

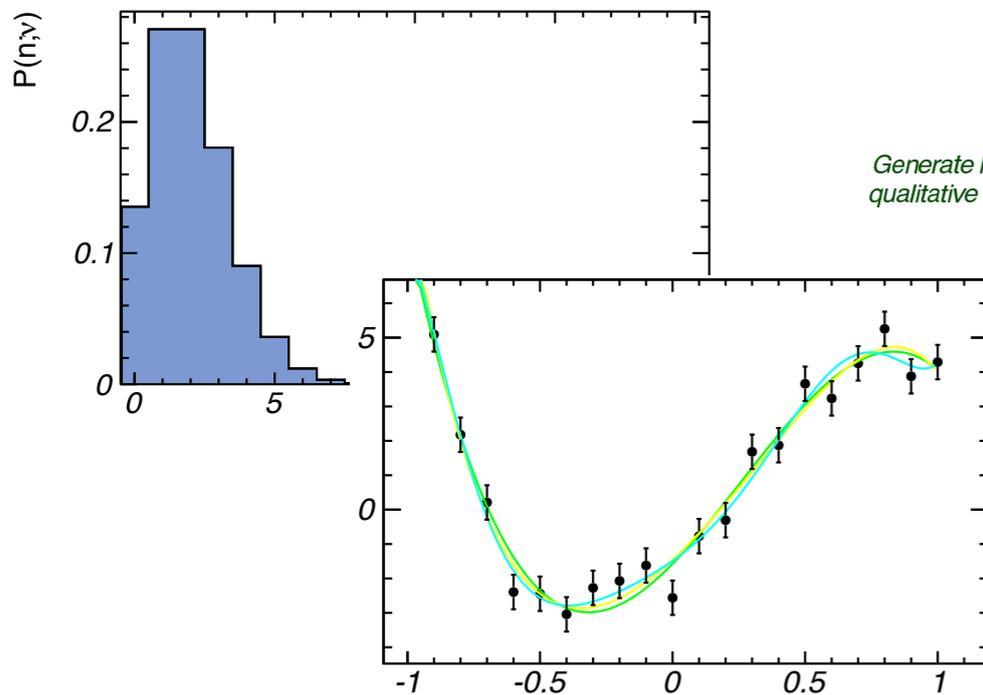
# Rechnernutzung in der Physik

## Teil 3 – Statistische Methoden der Datenanalyse

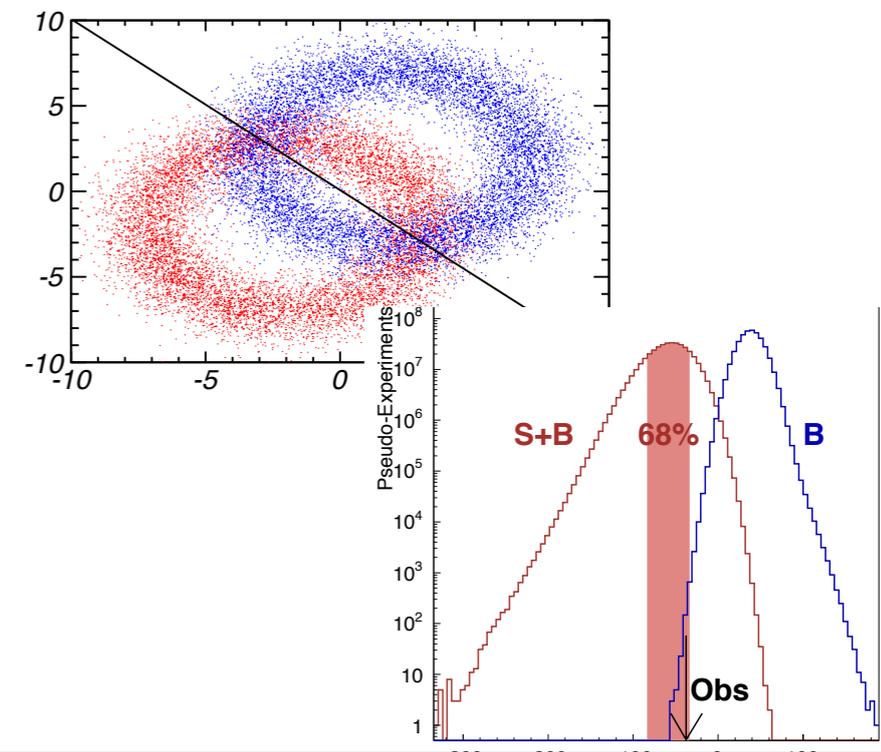
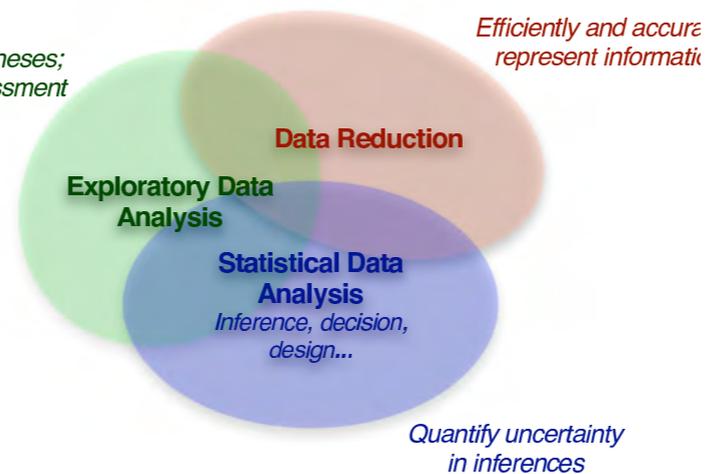
Karlsruher Institut für Technologie  
Wintersemester 2012/2013

