

Block 3:

Statistische Methoden der Datenanalyse

- Einführung
- Wahrscheinlichkeit
- diskrete und kontinuierliche Verteilungen

- Varianz und Kovarianzmatrix
- Variablentransformation
- Fehlerfortpflanzung

- Monte-Carlo-Methode

- Parameterschätzung

- Hypothesentests und Klassifikation

Statistische Methoden der Datenanalyse - Literatur

- V. Blobel, E. Lohrmann “Statistische und numerische Methoden der Datenanalyse”, Teubner, Stuttgart 1998
- G. Cowan “Statistical Data Analysis”, Clarendon, Oxford, 1998
- R.J. Barlow “Statistics”, Wiley 1989
- D.S. Sivia “Data Analysis” – A Bayesian Tutorial, Clarendon, Oxford 1996
- G. Bohm u. G. Zech, “Einführung in Statistik und Messdatenanalyse für Physiker”, DESY, Hamburg 2005, e-book
<http://www-library.desy.de/preparch/books/vstatmp.pdf>
- + viele mehr, z.B. S. Brandt, “Datenanalyse”, Springer (recht mathematisch)

Vorhersehbar


Einfache (klassische) physikalische Prozesse:

Ergebnis exakt vorhersagbar

- Ursache erzeugt eine eindeutige Wirkung,
- Determinismus

Beispiele hierfür sind:

- Pendel
- Planetenbahnen,
- Billard
- Elektromagnetismus...




Zufall

Rein zufällige Ereignisse sind prinzipiell nicht vorhersagbar
(auch bei genauer Kenntnis der Ausgangssituation!)

Beispiele hierfür sind:

- Lottozahlen (zu viele Einflussgrößen, deterministisches Chaos)
- radioaktiver Zerfall (Quantenmechanik)
- Elektronisches Rauschen
- Meßfehler und apparative Auflösung



Zufall in der Physik !?

Schon in der klassischen Physik:

- Einfluss unkontrollierbarer Größen (Ablesegenauigkeit, Fertigungsgenauigkeit von Messgeräten, „Rauschen“ usw.) wird als „Messfehler“ statistisch behandelt
- in Vielteilchensystemen: statistische Mechanik betrachtet Eigenschaften von Verteilungen statt (Energie, Impuls usw.) statt aller Koordinaten von Teilchen

In der Quantenphysik:

- Vorhergesagt werden Wahrscheinlichkeitsverteilungen von Observablen
→ nur statistische Aussagen
z.B. „mittlere Lebensdauer eines Zustands“ oder „Erwartungswert des Aufenthaltsortes“

Viele Systeme:

Mischung aus vorhersagbarer Komponente und Zufallskomponente.

→ Wahrscheinlichkeitsaussage, Statistik.

Ziel: Extraktion der vorhersagbaren Komponente

Überprüfung von physikalischen Modellen

Physik beschreibt die Wirklichkeit mit (theoretischen) Modellen

- Modellvorhersagen enthalten Näherungen und numerische Fehler
- Überprüfung der Modelle durch Experimente (=fehlerbehaftete Messungen)
- fast immer existier(t)en alternative Modelle

(das ist immer so an der vordersten Front der physikalischen Forschung)

**Vergleich von Theorie (=Modell) und Experiment
erfordert statistische Methoden**

z.B.: linearer Zusammenhang ? Wenn ja: Steigung bestimmen!

Wenn nein: Modell falsch, Steigung irrelevant!

(in unseren Praktika wird die erste Frage leider fast immer ausgeblendet)

**Ziel: 1. Hypothesentest: stimmt das Modell
2. Bestimmung von Modellparametern**

Zufall und statistische Methoden anderswo


- Medizin: Wirksamkeit von Therapien und Medikamenten
- Umfragen: Wähler-, Kunden-, Studentenbefragungen o.Ä.
- Qualitätssicherung in der Produktion
- Risikobewertung bei Versicherungen
- Angebotsplanung im Handel
- Glücksspiel
- Aktienmarkt und Kursentwicklung

sowie viele, viele andere Beispiele

Quantenmechanik:


jedes Mal passiert etwas anderes!

OPAL Experiment am LEP



e^+e^- - Kollisionen im Opal-Experiment am LEP-Collider

Experiment: Messe Häufigkeitsverteilungen



Fehlerbehaftete Messdaten und Parameter-abhängiges Modell

Zahl der beobachteten Ereignisse mit einer invarianten Masse in einem bestimmten Intervall ist ein Zufallsereignis

(Zufalls-)Ereignis im Sinne der Statistik:

durch spezifische Eigenschaften definiertes Ergebnis eines Prozesses

Beispiele:

- eine „3“ würfeln
- ein Tor fällt in den ersten fünf Minuten eines Fußballspiels
- beim Angeln einen Hecht fangen
- eine „2“ und dann eine „5“ würfeln
- eine Zahl größer als „3“ würfeln
- Messung eines Werts für e zwischen $1.60 \cdot 10^{-19}$ C und $1.61 \cdot 10^{-19}$ C

Kompatible Ereignisse:

- eine gewürfelte Zahl ist „ >3 “ **und** „5“ („ >3 “ \cap „5“)
- eine Karte aus einem Kartenspiel ist rot **und** ein As „rot“ („rot“ \cap „As“)
- eine Karte ist ein As **oder** eine Dame („As“ \cup „Dame“)
- Karte ist As oder kein As (gilt für beliebige, d.h. alle Karten!)

Exklusive Ereignisse:

- „3“ und gleichzeitig „5“ würfeln
- eine Karte ist ein As **und** eine Dame (gilt für keine Karte)

Wahrscheinlichkeit

Definition Wahrscheinlichkeit

Frequentist-Wahrscheinlichkeit = „objektive“ Definition

für beliebig wiederholbare Ereignisse oder bei
Vorhandensein von Symmetrien anwendbar

auch „Klassische Statistik“ genannt

Bayes-Wahrscheinlichkeit = „subjektive“ Definition

auch für einmalige Ereignisse anwendbar

Streit der Schulen zwischen **Frequentisten** und **Bayesianern** bis heute

Physiker nehmen meist einen pragmatischen Standpunkt ein –

Anwendung “hybrider” Verfahren

Frequentist-Definitionen von Wahrscheinlichkeit

Kombinatorische Definition:

Wenn ein Ereignis in n verschiedenen Arten auftreten kann, die alle gleiche Wahrscheinlichkeit haben, und wenn k Ereignisse davon die Eigenschaft A aufweisen, ist die Wahrscheinlichkeit für A : $P(A) = k/n$

Empirische Definition:

Eine Beobachtung ist unter identischen Bedingungen unabhängig voneinander n mal wiederholt.

