung (Summe über $k!$): $\sum_{k=0}^n P(n, k) \rightarrow 1$

Präzise Formulierungen durch nichts zu ersetzen!



Bernoulli und die 2 Möglichkeiten

Derivate der Binomialverteilung



Bitte formulieren Sie 3 Fragen so, dass ihre Beantwortung mit Hilfe der negativen Binomialverteilung berechnet werden kann.

Bitte formulieren Sie dann 3 Fragen, die mit der Original-Binomialverteilung beantwortbar sind.



Bernoulli und die 2 Möglichkeiten

Derivate der Binomialverteilung


Wie viele Versuche bis zum ersten günstigen Ereignis?

Exp. Nr.	1	2	3	...	k	k+1	k+2	...	n
Ergebnis	0	0	0	...	1	egal	egal	egal	egal

Geometrische Verteilung

Wahrscheinlichkeit, dass k das erste günstige Ereignis

$$P_{geo}(k = \text{Erstwert}) = (1 - p)^{(k-1)} \cdot p$$



(Applet der Uni Konstanz)



Bernoulli und die 2 Möglichkeiten


Derivate der Binomialverteilung

Spezialfall: Binomialverteilung für große n und sehr kleine p mit $\mu = n \cdot p$

Poisson (1837) „*Recherches sur la probabilité des jugements en matières criminelles et en matière civile*“

Poisson Verteilung

$$P(\mu, k) = \frac{\mu^k}{k!} e^{-\mu}$$



Siméon Denis Poisson

Welche
Bedeutung
hat μ ?

Was ist egal?