Ulrich Husemann

Institut für Experimentelle Kernphysik, Karlsruher Institut für Technologie



Generate hypotheses;  
qualitative assessment



# QISPOS-Anmeldung

- Rechnernutzung jetzt bei QISPOS freigeschaltet  
→ bitte anmelden
  - Name: Rechnernutzung
  - Prüfungsnummer: 172
  - Anmeldebeginn: 15.10.12
  - Anmeldeende: 07.02.13
  - Rücktrittsende: 07.02.13
  - Prüfungsdatum: 08.02.13

# Kurze Wiederholung

## ■ Beispiele für Wahrscheinlichkeitsverteilungen

■ Binomialverteilung („Erfolg-Misserfolg”)  $P(n; N, p) = \binom{N}{n} p^n (1 - p)^{N-n}$

■ Poissonverteilung („Zählexperiment”)  $P(n; \nu) = \frac{\nu^n}{n!} e^{-\nu}$

■ Gaußverteilung (zentraler Grenzwertsatz)  $G(x; \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(x - \mu)^2}{2\sigma^2}\right]$

■ Log-Normalverteilung  $f(x; \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} \frac{1}{x} \exp\left[-\frac{(\ln x - \mu)^2}{2\sigma^2}\right]$

■  $\chi^2$ -Verteilung  $\chi^2(x; n) = \frac{x^{\frac{n}{2}-1}}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} \exp\left[-\frac{x}{2}\right]$

■ Cauchy-Lorentz-Verteilung (Resonanzen)  $f(x; x_0, \Gamma) = \frac{1}{\pi} \frac{\Gamma}{(x - x_0)^2 + \Gamma^2}$