Wenn Eigenschaft A dabei k mal beobachtet wird, ist das Verhältnis k/n die empirische Wahrscheinlichkeit. Die Wahrscheinlichkeit $P(A)$ wird definiert als der Grenzwert für unendlich viele Beobachtungen n .

Beide Definitionen können kritisiert werden:

Kombinatorisch: Schlange, die sich in den Schwanz beißt.

Empirisch: Grenzwert kann in der Praxis nie erreicht werden.

Formale Definition von Wahrscheinlichkeit: Kolmogorov-Axiome (1931)


Betrachte Elementarereignisse e_i

Elementary events e_i are considered, which *exclude* each other:

e_i = elementary event

Ω = set of all elementary events

$P(e_i)$ = probability of event e_i



1. $P(e_i) \geq 0$ for all i

2. $P(e_i \vee e_j) = P(e_i) + P(e_j)$ (\vee = or)

3. $\sum_{\Omega} P(e_i) = 1$

positiv

additiv


normiert

Kombination von Wahrscheinlichkeiten

$$P(\mathcal{A} \text{ or } \mathcal{B}) = P(\mathcal{A}) + P(\mathcal{B}) - P(\mathcal{A} \text{ and } \mathcal{B})$$
$$P(\mathcal{A} \text{ and } \mathcal{B}) = 0$$
$$P(\mathcal{A} \text{ or } \mathcal{B}) = P(\mathcal{A}) + P(\mathcal{B})$$
$$P(\mathcal{A} \text{ or } \bar{\mathcal{A}}) = P(\mathcal{A}) + P(\bar{\mathcal{A}}) = 1$$
$$P(\mathcal{A} \text{ and } \mathcal{B}) = P(\mathcal{A}) \cdot P(\mathcal{B}|\mathcal{A}) = P(\mathcal{B}) \cdot P(\mathcal{A}|\mathcal{B})$$
$$P(\mathcal{A} \text{ and } \mathcal{B}) = P(\mathcal{A}) \cdot P(\mathcal{B})$$

\mathcal{A} or \mathcal{B}
if \mathcal{A} and \mathcal{B} exclude each other
if \mathcal{A} and \mathcal{B} exclude each other
($\bar{\mathcal{A}}$ = not \mathcal{A})
 \mathcal{A} and \mathcal{B}
if \mathcal{A} and \mathcal{B} independent

Bedingte Wahrscheinlichkeit, dass
A wahr ist, wenn B wahr ist.



Bayes'sche Definition von Wahrscheinlichkeit

Wahrscheinlichkeit ist der Grad des Glaubens, dass ein Experiment ein bestimmtes Ergebnis haben wird.

- Subjektive Wahrscheinlichkeit -
(erfüllt Kolmogorov-Axiome !)

Reverend Thomas
Bayes (1702 – 1761)



Essay "Towards Solving a Problem in the Doctrine of Chances" (1763), posthum veröffentlicht in *Philosophical Transactions of the Royal Society of London*.

Frequenz-Aussagen oft nicht möglich.

Dann ist Bayes- Interpretation die einzig mögliche:

Wahrscheinlichkeit ist der Grad des Glaubens, dass eine Aussage zutrifft.

Beispiele für Bayes-Wahrscheinlichkeit:

- das Teilchen in diesem Ereignis ist ein Positron.
- die Natur ist supersymmetrisch.
- es wird morgen regnen.
- Deutschland wird 2014 Fußball-Weltmeister.
- es hat am 8. März 1792 in Kairo geregnet.

Oft kritisiert, weil „subjektiv“ und „unwissenschaftlich“.

Beruhet jedoch auf einfacher Wahrscheinlichkeitsrechnung und ist –
richtig angewendet – nicht im Widerspruch zu Frequentist-Ansatz.

Bayes' Theorem:

Bedingte (conditional) Wahrscheinlichkeiten:

$$P(B|A) = \frac{P(B \cap A)}{P(A)}$$

$$P(A|B) = \frac{P(A \cap B)}{P(B)}$$

Wegen $P(A \cap B) = P(B \cap A)$ gilt:

$$P(A|B) = \frac{P(B|A) P(A)}{P(B)}$$

Bayes Theorem

Statistik: Wahrscheinlichkeit, Bayes' Theorem (2)

Besonders wichtig durch die Interpretation

A: Richtigkeit einer Theorie

B: Wahrscheinlichkeit der Beobachtung bestimmter Daten

$$P(\textit{Theorie} | \textit{Daten}) = \frac{P(\textit{Daten} | \textit{Theorie}) P(\textit{Theorie})}{P(\textit{Daten})}$$

„Likelihood“

„Prior“

„Posterior“

„Evidenz“

$P(\textit{Theorie} | \textit{Daten})$ Wahrscheinlichkeit, dass die Theorie stimmt, wenn bestimmte Daten beobachtet wurden

$P(\textit{Daten} | \textit{Theorie})$ Wahrscheinlichkeit, bestimmte Daten zu beobachten, wenn die Theorie stimmt

Interessant ist die erste Frage, häufig wird jedoch nur die zweite beantwortet!

Bsp: AIDS-Test

Wahrscheinlichkeit in
allgemeiner Bevölkerung:

$$P(\text{AIDS}) = 0.001$$

$$P(\text{no AIDS}) = 0.999$$

a priori-Wissen

Ziemlich zuverlässiger AIDS-Test
(Resultat + oder -):

$$P(+|\text{AIDS}) = 0.98$$

$$P(-|\text{AIDS}) = 0.02$$

$$P(+|\text{no AIDS}) = 0.03$$

$$P(-|\text{no AIDS}) = 0.97$$

Messung,
Likelihoods

Wie besorgt sollte man sein, wenn man ein positives Testresultat hat?
d.h. wie groß ist (die posteriori-Wahrscheinlichkeit) $P(\text{AIDS}|+)$?