Bernoulli und die 2 Möglichkeiten

Zusammenfassung

„ $P(k)$ bei gegebenem n “ → Bernoulli
Speziell für n groß, p klein → Poisson

„ $P(n)$ bei gegebenem k “ → negativ Bernoulli

„ $P(k=\text{erstes günstiges})$ “ → geometrische




Daten → Erkenntnis



*Das musst
Du mir
erklären!*


***Parameter
bestimmen ist
auch nichts
anderes als
Hypothesen
testen!***





Daten → Erkenntnis

Nützliche Definitionen



Erwartungswert

$$\mu = E(x) = \sum_i p_i x_i$$

$$\mu_{\text{exp.}} = \frac{1}{n} \sum_{i=0}^n x_i$$

Varianz

$$V(x) = \sum_i p_i \cdot (x_i - \mu)^2$$

$$V_{\text{exp}} = \frac{1}{n-1} \sum_{i=0}^n (\mu - x_i)^2$$

Standard Abweichung

$$\sigma_x = \sqrt{V(x)}$$



Daten → Erkenntnis

Verschiebungssatz der Varianz

$$V(x) = \sum_i p_i \cdot (x_i - \mu)^2$$

$$V(x) = \sum_i p_i \cdot (x_i^2 - 2\mu x_i + \mu^2)$$

$$V(x) = \sum_i p_i \cdot x_i^2 - 2\mu \sum_i p_i \cdot x_i + \mu^2 \sum_i p_i$$

$$V(x) = E(x^2) - 2\mu \cdot E(x) + \mu^2$$

$$V(x) = E(x^2) - (E(x))^2$$

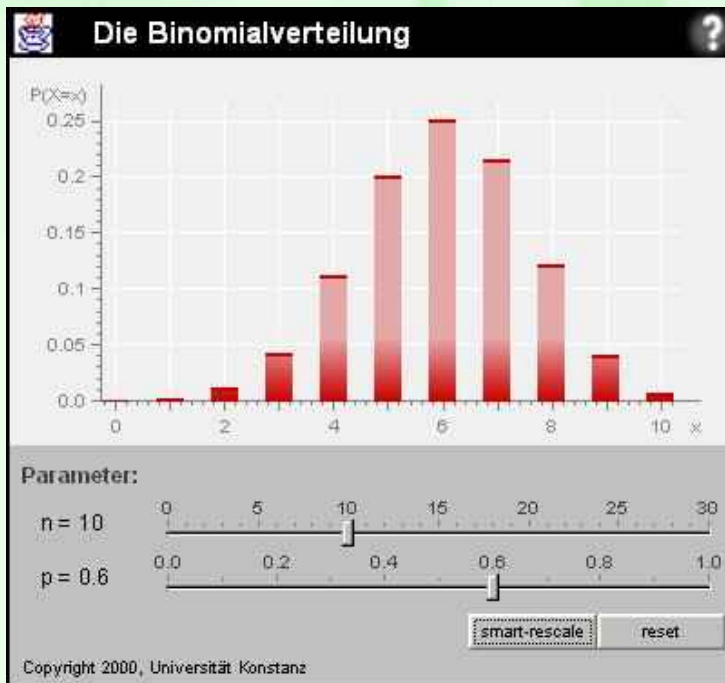
$$V(x) = E(x^2) - \mu^2$$

„Erwartungswert des Quadrates minus
Quadrat des Erwartungswertes“



Daten → Erkenntnis

Eigenschaften der Binomialfunktion:



(Applet der Uni Konstanz)

$$P(n, k) = \binom{n}{k} \cdot p^k \cdot (1-p)^{(n-k)}$$

$$E(k) = \mu = n \cdot p$$

$$V(k) = \sigma_k^2 = n \cdot p \cdot (1-p)$$

→

$$\frac{\sigma_k}{\mu} = \frac{\sqrt{n \cdot p \cdot (1-p)}}{np} = \sqrt{\frac{1-p}{p}} \cdot \sqrt{\frac{1}{n}}$$


Relative Streubreite sinkt mit der Wurzel der Testanzahl!



Daten → Erkenntnis

Eigenschaften der Binomialfunktion: Das Wurzelgesetz

$$P(n, k) = \binom{n}{k} \cdot p^k (1-p)^{(n-k)}$$




$$\frac{\sigma_k}{\mu} = \frac{\sqrt{n \cdot p \cdot (1-p)}}{np} = \sqrt{\frac{1-p}{p}} \cdot \sqrt{\frac{1}{n}}$$



Daten → Erkenntnis

Eigenschaften der Binomialfunktion: Experimentelle Bestimmung von p



Wenn $p = 0,3$ Wenn $p = 0,75$
 $P(k > 9) \approx 0,05$ $P(k < 11) \approx 0,02$

Was bedeutet $k_{exp} = 10$

Bei $n = 20$?

95% Wahrscheinlichkeit: $p < 0,3$ ausgeschlossen

98% Wahrscheinlichkeit: $P > 0,75$ ausgeschlossen.


→

93% Wahrscheinlichkeit:
 $0,3 < p < 0,75$



Daten → Erkenntnis

Eigenschaften der Binomialfunktion: Bestimmung des Vertrauensintervalls



Das „y% Vertrauensintervall“ gibt an mit welcher y%-igen Wahrscheinlichkeit p in diesem Intervall liegt.

Beispiel 90 %, numerisch lösen:

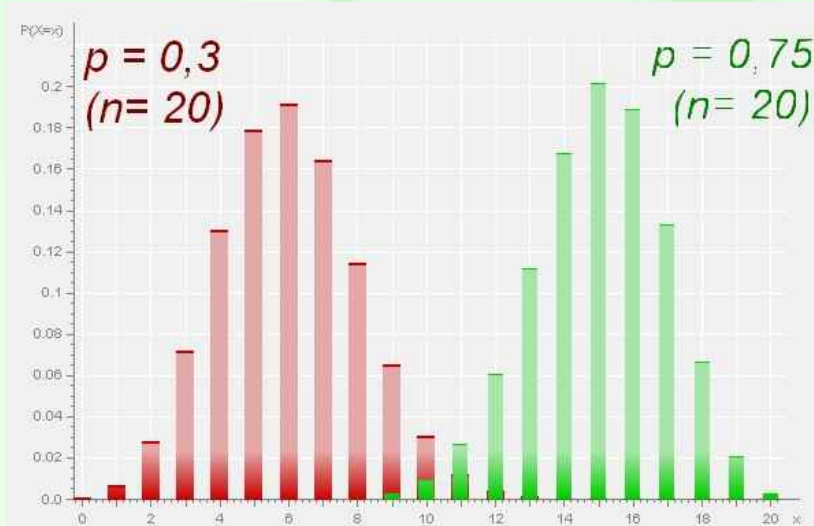
$$\sum_{k=0}^{k_{exp.}} P(n, k) = \binom{n}{k} \cdot p_{min}^k (1 - p_{min})^{(n-k)} > 0,95$$

$$\sum_{k=0}^{k_{exp.}} P(n, k) = \binom{n}{k} \cdot p_{max}^k (1 - p_{max})^{(n-k)} < 0,05$$