## ■ Monte-Carlo-Methoden

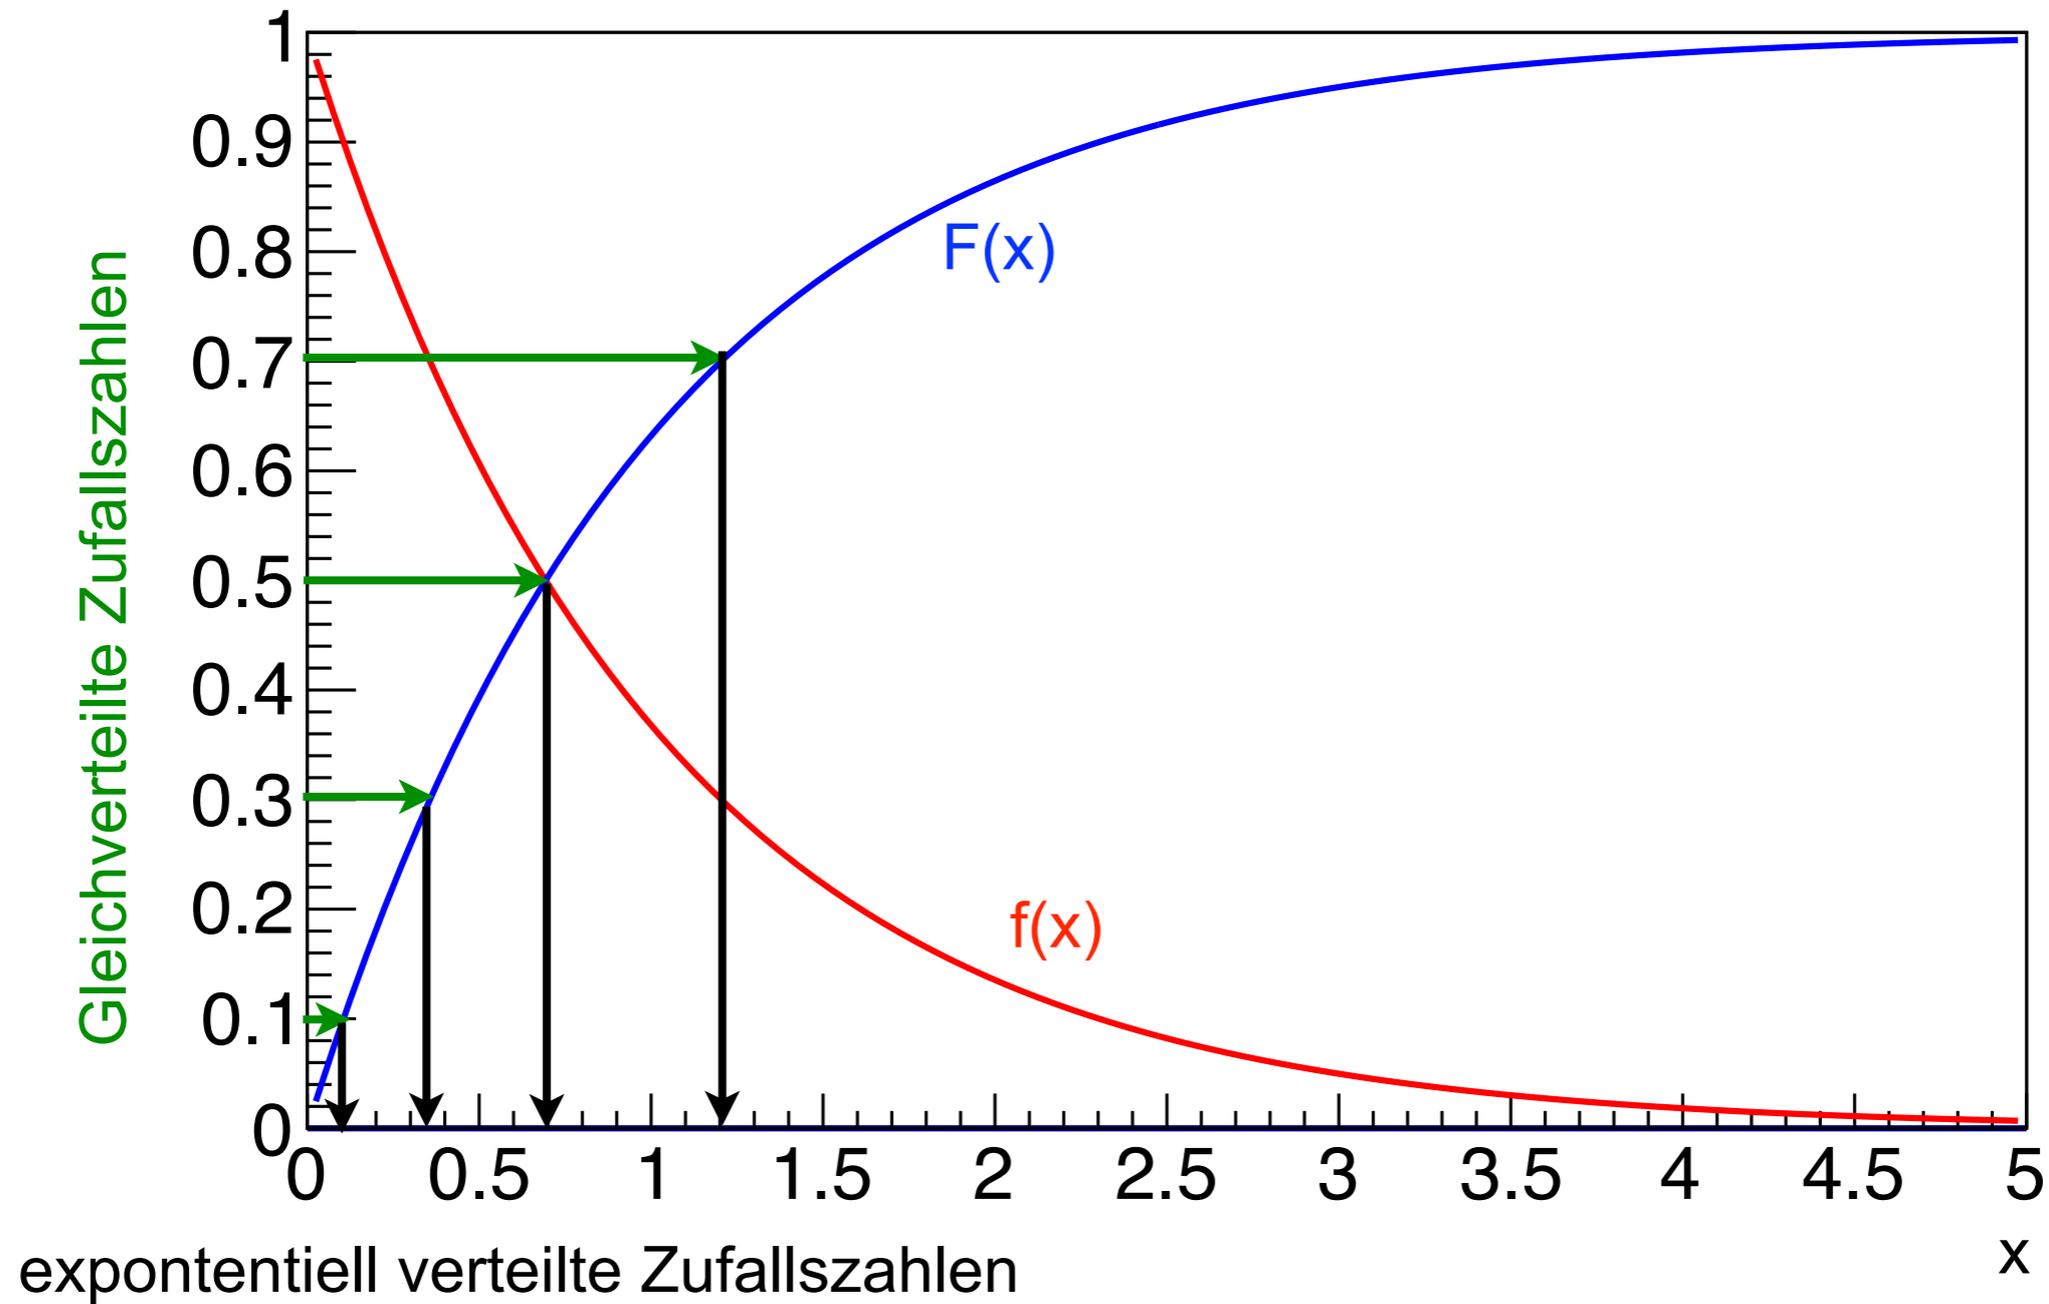
■ Numerische Techniken zur Berechnung von W.keiten mit Zufallszahlen