Bsp.: AIDS-Test (2)

$$\begin{aligned} P(\text{AIDS}|+) &= \frac{P(+|\text{AIDS}) P(\text{AIDS})}{P(+|\text{AIDS}) P(\text{AIDS}) + P(+|\text{no AIDS}) P(\text{no AIDS})} \\ &= \frac{0.98 \times 0.001}{0.98 \times 0.001 + 0.03 \times 0.999} \\ &= 0.032 \end{aligned}$$

Die Posterior-Wahrscheinlichkeit $P(\text{AIDS}|+)$ beträgt nur 3,2%!

Warum? Wegen der kleinen Prior-Wahrscheinlichkeit von 0.01% und der nicht vernachlässigbaren Mißidentifikationswahrscheinlichkeit!

Vorsicht: Prior nicht richtig, wenn man zu einer Risikogruppe gehört!

Statistik: Wahrscheinlichkeit, Bayes' Theorem (5)

Bayes'sche vs. klassische Statistik

Klassische Statistik (basierend auf Maximieren der Likelihood)
ist nur Sonderfall der Bayes-Statistik:

$$P(\text{Theorie}|\text{Daten}) = \frac{P(\text{Daten}|\text{Theorie})P(\text{Theorie})}{P(\text{Daten})}$$

„Likelihood“

„Prior“

„Posterior“

„Evidenz“

Maximieren der Likelihood **statt der a posteriori-Wahrscheinlichkeit** heisst:
Implizite Annahme, dass die Prior-Wahrscheinlichkeit flach verteilt ist, d.h.
jeder Wert ist gleich wahrscheinlich.

Hört sich vernünftig an, ist aber oft falsch!
Heisst nicht, dass man nichts weiss!

Nicht-informativer Prior

Wenn man über eine dimensionsbehaftete Größe x nichts (nicht einmal die Größenordnung) weiss, dann ist

$$f(x) = \text{const.} \quad \text{FALSCH!}$$

Vielmehr ist

$$f(\ln(x)) = \text{const.} \quad \text{RICHTIG!}$$

Das ist gleichbedeutend mit

$$f(x) \propto 1/x.$$

Bradford'sche Zahlengesetz: Die Ziffer 1 ist viel öfter die signifikanteste Ziffer einer Zahl als die 9. Wie auf logarithmischer Skala. Übrigens: Finanzamt weiss Bescheid: Steuererklärungen richtig fälschen!

Verteilungen von Zufallsgrößen:

Wahrscheinlichkeitsverteilungen

und

Wahrscheinlichkeitsdichten

Kumulative Verteilungen


Wahrscheinlichkeitsverteilung

Eine **diskrete** Zufallszahl k kann eine endliche oder unendliche Anzahl von Werten k_i mit $i=a, a+1, \dots, b$ annehmen. Die Wahrscheinlichkeit für den Wert k_i ist $P(k_i)$ und erfüllt die Normierungs-

bedingung

$$\sum_{\text{alle } i} P(k_i) = 1$$

Kumulierte Verteilungsfunktion
= Wahrscheinlichkeit, einen Wert k_i oder kleiner zu beobachten.




Wahrscheinlichkeitsdichte

Eine **kontinuierliche** Zufallsvariable kann reelle Werte annehmen. Die Wahrscheinlichkeit, dass x in das *Intervall* $a \leq x < b$ fällt, ist

$$P(a \leq x < b) = \int_a^b f(x) dx$$

dabei ist $f(x)$ die **Wahrscheinlichkeitsdichte** (*probability density function, pdf*) der Zufallsvariablen x ; die Dichte ist nicht-negativ und auf 1 normiert:

$$\begin{aligned} f(x) &\geq 0 \\ \int_{-\infty}^{\infty} f(x) dx &= 1 \end{aligned}$$



Verteilungsfunktion

Die **Verteilungsfunktion** (*(cumulative) distribution function, cdf*)


$F(x)$ ist die Wahrscheinlichkeit, einen kleineren Wert als x zu finden:

$$F(x) = \int_{-\infty}^x f(x') dx'$$

mit $F(-\infty)=0$ und $F(+\infty)=1$

Die Wahrscheinlichkeitsdichte ist also die Ableitung der Verteilungsfunktion:

$$f(x) = \frac{dF(x)}{dx}$$



Erwartungswert und Varianz

Der **Erwartungswert** einer Funktion $h(x)$ einer Zufallsvariablen mit der Wahrscheinlichkeitsdichte $f(x)$ bzw. Wahrscheinlichkeit $P(x_i)$ ist definiert durch:

$$E[h] = \int_{-\infty}^{\infty} h(x) f(x) dx$$

$$E[h] = \sum_{\text{alle } i} h(x_i) P(x_i)$$

Wichtige Spezialfälle: a) $h(x)=x$: **Erwartungswert (auch Mittelwert)**

$$\underline{E[x]} = \int_{-\infty}^{\infty} x f(x) dx = \underline{\langle x \rangle} = \bar{x}$$

$$E[x] = \sum_{\text{alle } i} x_i P(x_i) = \underline{\langle x \rangle} = \bar{x}$$

b) **Varianz**

$$V[x] = \int_{-\infty}^{\infty} (x - \langle x \rangle)^2 f(x) dx$$


$$V[x] = \sum_{\text{alle } i} (x_i - \langle x \rangle)^2 P(x_i)$$

Standardabweichung $\sigma = \sqrt{V}$

Zufallsgrößen: Beispiel Mittelwert und Varianz

Mittelwert: „Position“ der Verteilung

Standardabweichung: „Breite“ der Verteilung







Histogramme

Häufigkeitsverteilung:

Anzahl Ereignisse in
endlichen Intervallen
(*Bins*)

Wahrscheinlichkeitsdichte

- $f(x)$ = Histogramm mit
- unendlicher Statistik;
 - Bin-Breite 0,
 - normiert auf Fläche 1





Mittelwert („mean“): $\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$,

Standardabweichung („RMS“ in Root): $\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}$


Mehrdimensionale Zufallszahlen

Darstellung einer 2-dimensionalen Wahrscheinlichkeitsdichte $f(x,y)$ als Punktwolke (*scatter plot*)