Daten → Erkenntnis

Verallgemeinerung des Verfahrens zur Bestimmung des Vertrauensintervalls



Wenn die Verteilungsfunktion $p(x)$ für eine Messgröße x bekannt ist, dann ist die Wahrscheinlichkeit y , dass der Erwartungswert im Bereich $[x_{min}, x_{max}]$ liegt

$$\sum_{x_i=-\infty}^{x_{exp.}} P(x_i, x_{min}) > 1 - y/2$$


$$\sum_{x_i=-\infty}^{x_{exp.}} P(x_i, x_{max}) < y/2$$



Daten → Erkenntnis



Education mission accomplished!



Die Grenzen des Vertrauensintervalls markieren die Punkte, jenseits derer die Theorien mit dem Experiment unverträglich werden



Daten → Erkenntnis

Spezialfall Poisson-Verteilung:
Experimentelle Bestimmung von μ
 Bestimmung des 90% Vertrauensintervalls
 für $k_{exp} = 3$:

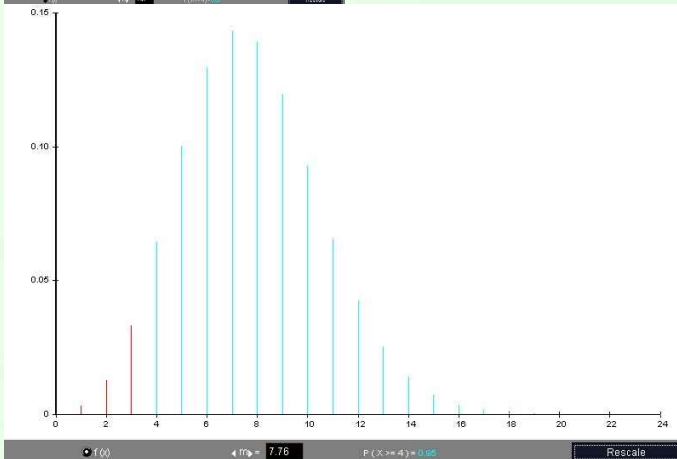

$$P(\mu = 1,37, k > 3) = 0,05$$

$$P(\mu = 7,76, k > 3) = 0,95$$

Mit 90%
 Wahrscheinlichkeit gilt

$$\mu = 3^{+4,76}_{-1,63}$$

(PS: meist wird nur das
 68% Intervall angegeben)




(www.stat.wvu.edu/SRS/Modules/Poisson/poisson.html)



Kontinuierliche Verteilungen

πάντα ῥεῖ,
„alles fließt“)