■ Pseudozufallszahlen im Computer: lange Periode, so wenig Korrelation wie möglich, Startwert („seed”) geschickt wählen (z. B. Mersenne-Twister)

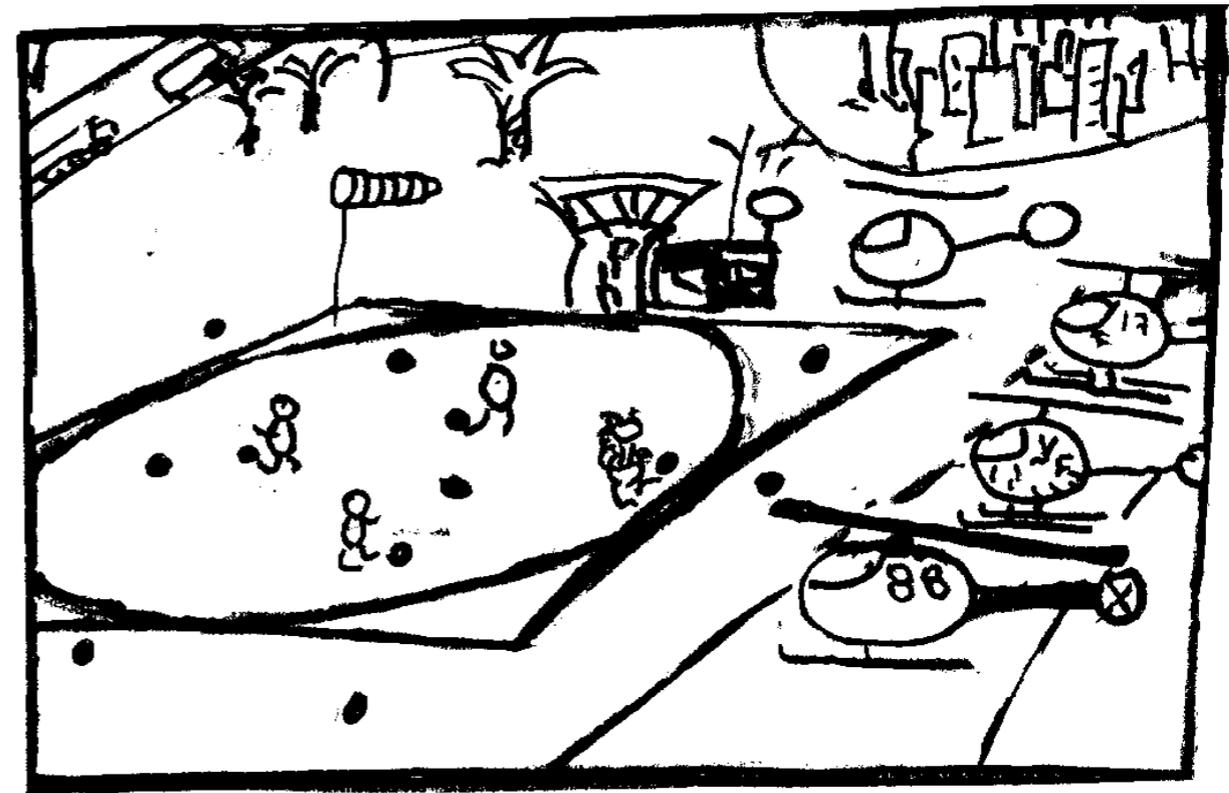
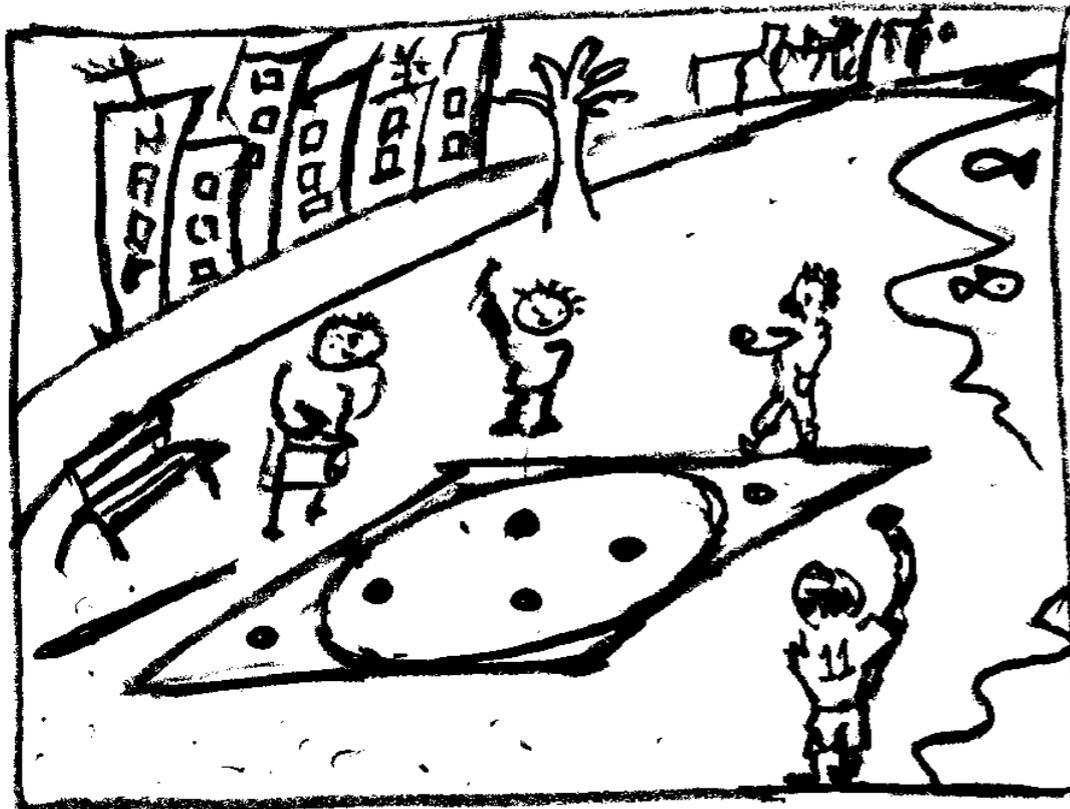
## Kapitel 3.4