Normierungsbedingung:

$$\int \int f(x, y) dx dy = 1$$




Randverteilungen
= Projektionen auf Achsen

$$f_x(x) = \int f(x, y) dy$$

$$f_y(y) = \int f(x, y) dx$$

Lässt sich leicht auf n Dimensionen erweitern;
in ROOT: Klassen TH1, TH2 und TH3

Mehrdimensionale Zufallszahlen (2)



Bedingte Wahrscheinlichkeitsdichte $h(y|x) = \frac{f(x, y)}{f_x(x)}$ Wahrscheinlichkeitsdichte für y falls x bekannt

Bedingte Wahrscheinlichkeit für Y unter der Bedingung das X bekannt ist:

$$P(y \leq Y < y + dy \mid x \leq X < x + dx) = h(y|x)dy$$

Grundlegende Verteilungen

Binomialverteilung (1)

Wahrscheinlichkeit für die Beobachtung eines bestimmten Ereignisses ist p .

Was ist die Wahrscheinlichkeit, bei n Versuchen k solcher Ereignisse zu beobachten ?

z.B. - bei 10 Versuchen 3 mal eine 6 würfeln.

- bei 100 Einträgen in einem Histogramm 10 Einträge im ersten Bin

Binomialverteilung

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

$\binom{n}{k} = \frac{n!}{k!(n-k)!}$ ist die Anzahl der Kombinationen, k aus N Elementen ohne Berücksichtigung der Reihenfolge auszuwählen („Binomialkoeffizient“)


Erwartungswert

$$E[k] = np$$

Varianz

$$V[k] = np(1 - p)$$

Binomialverteilung (2)



$$\mu = 0.6$$
$$\sigma = \sqrt{3 \cdot 0.2 \cdot 0.8}$$
$$\sigma \approx 0.7$$

$$\mu = 1.2$$
$$\sigma = \sqrt{6 \cdot 0.2 \cdot 0.8}$$
$$\sigma \approx 0.98$$

$$\mu = 1.8$$
$$\sigma = \sqrt{3 \cdot 0.6 \cdot 0.4}$$
$$\sigma \approx 0.85$$

$$\mu = 3.6$$
$$\sigma = \sqrt{6 \cdot 0.6 \cdot 0.4}$$
$$\sigma = 1.2$$

Poissonverteilung

Binomialverteilung $B(k;p,n)$ im Grenzfalle $n \rightarrow \infty$, $p \rightarrow 0$, $np = \mu$ fest:

→ Poisson-Verteilung $P(k; \mu) = \frac{\mu^k}{k!} e^{-\mu}$

Erwartungswert $E[k] = \mu$

Varianz $V[k] = \mu$


Grenzwert bedeutet: Gesamtzahl beobachteter Ereignisse k in $n \rightarrow \infty$ Intervallen Δx , in denen jeweils ein Ereignis mit der (sehr kleinen) konstanten Wahrscheinlichkeit p erwartet wird.

Beispiele für Poisson- verteilte Zahlen:


- *ein Klassiker:* Zahl der pro Jahr durch Huftritt getöteten preußischen Kavallerieoffiziere
- *näherungsweise:* Zahl der Einträge in einem Bin eines Histogramms mit vielen Bins
- Zahl der bei fester Ereignisrate im Zeitintervall T beobachteten Ereignisse,
übrigens: Zeitdifferenz Δt zwischen zwei Ereignissen

folgt einer Exponentialverteilung: $f(\Delta t; \tau) = \frac{1}{\tau} e^{-\Delta t/\tau}$


Poission($n;\mu$)



Poission($n;\mu$)



Poission($n;\mu$)



Poissonverteilung

Erwartungswert μ

Standardabweichung $\sqrt{\mu}$

„**Statistischer Fehler**“ auf eine Anzahl n von Beobachtungen ist

$$\sqrt{n}$$

(dabei wird $n \approx \mu$ angenommen)

(Gauß'sche) Normalverteilung

Die **Normalverteilung** (oder Gauß-Verteilung) ist die wichtigste kontinuierliche Verteilung

$$N(x; \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad x \in]-\infty, \infty[$$

Erwartungswert


$$V[x] = \sigma$$

Quantile der Gauß-Verteilung:


$$\begin{aligned} P(|x - \mu| < 1 \cdot \sigma) &= 68.26\% \\ P(|x - \mu| < 2 \cdot \sigma) &= 95.45\% \\ P(|x - \mu| < 3 \cdot \sigma) &= 99.73\% \end{aligned}$$

Für große n bzw. μ nähern sich Binomial- und Poisson-Verteilung der Gauß-Verteilung an.


Gauß- oder Normal-Verteilung



Gauß- oder Normal- Verteilung




Standard-Normalverteilung ($\mu=0$ und $\sigma=1$)




Gauß-verteilte Zufallszahlen in ROOT mit Hilfe der Klasse TRandom und Methode Double_t Gaus() über globalen Zeiger gRandom->Gaus()

Zusammenhang der Standardverteilungen




Vergleich: Binomial- und Poisson mit Gauß-Verteilung


$p=0.75, n=50$




$p=0.3, n=100$




$p=0.05, n=100$



$p=0.05, n=300$



$p=0.05, n=3000$



- gute Annäherung Poisson - Binomial-V. für $np > \sim 50$
- Asymmetrie von Binomial-V. bei kleinen p von Gauß-V. nicht gut beschrieben
- Problematisch: Ausläufer bei großen Werten $|n - \langle n \rangle|$

Statistik: Zentraler Grenzwertsatz oder: warum sind Messfehler gaußförmig?