Heraklit

diskret

$$P(n, k)$$

$$\sum_{i=1}^n p_i = 1$$

$$\mu = \sum_{i=1}^n p_i \cdot x_i$$

$$V = \sum_{i=1}^n p_i \cdot (x_i - \mu)^2$$

kontinuierlich

$$p(x) = \frac{1}{n} \cdot \frac{dn}{dx}$$

$$\int p(x) dx = 1$$

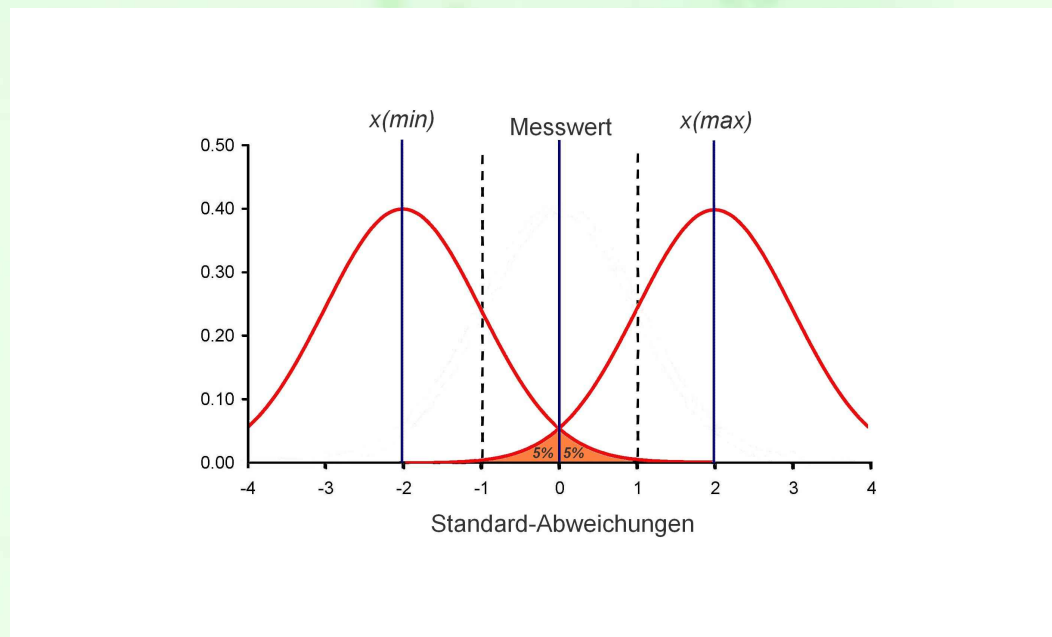
$$\mu = \int p(x) \cdot x dx$$

$$V = \int p(x) \cdot (x - \mu)^2 dx$$



Kontinuierliche Verteilungen

Bestimmung von Vertrauensintervallen



$$\int_{x_i=-\infty}^{x_{exp.}} p(x, x_{max}) dx < y/2$$

$$\int_{x_i=-\infty}^{x_{exp.}} p(x, x_{min}) dx > 1 - y/2$$

Der Messwert liegt


mit 95% Wahrscheinlichkeit oberhalb $x(\min)$

Mit 90% Wahrscheinlichkeit zwischen $x(\min)$ und $x(\max)$



Kontinuierliche Verteilungen

Die Gleichverteilung



$$p(x) = \text{konst.} = \frac{1}{x_o - x_u}$$

$$\mu = (x_o + x_u) / 2$$

$$V = (x_o - x_u)^2 / 12$$

Beispiele:

Zufallszahl zwischen 0 & 1


Spannungen zwischen den LSB Grenzen (ADC)

...