# Monte-Carlo-Methoden

# Transformationsmethode



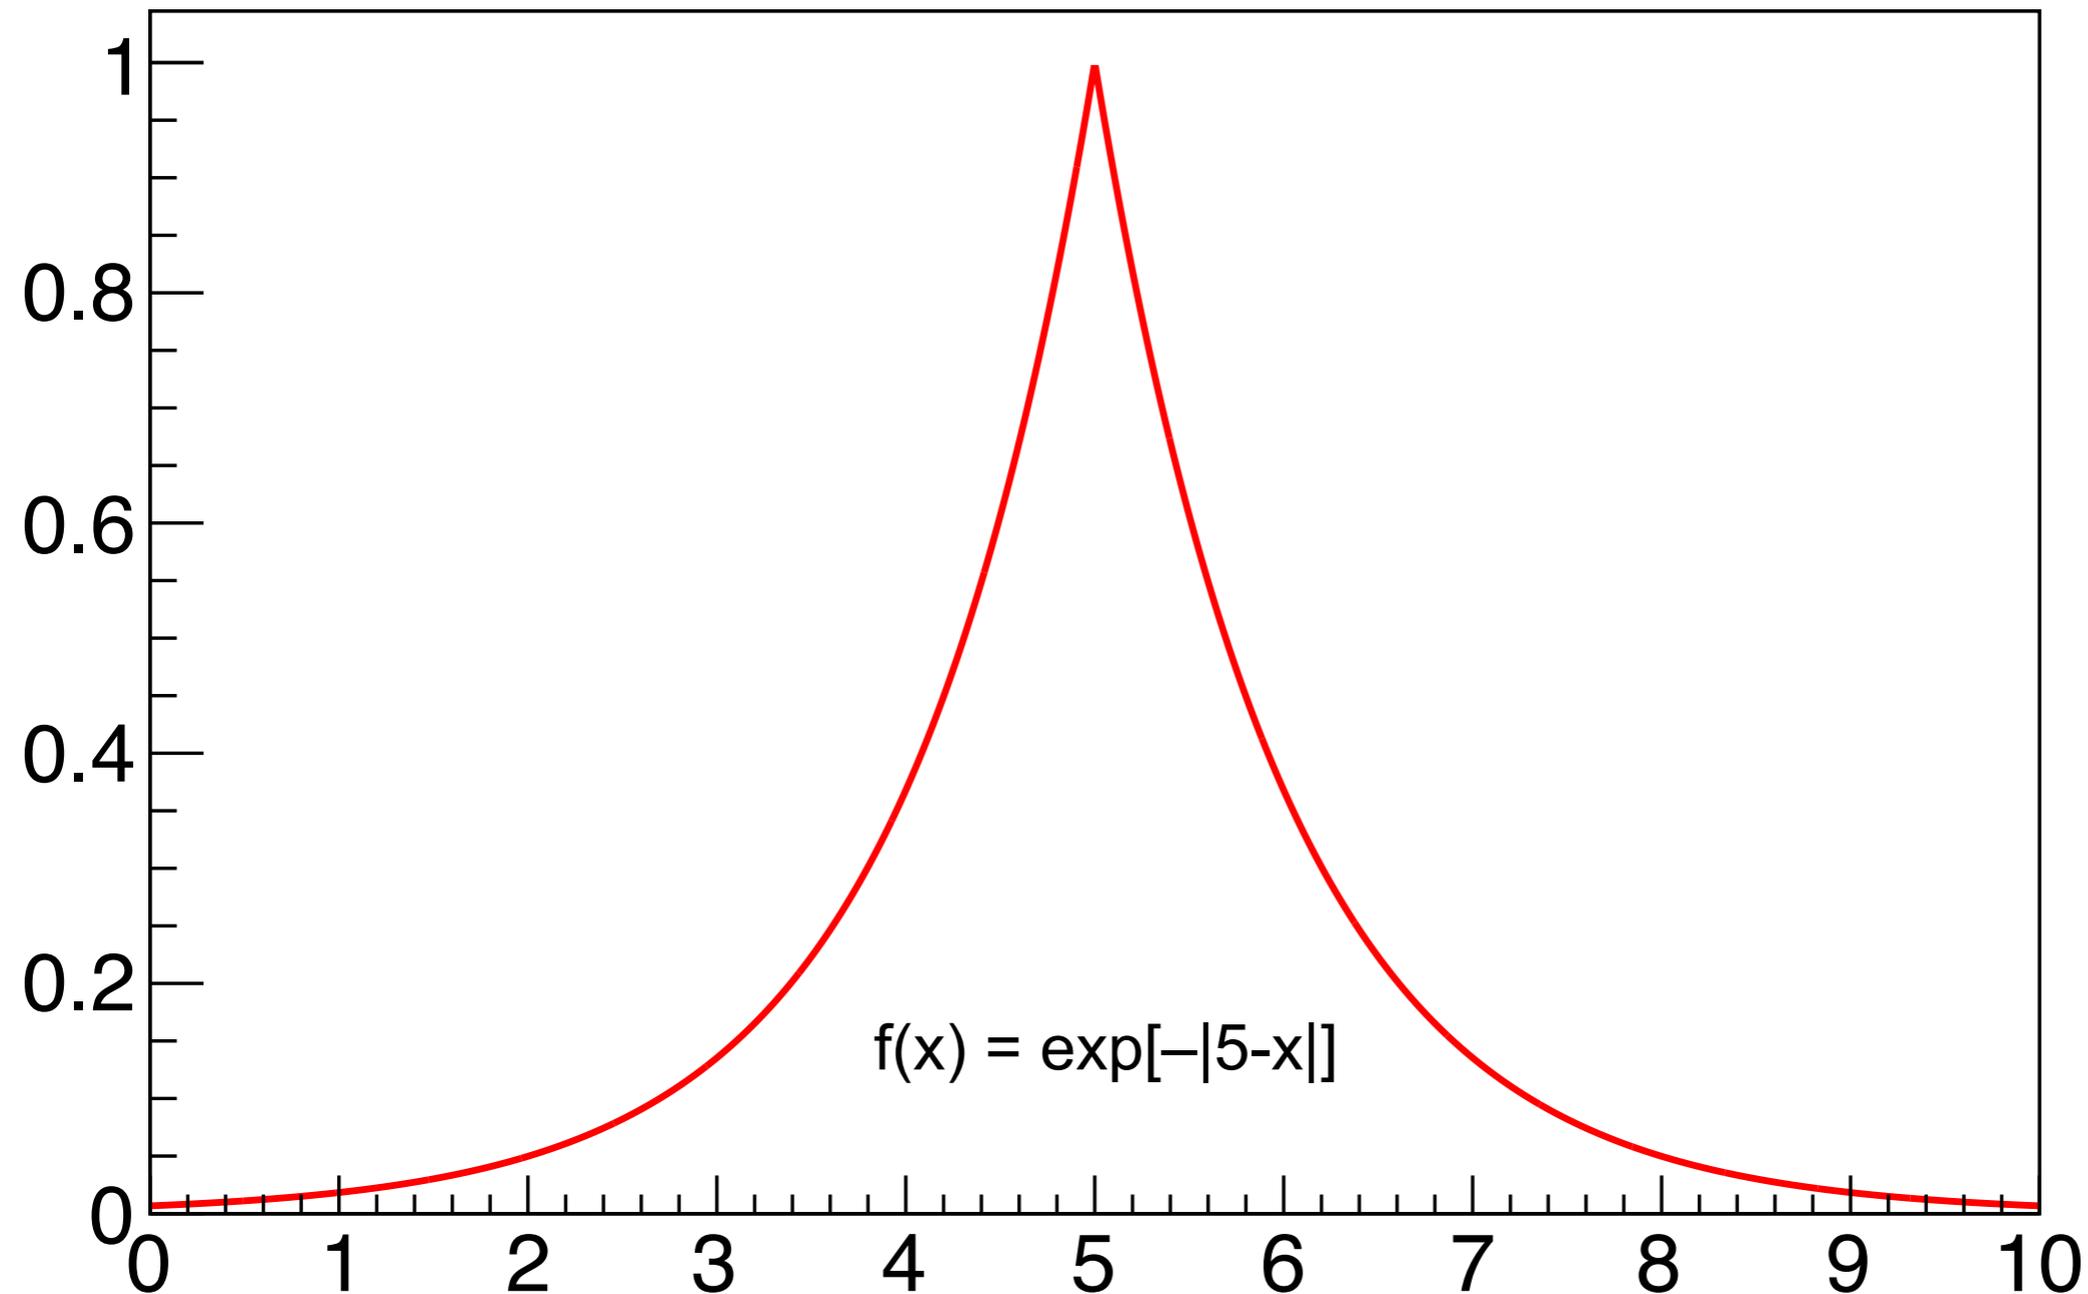
# Beispiel 1: Bestimmung von $\pi$



[W. Krauth, arXiv:cond-mat/9612186v2]

- Idee: Verhältnis der Kreisfläche zur Quadratfläche  $\pi/4$ 
  - Würfle gleichverteilte Zufallszahlen  $x, y$
  - Verwerfungsmethode: liegt  $(x,y)$  innerhalb des Kreises?
  - Vgl. Übungen