Im Grenzfall von großen N ist die Summe von N unabhängigen Zufallszahlen eine Zufallszahl, die einer Gauß-Verteilung folgt.

$$x = \lim_{N \rightarrow \infty} \sum_{i=1}^N x_i$$

x_i aus beliebiger Verteilung mit Mittelwert μ_i und endlicher Varianz σ_i

Bedingung von Lyapunov: $\sum_{i=1}^N E(|x_i - \mu_i|^3)$ endlich für alle n \Rightarrow

x ist Gauß-verteilt mit Erwartungswert $\mu = \sum_{i=1}^N \mu_i$ und Varianz $\sigma^2 = \sum_{i=1}^N \sigma_i^2$

Beweis im Prinzip einfach; erfordert neues Konzept: die „charakteristische Funktion“ einer Verteilung, s. z.B. S. Brand, Datenanalyse

s. Demonstration mit Root

weitere Verteilungen: χ^2

x_i standard-normalverteilt

$$\chi^2 = z = \sum_{i_1}^N x_i^2$$

folgt der sogenannten

χ^2 -Verteilung mit n Freiheitsgraden:


$$f(z; n) = \frac{1}{2^{n/2} \Gamma(n/2)} z^{n/2-1} e^{-z/2} \quad (z \geq 0)$$

Erwartungswert $E[z] = E[\chi^2] = n$

Varianz $V[z] = V[\chi^2] = 2n$

Anwendung: Summe der quadratischen Abweichung von Messwerten von einer Funktion,

$\chi^2 = \sum_{i=1}^n \frac{(y_i - t_i)^2}{\sigma_i^2}$, folgt einer χ^2 -Verteilung (für Gauß-förmige Fehler σ_i , s. auch später: χ^2 -Anpassung)



Es gilt: $\chi^2_{(n)} + \chi^2_{(m)} = \chi^2_{(n+m)}$

für große n ist $(\chi^2 - n) / \sqrt{2n}$
standard-normalverteilt.

Weitere Verteilungen: Cauchy (=Breit-Wigner) - Verteilung


$$f(x) = \frac{1}{\pi} \frac{1}{1+x^2}$$

$$f(x; \Gamma, x_0) = \frac{1}{\pi} \frac{\Gamma/2}{\Gamma^2/4 + (x - x_0)^2}$$

Erwartungswert $E[x] = x_0$

(aber schlecht definiert!)

Varianz existiert nicht, statt dessen
Halbwertsbreite („FWHM“) = Γ



- tritt bei allen Resonanzphänomenen auf,
 $V[x] = \sigma$
- ist Fouriertransformierte (im Frequenz- (=Energie) -Raum)
der Exponentialverteilung (in Zeit t).
- Unschärferelation: Resonanzbreite = h /Lebensdauer

Generalisierte Poisson-Verteilung: Gamma-Verteilung

Verteilung des Erwartungswertes einer Poissonverteilung, bestimmt aus der mit dem Faktor α skalierten Beobachtung von N Poisson-verteilten Ereignissen, $n=\alpha N$, z.B:

- N simulierte Ereignisse, αN Ereignisse in Daten erwartet
- Untergrundbeobachtung in Seitenband, αN Ereignisse im Signalbereich erwartet

$n=\alpha N$ folgt

$$p(n; \alpha, N) = \frac{1}{\alpha} \frac{n/\alpha}{N!} \exp(-n/\alpha)$$

**Spezialfall einer
Gamma-Verteilung**

**Maximum bei αN
Mittelwert $\alpha(N+1)$
Varianz $\alpha^2(N+1)$**

Logarithmische Normalverteilung

Logarithmus einer Zufallsgröße ist normalverteilt:


$$f(x; \tilde{x}, \kappa) = \frac{1}{\sqrt{2\pi x \ln \kappa}} \exp\left(-\frac{(\ln(x/\tilde{x}))^2}{2(\ln \kappa)^2}\right)$$

Eigenschaften:

- $f(x=0) = 0$; längere Ausläufer als Gaußverteilung für große x
- geht für Werte von $\kappa \approx 1$ mit $\kappa = \exp(\varepsilon) \approx 1 + \varepsilon$ und $\varepsilon = \sigma/\mu$ asymptotisch in die Gaußverteilung $G(x; \mu, \sigma)$ über

Anwendung: Größen, die sich als Produkt von fehlerbehafteten Faktoren ergeben

Bsp: Aussage „Faktor zwei Unsicherheit“ gut beschrieben durch Log-Normalverteilung mit $\kappa=2$



Mehrere, nicht unabhängige Zufallsgrößen

Kovarianz und Korrelation

Kovarianzmatrix

Kovarianz zweier Zufallsvariablen ist **Erwartungswert** von

(Abweichung vom Erwartungswert in Variable x) *

(Abweichung vom Erwartungswert in Variable y)

$$\text{cov}[x, y] = E[(x - \mu_x)(y - \mu_y)] = E[xy] - \mu_x\mu_y$$

Diagonalwerte sind die Varianzen:

Erwartungswert von (Abweichung vom Erwartungswert in Variable x)**2

$$\begin{aligned}\text{cov}[x, x] = V_x = \sigma_x^2 &= E[(x - \mu_x)^2] \\ &= E[x^2] - 2E[x]\mu_x + \mu_x^2 \\ &= E[x^2] - \mu_x^2\end{aligned}$$

Analog auch bei mehr als zwei Variablen:



$\text{cov}(x_i, x_j)$ bildet die **Kovarianzmatrix**

Korrelationsmatrix

Normiere Kovarianzmatrix, so dass die Diagonalelemente alle 1 sind:



$$\rho_{xy} = \frac{\text{cov}[x, y]}{\sigma_x \sigma_y}, \quad -1 \leq \rho_{xy} \leq 1$$

$$\rho = 0.75$$



$$\rho = -0.75$$

$$\rho = 0.95$$



$$\rho = 0.25$$

Korrelation

Wenn x, y unabhängig, d.h. $f(x, y) = f_x(x)f_y(y)$, dann gilt

$$E[xy] = \int \int xy f(x, y) dx dy = \mu_x \mu_y$$

$\Rightarrow \text{cov}[x, y] = 0$ x und y „unkorreliert“

Achtung: Die umgekehrte Aussage gilt nicht:

Beispiel: $x \in [-1, 1], y = x^2$

Praktisches Beispiel: Konstruktion einer Kovarianz-Matrix

Anfängerpraktikum: 6 Studenten in 3 Gruppen mit jeweils eigenem Messgerät vom gleichen Typ, von allen angewandte „Theorie-Korrektur“ mit Unsicherheit, 6 Einzelergebnisse.