Kontinuierliche Verteilungen

Die Gauß – oder Normalverteilung



$$p(x) = \frac{1}{\sqrt{2\pi\sigma_x^2}} e^{-\frac{(x-\mu)^2}{2\sigma_x^2}}$$

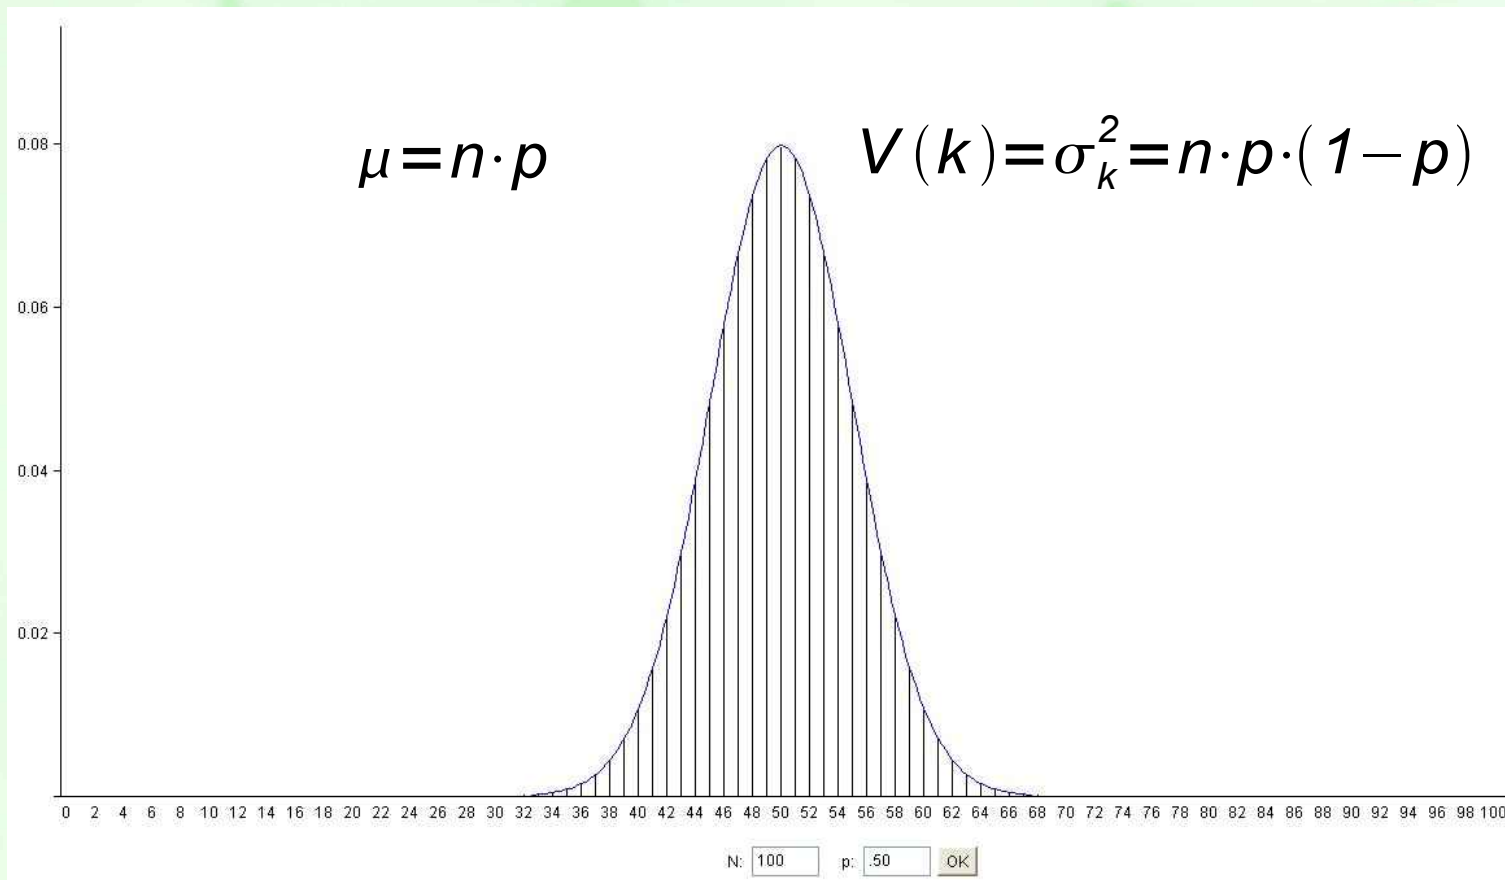
„Central Limit Theorem“:
„alles wird Gauß“
 (← viele Variable,
 $p(x_i)$ egal)





Kontinuierliche Verteilungen


Gauß und Bernulli:
„man trifft sich“





Kontinuierliche Verteilungen

Gauß: Bestimmung von Vertrauensintervallen



$$p_{\text{standard}}(z) = \frac{1}{\sqrt{2\pi}} e^{-z^2/2}$$

$$z := (x - \mu) / \sigma \rightarrow dz = \frac{1}{\sigma} dx$$

$$\Phi(z) = \int_{-\infty}^z p_{\text{standard}}(t) dt = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-t^2/2} dt$$