# Beispiel 2: MC-Integral



Analytische Lösung:  $2(1 - \exp[-5]) = 1.9865$

# Genauigkeit der MC-Methode

- MC-Integration:  $\int_{x_1}^{x_2} f(x) dx = \lim_{N \rightarrow \infty} \frac{N_{\text{hit}}}{N} \cdot (x_2 - x_1) \cdot y_{\text{max}}$ 
  - Effizienz  $\varepsilon = N_{\text{hit}}/N \rightarrow$  Genauigkeit aus Binomialverteilung:  $V[\varepsilon] = \varepsilon(1-\varepsilon)/N$
  - Verbesserung mit  $\sqrt{N}$  unabhängig von Dimension  $d$  des Integrals
- Vergleich: Quadraturformeln, z. B. Trapezregel
  - Effizienz skaliert mit Zahl der Stützstellen  $n$ :  $V[\varepsilon] \sim n^{-4}$   
 $\rightarrow$  viel besser als MC-Methode
  - Höherdimensionale Integrale ( $d$  Dimensionen):  $V[\varepsilon] \sim n^{-4/d}$   
 $\rightarrow$  MC-Integration ab 4 Dimensionen effizienter

# Anwendungen der MC-Methode

- Numerische Mathematik, z. B. Integration, Optimierung
- Angewandte Statistik, z. B. PDFs, Fehlerfortpflanzung, Hypothesentests
- Simulation stochastischer Prozesse
  - Vielteilchensysteme, z. B. Ising-Modell für gekoppelte Spins
  - Teilchenphysik: quantenmechanische Prozesse, z. B. Produktion von Elementarteilchen → „MC-Generatoren“ (z. B. Pythia)
  - Wechselwirkung von Teilchen in Materie, z. B. Neutrondiffusion, Streuung

## Kapitel 3.5

# Parameterschätzung

# Grundbegriffe

- Bislang: Wahrscheinlichkeitstheorie → jetzt: Arbeit mit Daten

Wahrscheinlichkeitstheorie	Messung
PDF = ideale Wahrscheinlichkeitsverteilung	Beobachtete Ereignisse = endliche zufällige Stichprobe aller mögliche Ergebnisse (engl.: random sample)
Bekanntes W.keitsmodel mit bekannten Parametern	Konstruktion einer “Likelihood- Funktion” (später) aus Daten → Schätzung der Parameter

- Ziel: Schätzung einer (hoffentlich kleinen) Zahl von Modellparametern aus (potenziell großer) Datenmenge

- **Stichprobe** der Größe  $n$ :
  - $n$ -dimensionaler Vektor  $\mathbf{x} = (x_1, \dots, x_n)$  unabhängiger Zufallsvariablen  $x_i$ ,
  - $x_i$  stammen aus einer Grundgesamtheit (auch: Population) der Größe  $N$
  - $x_i$  folgen derselben PDF  $f(x)$ , ggf. mit weiteren Parametern
  - Beispiel: 10 Längenmessungen
- **Prüfgröße** (auch: Kenngröße, engl.: statistic)
  - Beliebige Funktion der Daten der Stichprobe ohne freie Parameter (Stichprobe wird dabei als „eine Messungen“ interpretiert)
  - Beispiel: arithmetisches Mittel der Längenmessung  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$
- **Schätzfunktion** (auch: Schätzer, engl.: estimator)
  - Prüfgröße zur Schätzung von Eigenschaften der unbekannt PDF  $f(x)$
  - Beispiel: arithmetisches Mittel als Schätzer für „wahren“ Erwartungswert

# Parameterschätzung: Methoden

- Ziel: Schätzung eines Parameters  $\theta$  aus Daten
  - z. B. Steigung einer Ausgleichgeraden
- Gesucht: **systematische** Methoden, Schätzer mit „guten“ Eigenschaften zu konstruieren (z. B. erwartungstreu, möglichst kleine Varianz, ...)
- Methode der **kleinsten (Fehler-)Quadrate** (engl.: least squares method, LS)
  - Gauß, Laplace, Legendre, ca. 1800
  - Bekannt z. B. aus Praktikum („Ausgleichsgerade“)
- **Maximum-Likelihood-Methode (ML)**
  - Fisher, ca. 1912
  - Sehr universell einsetzbar

# LS und ML: Erster Vergleich

- Ausgangsfrage: welches Modell passt am besten zu den Daten?

Maximum Likelihood:  
maximiere Höhe der PDF

(PDF muss bekannt sein)

Kleinste Quadrate:  
minimiere Abstand vom  
Erwartungswert

(nur Erwartungswert  
bekannt)