Fehlerbeiträge:


- Systematischer Fehler eines Messgeräts: s (korreliert innerhalb einer Gruppe, d.h. Studierende 1-2, 3-4 und 5-6, unabhängig zwischen den Gruppen)
- Theoriefehler: t (korreliert für allen Messungen)
- Unabhängiger Messfehler jeder Gruppe: f_1, \dots, f_6

Jede Messung hat den Gesamtfehler $g_i = \sqrt{(f_i^2 + s^2 + t^2)}$

$$\text{COV} = \begin{pmatrix} g_1^2 & s^2+t^2 & t^2 & t^2 & t^2 & t^2 \\ s^2+t^2 & g_2^2 & t^2 & t^2 & t^2 & t^2 \\ t^2 & t^2 & g_3^2 & s^2+t^2 & t^2 & t^2 \\ t^2 & t^2 & s^2+t^2 & g_4^2 & t^2 & t^2 \\ t^2 & t^2 & t^2 & t^2 & g_5^2 & s^2+t^2 \\ t^2 & t^2 & t^2 & t^2 & s^2+t^2 & g_6^2 \end{pmatrix}$$

Gauß-Verteilung in mehreren Dimensionen

$$p(\vec{x}|\vec{\mu}, V) = \frac{1}{(2\pi)^{\frac{n}{2}} |V|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} (\vec{x} - \vec{\mu})^T V^{-1} (\vec{x} - \vec{\mu}) \right]$$



$$V = \begin{pmatrix} \sigma_1^2 & \sigma_1\sigma_2\rho_{12} & \cdot & \cdot & \cdot & \sigma_1\sigma_n\rho_{1n} \\ \sigma_2\sigma_1\rho_{21} & \sigma_2^2 & \cdot & \cdot & \cdot & \sigma_2\sigma_n\rho_{2n} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \sigma_n\sigma_1\rho_{n1} & \cdot & \cdot & \cdot & \sigma_n\sigma_{n-1}\rho_{n-1} & \sigma_n^2 \end{pmatrix}$$

Kovarianzmatrix

ρ_{ij} : Korrelationskoeffizienten

2-dimensional

$$g(x_1, x_2 | \mu_1, \mu_2, \sigma_1, \sigma_2, \rho) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \cdot \exp \left(-\frac{1}{2(1-\rho^2)} [u_1^2 + u_2^2 - 2\rho u_1 u_2] \right)$$


$$\text{mit } u_i = \frac{x_i - \mu_i}{\sigma_i}$$

2-dim. Gauß-Verteilung und Kovarianzellipse

Kontur konstanter Wahrscheinlichkeitsdichte

$$\left(\frac{x_1 - \mu_1}{\sigma_1}\right)^2 + \left(\frac{x_2 - \mu_2}{\sigma_2}\right)^2 - 2\rho_{12} \left(\frac{x_1 - \mu_1}{\sigma_1}\right) \left(\frac{x_2 - \mu_2}{\sigma_2}\right) = 1 - \rho_{12}^2 \quad \text{ist eine Ellipsengleichung}$$


x_2
Kovarianz-Ellipse



Winkel zwischen
x-Achse und Haupt-
achse der Ellipse
hängt von ρ_{12} ab:

$$\tan 2\alpha = \frac{2\rho_{12}\sigma_1\sigma_2}{\sigma_1^2 - \sigma_2^2}$$

- $\alpha=45^\circ$ nur für $\sigma_1 = \sigma_2$
- $\alpha=0^\circ$ für $\rho_{12}=0$



Ellipsen berühren das Rechteck mit den
Kantenlängen $2\sigma_1$ und $2\sigma_2$ an vier Stellen

Fläche innerhalb der 1- σ Ellipse entspricht $\sim 39\%$

Kovarianzellipse - Ablesen des Korrelationskoeffizienten

Betrachten normierte Variable $x_1' = x_1/\sigma_1$ und $x_2' = x_2/\sigma_2$







x_2' Normierte Kovarianz-Ellipse

→ **Halbachsen P_1' und P_2'**

$$P_1'^2 + P_2'^2 = 2 \quad \frac{P_1'^2 - P_2'^2}{2} = \rho$$

$$\rho = \frac{P_1'^2 - P_2'^2}{P_1'^2 + P_2'^2}$$

Korrelationskoeffizient lässt sich aus Längen der Halbachsen bestimmen




Kovarianz in ROOT

Standard-normalverteilte Zufallszahlen mit $\rho=0.75$


`mux=0.00, sigx=1.00, muy=0.00, sigy=1.00, rho=0.75`

measured correlation 0.754

correlated random numbers



correlated random numbers



```
TH2::Draw("surf3");
```

```
„scatter plot“ TH2::Draw();
```

Methoden `TH2::GetCovariance` und `TH2::GetCorrelationFactor`
zur Berechnung der Kovarianz oder des Korrelations-Koeffizienten

Multinomial-Verteilung

Verallgemeinerung der Binomialverteilung von zwei auf k mögliche Ergebnisse,
Verteilung der Anzahlen \mathbf{n}_k für die Beobachtung von Ereignis k bei N Versuchen

$$P(n_1 \dots n_k; N, p_1 \dots, p_k) = \frac{N!}{n_1! \dots n_k!} p_1^{n_1} \dots p_k^{n_k}, \quad N = \sum_{i=1}^k n_i$$

Eigenschaften:

Erwartungswert $E[n_i] = N p_i$

Varianz $V[n_i] = \text{cov}(n_i, n_i) = N p_i (1 - p_i)$

Kovarianz $\text{cov}[n_i, n_j] = -N p_i p_j$

Korrelationskoeffizient $\rho_{ij} = -\sqrt{\frac{p_i p_j}{(1 - p_i)(1 - p_j)}}$

Beschreibt z.B. Verteilung der Bin-Inhalte eines Histogramms mit k Bins und N Einträgen

Randverteilung **$\mathbf{P}(\mathbf{n}_j) = \text{Binomial}(\mathbf{n}_j; N, p_j)$**

Grenzverteilung für große N und k : **$\mathbf{P}(\mathbf{n}_j) = \text{Poisson}(\mathbf{n}_j; N p_j)$**

Funktionen von Zufallsgrößen

Einfacher Fall: lineare Funktionen von Zufallsvariablen

Zufallsvariable:
$$x = \sum_i^N a_i x_i$$

Erwartungswert $E[x]$:
$$E \left[\sum_i^N a_i x_i \right] = \sum_i^N a_i E[x_i] = \sum_i^N a_i \mu_{x_i}$$