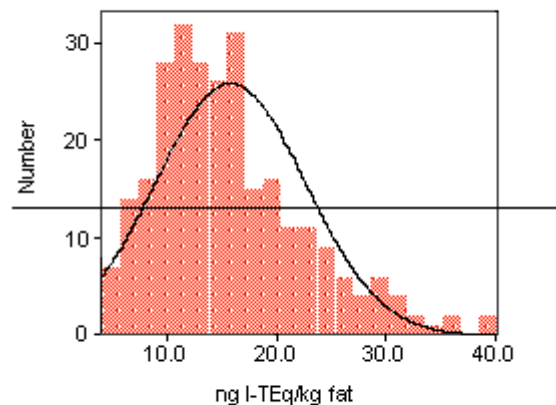
$$\int_{-\infty}^x p(t) dt = \Phi\left(\frac{x - \mu}{\sigma}\right)$$

(Grafik aus Wikipedia)



Kontinuierliche Verteilungen

Gauß: Bestimmung von Parametern (1)




(aus einer Studie der WHO)

$$\sigma_x \approx \sigma_{(exp.)} = \sqrt{\frac{(x - \bar{x})^2}{n-1}}$$

$$\sigma_\mu = \frac{\sigma_x}{\sqrt{n}} \approx \sqrt{\frac{(x - \bar{x})^2}{n \cdot (n-1)}}$$

Für σ_μ gilt das Wurzelgesetz!

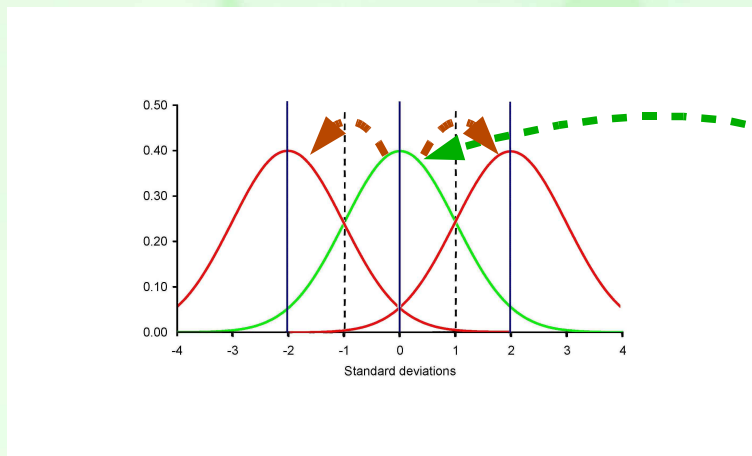


...aber nur, wenn es passt...



Kontinuierliche Verteilungen

Gauß: Bestimmung von Parametern (2)



$$\sigma_x \approx \sigma_{(exp.)} = \sqrt{\frac{(x - \bar{x})^2}{n-1}}$$

$$\sigma_\mu = \frac{\sigma_x}{\sqrt{n}} \approx \sqrt{\frac{(x - \bar{x})^2}{n \cdot (n-1)}}$$

Voraussetzungen: Verteilungsfunktion symmetrisch
 Verteilungsfunktionen für Werte neben μ
 genau so breit wie um μ herum


eigentlich eine Hypothesentest – aber man merkt es nicht...



Mehr Dimensionen!

Das Grundproblem: Korrelationen

positiv



negativ

stark

schwach

(aus G. Cowan, Lecturs on Statistical Data Analysis).



Mehr Dimensionen!

Erweiterung der Begriffe

Varianz

→ **Kovarianz**

$$V(x) = E((x - \mu)^2) \quad \text{cov}(x, y) = E((x - \mu_x) \cdot (y - \mu_y))$$

Korrelationskoeffizient $\rho_{xy} = \frac{\text{cov}(x, y)}{\sigma_x \cdot \sigma_y}$

$$x_i = a \cdot y_i \rightarrow \rho_{xy} = 1$$

$$x_i = -a \cdot y_i \rightarrow \rho_{xy} = -1$$

$$x_i \text{ unabhängig von } y_i \rightarrow \rho_{xy} = 0$$

Gilt der Umkehrschluss auch?



Mehr Dimensionen!

Fehlerfortpflanzung(1)

Wie kommt man vom Fehler der Messgrößen zur Fehler der Zielgröße?

Gegeben: $y(x_i)$ $V_{i,j}(x_i, x_j) = \text{cov}(x_i, x_j)$

Gesucht: $V(y(x_j))$

...analytisch praktisch nicht zu schaffen!

→ **Potenzreihen um die Erwartungswerte:**

$$y(x_i) \approx y(\mu_i) + \sum_{i=1}^n \left[\frac{\partial y}{\partial x_i} \right]_{x_i=\mu_i} \cdot (x_i - \mu_i)$$



Mehr Dimensionen!

Fehlerfortpflanzung(2)

→ Potenzreihen um die Erwartungswerte:

$$y(x_i) \approx y(\mu_i) + \sum_{i=1}^n \left[\frac{\partial y}{\partial x_i} \right]_{x_i=\mu_i} \cdot (x_i - \mu_i)$$

und Verschiebungsgesetz

$$V(y) = E(y^2) - (E(y))^2 \approx E(y^2) - (E(\mu))^2$$

Potenzreihen in das Verschiebungsgesetz → ...

→

$$\sigma_y^2 = \sum_{i,k=1}^n \left[\frac{\partial y}{\partial x_i} \frac{\partial y}{\partial x_k} \right]_{x_i=\mu_i} \cdot V_{i,k}$$

Fehlerfortpflanzungsgesetz in n Dimensionen



Mehr Dimensionen!

Fehlerfortpflanzung(3)

Vektor-wertige Funktionen

Gegeben: $y_r(x_i)$ $V_{i,j}(x_i, x_j) = \text{COV}(x_i, x_j)$

Gesucht: $V_{r,s}(y(x_j))$

$$\rightarrow V_{r,s}(y_r, y_s) = \sum_{i,k=1}^n \left[\frac{\partial y_r}{\partial x_i} \frac{\partial y_s}{\partial x_k} \right]_{x_i=\mu_i} \cdot V_{i,k}$$

oder, eleganter:

$$V(\vec{y}) = A \cdot V(\vec{x}) \cdot A^T, \quad A_{i,k} = \left[\frac{\partial y_i}{\partial x_k} \right]_{x_i=\mu_i}$$



Mehr Dimensionen!

Spezialfälle (1)

Differenz zweier Messwerte

$$y = x_1 - x_2 \rightarrow \sigma_y^2 = \sigma_{x_1}^2 - 2 \operatorname{cov}(x_1, x_2) + \sigma_{x_2}^2$$

- unkorreliert $\rho_{x_1 x_2} = 0 \rightarrow \sigma_y^2 = 2 \cdot \sigma_x^2$
- antikorreliert $\rho_{x_1 x_2} = -1 \rightarrow \sigma_y^2 = 4 \cdot \sigma_x^2$
- 100% korreliert $\rho_{x_1 x_2} = 1 \rightarrow \sigma_y^2 = 0 (!!!)$

Folgen der Korrelationen bisweilen dramatisch



Mehr Dimensionen!

Spezialfälle (2)

Produkt zweier Messwerte

$$y = x_1 \cdot x_2 \rightarrow \left(\frac{\sigma_y}{\mu_y} \right)^2 = \left(\frac{\sigma_{x1}}{\mu_1} \right)^2 + 2 \left(\frac{\text{COV}(x_1, x_2)}{\mu_1 \mu_2} \right) + \left(\frac{\sigma_{x2}}{\mu_2} \right)^2$$

→ unkorreliert für n Multiplikatoren:

$$y = x_1 \cdot x_2 \cdot \dots \cdot x_n \rightarrow \left(\frac{\sigma_y}{\mu_y} \right)^2 = \sum_{i=1}^n \left(\frac{\sigma_{x_i}}{\mu_i} \right)^2$$

„Die Summe der quadrierten relativen Fehler“



Mehr Dimensionen!

Zusammenfassung

Korrelationen im Allgemeinen wichtig

→ Immer die gesamte Kovarianzmatrix benutzen

Brauche lineare Näherungen

→ funktioniert nur bei kleinen relativen Fehlern

Verfahren beinhaltet viele Parameter

(n Ableitungen, n Mittelwerte, n^2 Matrixelemente)

→ deutlich mehr als $n^2 + 2n$ Messwerte benutzen!



Mehr Freizeit!



*Jetzt wäre
ein günstiger
Zeitpunkt zum
Aufwachen*