Varianz $V[x]$:
$$V \left[\sum_i^N a_i x_i \right] = \sum_i^N a_i^2 V[x_i] + 2 \sum_{i=1}^N \sum_{j=i+1}^N a_i a_j \text{cov}(x_i, x_j)$$

Bitte nicht die Kovarianzen vergessen, nur für unkorrelierte Zufallsvariable gilt die einfache Fehlerfortpflanzung

$$V \left[\sum_i^N a_i x_i \right] = \sum_i^N a_i^2 V[x_i] \quad \text{bzw.} \quad \sigma_x^2 = \sum_i a_i^2 \sigma_{x_i}^2$$

Variablentransformation

Eine Funktion $\mathbf{u}(\mathbf{x})$ einer Zufalls- Variablen x mit *pdf* $\mathbf{f}(\mathbf{x})$ ist ebenfalls eine Zufallsvariable mit *pdf* $\mathbf{g}(\mathbf{u})$

Oft ist die Kenntnis von $\mathbf{g}(\mathbf{u})$ notwendig:

- kinetische Energie ist eine Funktion des Quadrats der Geschwindigkeiten
- eine Größe ist eine Funktion verschiedener Messgrößen;
außer dem Fehler interessiert oft auch die pdf
- Erzeugung beliebiger Verteilungen durch Transformation von gleichverteilten Zufallszahlen


Für **diskrete Verteilungen** ist die Berechnung trivial:

$$u_k = u(x_k) \quad (u \text{ ist umkehrbar eindeutige Funktion von } x)$$

$$\text{Prob} [u(x_k)] = \text{Prob} [x_k] \quad \text{für jedes } k$$

Variablentransformation II

- Kontinuierliche Verteilungen



Es muss gelten:

$$P(x_1 < x < x_2) = P(u_1 < u < u_2)$$

mit $u_1 = u(x_1)$, $u_2 = u(x_2)$


(blau unterlegte Flächen)

Differentiell geschrieben:

$$|g(u) du| = |f(x) dx| \text{ oder}$$

$$g(u) = f(x) |dx / du|$$


$u(x)$ ist eindeutig umkehrbare Funktion von x



durch Integration folgt **Gleichheit der Verteilungsfunktionen: $F(x) = G(u)$**

Variablentransformation III

$u(x)$ ist mehrdeutig



Wenn u mehrdeutig ist, muss über die Beiträge der einzelnen Funktionsäste summiert werden:

$$g(u) = \left\{ f(x) \left| \frac{dx}{du} \right| \right\}_{Ast1} + \left\{ f(x) \left| \frac{dx}{du} \right| \right\}_{Ast1} + \dots$$

Variablentransformation - Beispiele

$$u = -\ln(x) ; \quad \left| \frac{dx}{du} \right| = \exp(-u)$$

x gleichverteilt in]0,1], d.h. $f(x)=1$ \Rightarrow

$$g(u) = \exp(-u)$$

$$u = \exp(x) ; \quad \frac{dx}{du} = 1/u$$

x gleichverteilt in]0,1] \Rightarrow

$$g(u) = 1/u$$

Oder andersherum: $x=\ln(u)$ gleichverteilt \rightarrow pdf $1/u$

Variablentransformation - Beispiele

x normalverteilt,

$$u = (x - \mu)^2 / \sigma^2$$

$$dx/du = (2\sqrt{u})^{-1} \Rightarrow$$

$$g(u) = \left\{ \frac{s}{2\sqrt{u}} \frac{1}{s\sqrt{2\pi}} e^{-u/2} \right\}_{Ast1} + \{ \dots \}_{Ast2}$$

Beiträge beider Äste sind gleich, also:

$$g(u) = \frac{1}{\sqrt{2\pi u}} e^{-u/2}$$

χ^2 - Verteilung für einen Freiheitsgrad

Variablentransformation in mehreren Dimensionen

„Multivariate Verteilungsdichten“

Wahrscheinlichkeitsdichte $f(x,y)$;

x und y werden transformiert in $u=u(x,y)$ und $v=v(x,y)$

Wieder muss gelten:

$$g(u,v) du dv = f(x,y) dx dy$$

d.h. $g(u,v) = f(x,y) \cdot |J|$; dabei ist

$$|J| = \det \begin{pmatrix} \partial x / \partial u & \partial x / \partial v \\ \partial y / \partial u & \partial y / \partial v \end{pmatrix}$$

die Jakobi- oder Funktional-Determinante

Ganz analog:

Erweiterung auf n Dimensionen, $\mathbf{x}_i = \mathbf{x}_i(u_1, u_2, \dots, u_n)$, $i=1, \dots, n$

Funktionen von Zufallsvariablen

Fehlerfortpflanzung

Fehlerfortpflanzung

Problem: eine Größe y hängt von Zufallsgrößen x_i ab;
was ist die Varianz von y ?

Fragestellung tritt auch auf bei der Mittelung von Messungen

(der Mittelwert ist schließlich eine Funktion aller Einzelmessungen x_i)

Falls die Verteilungsdichten der x_i bekannt sind, könnte man mittels Variablentransformation die Verteilungsdichte von y bestimmen und die Varianz berechnen.

Wenn die Varianz der x_i so klein ist, dass sich die Funktion $y(\mathbf{x})$ im Bereich der Variation der x_i durch eine Gerade annähern läßt, hilft eine Taylor-Entwicklung um den Vektor der Mittelwerte \mathbf{x}_m

$$y(\mathbf{x}) = y(\mathbf{x}_m) + \left(\frac{\partial y}{\partial x_1}, \dots, \frac{\partial y}{\partial x_n} \right) (\mathbf{x} - \mathbf{x}_m) + \dots$$

y ist näherungsweise eine lineare Funktion der x_i

Fehlerfortpflanzung (2)

Betrachten allgemeinen Fall eines Vektors y_j von Funktionen der x_i , $y(\mathbf{x})$

(der Fall von eben entspricht z.B. $y_1=y(x_1,\dots,x_n)$, $y_2=x_2$, ..., $y_n=x_n$)

$\Rightarrow y(\mathbf{x}) \approx y(\mathbf{x}_m) + T (\mathbf{x}-\mathbf{x}_m)$, $T_{ij} = \left(\frac{\partial y_i}{\partial x_j} \right)$ ist Matrix der ersten Ableitungen

Der Erwartungswert von y ist $\langle y \rangle = y_m = y(\mathbf{x}_m)$

Die Kovarianz-Matrix der y_j ergibt sich zu

$$\begin{aligned} C_y &= \langle (\mathbf{y}-\mathbf{y}_m)(\mathbf{y}-\mathbf{y}_m)^T \rangle \\ &= \langle (\mathbf{y}(\mathbf{x}_m) + T(\mathbf{x}-\mathbf{x}_m) - \mathbf{y}_m) (\mathbf{y}(\mathbf{x}_m) + T(\mathbf{x}-\mathbf{x}_m) - \mathbf{y}_m)^T \rangle \\ &= \langle (T(\mathbf{x}-\mathbf{x}_m)) (T(\mathbf{x}-\mathbf{x}_m))^T \rangle \\ &= \langle T (\mathbf{x}-\mathbf{x}_m) (\mathbf{x}-\mathbf{x}_m)^T T^T \rangle \\ &= T \langle (\mathbf{x}-\mathbf{x}_m) (\mathbf{x}-\mathbf{x}_m)^T \rangle T^T = T C_x T^T \end{aligned}$$

Zu den Fehlern von y trägt auch die Kovarianz der x_i entscheidend bei !

Fehlerfortpflanzung (3)

Falls die Kovarianzmatrix-Elemente der x_i verschwinden (bzw. vernachlässigbar sind), C_x also eine Diagonalmatrix ist, erhält man das bekannte Fehlerfortpflanzungsgesetz

$$\sigma_{y_j}^2 = \sum_{i=1}^n \left(\frac{\partial y_j}{\partial x_i} \right)^2 \sigma_{x_i}^2$$

für x_1, x_2 unkorreliert:

$$y = x_1 + x_2$$

$$\Rightarrow \sigma_y^2 = \sigma_1^2 + \sigma_2^2 + 2\text{COV}[x_1, x_2]$$

Quadrierter *absoluter* Fehler auf Summe (oder Differenz) zweier Zahlen ist die quadratische Summe ihrer *absoluten* Fehler

$$y = x_1 x_2$$

$$\Rightarrow \frac{\sigma_y^2}{y^2} = \frac{\sigma_1^2}{x_1^2} + \frac{\sigma_2^2}{x_2^2} + 2 \frac{\text{COV}[x_1, x_2]}{x_1 x_2}$$

Quadrierter *relativer* Fehler auf Produkt (oder Verhältnis) zweier Zahlen ist die quadratische Summe ihrer *relativen* Fehler

Fehlerfortpflanzung (4)

Korrelationen können das Bild sehr stark verändern:

Beispiel: $y = x_1 - x_2$

$\mu_1 = \mu_2 = 10$, $\sigma_1 = \sigma_2 = 1$, Korrelationskoeffizient $\rho = 0$:

$$\implies \sigma_y = 1.4$$

Aber mit Korrelationskoeffizient $\rho = 1$:

$$\implies \sigma_y = 0!$$

Tücken der Fehlerfortpflanzung

Achtung: bei nichtlinearen Transformationen $y(x)$ auf den Erwartungswert aufpassen:

Es gilt NICHT allgemein

$$E[y(x)] = y(E[x])$$

sondern:

$$E[y(x)] \approx y(E[x]) + \frac{1}{2} \left(\frac{d^2 y}{dx^2} \right)_{x=E[x]} \sigma_x^2$$




Der zweite Term ist wichtig, wenn sich die Steigung der Transformation innerhalb einer Standardabweichung von x erheblich ändert, d.h. bei großer Krümmung.

Fehlerfortpflanzung: Tücken (2)

Einfache Operationen mit gaußverteilten Zufallsvariablen (wie z.B. Anfängerpraktikum)

$z=x+y$ oder $z=x-y$ klarer Fall: lineare Transformation \rightarrow **z gaußförmig**

$z=x*y$? nach Vorschrift: $\left(\frac{\sigma_z}{z}\right)^2 = \left(\frac{\sigma_x}{x}\right)^2 + \left(\frac{\sigma_y}{y}\right)^2$, **aber ist z gaußverteilt ???**



jedenfalls nicht immer !

Fehlerfortpflanzung: Tücken (3)

$z=x/y$ wieder nach Vorschrift: $\left(\frac{\sigma_z}{z}\right)^2 = \left(\frac{\sigma_x}{x}\right)^2 + \left(\frac{\sigma_y}{y}\right)^2$, **aber wie ist z verteilt ???**

z folgt meistens keiner Gaußverteilung !

Für normalverteilte x,y mit $\mu=0$ und $\sigma=1$ folgt z sogar einer Cauchy-Verteilung:

$$p(z) = \frac{1}{\pi(1+z^2)} \quad \sigma \text{ ist hier gar nicht endlich !}$$


Falls μ_y / y so groß, das y nicht negativ wird:

$$p(Z) = \frac{1}{\sqrt{2\pi}} \frac{\mu_Y \sigma_X^2 + \mu_X \sigma_Y^2 Z}{(\sigma_X^2 + \sigma_Y^2 Z^2)^{\frac{3}{2}}} \exp \left[-\frac{1}{2} \frac{(\mu_X - \mu_Y Z)^2}{\sigma_X^2 + \sigma_Y^2 Z^2} \right]$$

s. Eadie et al.

$1.0 (+-0.30) * 1.0(+0.30)$


product of x and y



Verteilung des Produktes zweier Zufallszahlen, je Gauss($\mu=1$, $\sigma=0.3$), u. Gauß-Funktion mit Parametern aus naiver Fehlerfortpflanzung
(Beispiel `xtimesy.C`)

 $6.0 (+-1.0) / 2.0 (+-1.0)$

ratio of x and y



Verteilung des Quotienten zweier Zufallszahlen, Gauss($\mu=6$, $\sigma=1$) u. Gauss($\mu=2$, $\sigma=1$), u. Gauß-Funktion mit Parametern aus naiver Fehlerfortpflanzung
(Beispiel `xovery.C`)

Simulation mit Zufallszahlen ist der nächste Teil dieser Vorlesung !